



**UNIVERSIDADE FEDERAL DO OESTE DO PARÁ
PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO
TECNOLÓGICA
PROGRAMA DE PÓS-GRADUAÇÃO EM RECURSOS NATURAIS DA AMAZÔNIA**

JEFFERSON ROSSY PEREIRA DA SILVA

**IDENTIFICAÇÃO DE COPAS DE ÁRVORES EM FLORESTAS DENSAS E
SAVANAS NA AMAZÔNIA USANDO VANTS E DEEP LEARNING**

**SANTARÉM – PARÁ
2024**

JEFFERSON ROSSY PEREIRA DA SILVA

**IDENTIFICAÇÃO DE COPAS DE ÁRVORES EM FLORESTAS DENSAS E
SAVANAS NA AMAZÔNIA USANDO VANTS E DEEP LEARNING**

Dissertação apresentada ao Programa de Pós-Graduação em Recursos Naturais da Amazônia da Universidade Federal do Oeste do Pará, como requisito para obtenção do título de Mestre em Ciências Ambientais.

Orientador: Prof. Dr. Anderson Alvarenga de Moura Meneses.

Coorientador: Prof. Dr. Gilson Fernandes da Silva.

**SANTARÉM – PARÁ
2024**

Dados Internacionais de Catalogação-na-Publicação (CIP)
Sistema Integrado de Bibliotecas – SIBI/UFOPA

S586i Silva, Jefferson Rossy Pereira da
Identificação de copas de árvores em florestas densas e savanas na Amazônia usando Vants e Deep Learning. /Jefferson Rossy Pereira da Silva. – Santarém, 2025.

70 p.: il.
Inclui bibliografias.

Orientador: Anderson Alvarenga de Moura Meneses.

Coorientador: Gilson Fernandes da Silva.

Dissertação (Mestrado) – Universidade Federal do Oeste do Pará, Pró-reitoria de Pesquisa, Pós-graduação e Inovação Tecnológica, Programa de Pós-Graduação em Recursos Naturais da Amazônia.

1. Detecção de Copas de Árvores. 2. Sensoriamento Remoto. 3. Inteligência Artificial. 4. Aprendizagem Profunda. I. Meneses, Anderson Alvarenga de Moura, *orient.* II. Silva, Gilson Fernandes da, *coorient.* III. Título.

CDD: 23 ed. 621


JEFFERSON ROSSY PEREIRA DA SILVA

**IDENTIFICAÇÃO DE COPAS DE ÁRVORES EM FLORESTAS DENSAS E
SAVANAS NA AMAZÔNIA USANDO VANTS E DEEP LEARNING**


Dissertação apresentada ao Programa de Pós-Graduação em Recursos Naturais da Amazônia da Universidade Federal do Oeste do Pará, como requisito para obtenção do título de Mestre em Ciências Ambientais.

Conceito: Aprovado


Data de Aprovação: 21 / 01 / 2025

Documento assinado digitalmente
 **ANDERSON ALVARENGA DE MOURA MENESES**
Data: 15/02/2025 09:24:34-0300
Verifique em <https://validar.iti.gov.br>


Prof. Dr. Anderson Alvarenga de Moura Menezes - Orientador
Universidade Federal do Oeste do Pará – UFOPA

Documento assinado digitalmente
 **RONIE SILVA JUVANHOL**
Data: 18/02/2025 15:44:41-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Ronie Silva Juvanhol - 1º examinador
Universidade Federal do Piauí - UFPI

Documento assinado digitalmente
 **WILDERCLAY BARRETO MACHADO**
Data: 17/02/2025 17:56:53-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Wilderclay Barreto Machado - 2º examinador
Universidade Federal do Oeste do Pará – UFOPA

Documento assinado digitalmente
 **DAVI GUIMARAES DA SILVA**
Data: 17/02/2025 16:31:56-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Davi Guimarães da Silva - 3º examinador
Instituto Federal do Pará – IFPA/Campus Itaituba

AGRADECIMENTO

Aos meus pais, irmãs e irmão, minha eterna gratidão pelo incentivo constante, apoio incondicional e por acreditarem em mim em todos os momentos desta jornada.

À minha noiva, meu mais profundo agradecimento por estar ao meu lado durante todo o percurso, oferecendo amor, compreensão e força, especialmente nos momentos mais desafiadores.

Ao meu orientador, Prof. Dr. Anderson Alvarenga de Moura Meneses, agradeço a sabedoria compartilhada, pelas orientações e por todo o suporte nas diversas etapas deste trabalho.

Ao meu coorientador, Prof. Dr. Gilson Fernandes da Silva, expresso minha gratidão pelas valiosas contribuições e pelo apoio durante o desenvolvimento deste trabalho.

Aos membros do Laboratório de Inteligência Computacional, agradeço por suas contribuições enriquecedoras, pelo ambiente colaborativo e pelo apoio essencial ao longo dessa caminhada.

Aos amigos, pela convivência inspiradora e pelas trocas que tanto agregaram à minha trajetória acadêmica.

À UFOPA, pela oportunidade de cursar este programa e pelo acesso ao CLUSTER Tapajós e demais infraestruturas que foram indispensáveis para a realização deste trabalho.

À FAPESPA, pelo apoio financeiro por meio da bolsa de mestrado, que foi fundamental para a concretização desta etapa tão importante.

Com imensa gratidão, dedico este trabalho a todos que, de alguma forma, fizeram parte desta conquista.

“Macte animo! Generose puer, sic itur ad astra.”

(Publius Papinius Statius)

RESUMO

A detecção de árvores individuais e sua quantificação é uma etapa importante na ecologia, sendo fundamental para o manejo de florestas, principalmente em unidades de conservação, e vem sendo um desafio automatizar esse processo. O sensoriamento remoto (SR) pode ser um forte aliado nesse aspecto ao permitir cobrir grandes áreas. Ao utilizar imagens aéreas em conjunto com modelos de *Deep Learning* (DL), é possível obter essa detecção automatizada e contribuir ao integrar novas tecnologias ao campo da ecologia. Por este motivo, o objetivo deste trabalho será analisar abordagens eficazes de detecção de copas de árvores baseadas em DL em imagens RGB obtidas através de Veículo aéreo não tripulado (VANT) em florestas ombrófilas densas e savanas amazônicas. Foram selecionadas imagens na APA Alter do Chão e FLONA Tapajós, onde foram coletadas imagens RGB com Distância da amostra do solo (GSD) de 3,26cm/pixel utilizando um VANT Air 2S para formar ortomosaicos de 1km² no formato tiff. Após o pré-processamento, as imagens foram submetidas a diferentes configurações de treinamento no modelo DeepForest, variando-se o número de épocas (10, 15 e 30) e a resolução (4 cm, 7 cm e 10 cm). Entre os resultados obtidos o modelo alcançou um valor de *F1 Score* de 0,8290 em 30 épocas, em comparação aos 0,7451 obtidos com 10 épocas. Utilizando a melhor resolução (4 cm), foram alcançados *F1 Score* de 0,9021 para a savana mais densa e 0,7984 para a FLONA Tapajós. Os resultados obtidos demonstram que foi possível adaptar o modelo DeepForest às condições específicas da Amazônia, um dos biomas mais complexos do mundo, evidenciando sua aplicabilidade em cenários desafiadores e seu potencial para estudos de conservação e manejo florestal. Dessa forma, conclui-se que o DeepForest, aliado ao uso de VANTs e imagens de alta resolução, é uma ferramenta eficaz para o monitoramento de florestas tropicais.

Palavras-Chave: Detecção de Copas de Árvores. Sensoriamento Remoto. Inteligência Artificial. Aprendizagem Profunda.

ABSTRACT

Individual tree detection and quantification is a crucial step in ecology, essential for forest management, particularly in conservation units, and automating this process remains a challenge. Remote sensing (RS) can be a powerful ally in this regard, enabling the coverage of large areas. By combining aerial images with Deep Learning (DL) models, it is possible to achieve automated detection and contribute to integrating new technologies into the field of ecology. For this reason, the objective of this study is to analyze effective approaches for tree crown detection based on DL in RGB images obtained through an Unmanned Aerial Vehicle (UAV) in dense ombrophylous forests and Amazonian savannas. Images were selected from the Alter do Chão Environmental Protection Area (APA) and the Tapajós National Forest (FLONA), where RGB images were collected with a Ground Sample Distance (GSD) of 3.26 cm/pixel using an Air 2S UAV to create 1 km² orthomosaics in TIFF format. After preprocessing, the images were subjected to different training configurations in the DeepForest model, varying the number of epochs (10, 15, and 30) and resolution (4 cm, 7 cm, and 10 cm). Among the results obtained, the model achieved an F1 Score of 0.8290 with 30 epochs, compared to 0.7451 with 10 epochs. Using the best resolution (4 cm), F1 Scores of 0.9021 were achieved for the denser savanna and 0.7984 for the Tapajós National Forest. The results demonstrate that the DeepForest model could be adapted to the specific conditions of the Amazon, one of the most complex biomes in the world, highlighting its applicability in challenging scenarios and its potential for conservation and forest management studies. Thus, it is concluded that DeepForest, combined with UAVs and high-resolution imagery, is an effective tool for monitoring tropical forests.

Keywords: Tree Crown Detection. Remote Sensing. Artificial Intelligence. Deep Learning.

LISTA DE ILUSTRAÇÕES

Figura 1 – Mapa das unidades de conservação (em verde) e áreas de desmatamento (em vermelho) no bioma Amazônia, com dados do ano de 2023 extraídos do MapBiomas.	21
Figura 2 – Comparação de imagens de satélite da área desmatada em Altamira, Pará, entre fevereiro e maio de 2023, destacando a rápida expansão do desmatamento, que totalizou 2.683,41 hectares.	22
Figura 3 – VANT Asa-fixa Modelo eBee X da marca AgEagle (à esquerda) e VANT Asa-rotativa Modelo Air 2S da marca DJI (à direita).....	24
Figura 4 – Relação entre a altura de voo (H'), a distância focal (f) e o terreno na captura de imagens aéreas.....	26
Figura 5 – Planejamento de voo para captura de imagens aéreas automatizadas. .	27
Figura 6 – Esquema de um processo de aprendizagem não supervisionada.	30
Figura 7 – Esquema de um processo de aprendizagem supervisionada	32
Figura 8 – Representação de uma Rede Neural.	34
Figura 9 – Estrutura de uma RNP.....	36
Figura 10 – Esquema ilustrativo do processo de detecção de copas de árvores utilizando DL.....	37
Figura 11 – Mapa de localização das áreas da NEON incluídos no conjunto de dados de copas e exemplos de previsões de árvores mostradas com imagens RGB para seis locais.	38
Figura 12 – Fluxo de trabalho do modelo pré-construído DeepForest.....	39
Figura 13 – Diagrama da Metodologia.	40
Figura 14 – Mapa da área de estudo localizada no estado do Pará, Brasil, incluindo a APA Alter do Chão e a FLONA Tapajós.	41
Figura 15 – Diagrama da Coleta de dados e Pré-processamento.....	42
Figura 16 – Área de vegetação de Savana menos densa (A), Savana mais densa (B) e Floresta Ombrófila densa (C).	43
Figura 17 – Anotações manuais de copas de árvores realizadas nas três áreas de estudo. (A) Alter Menos Densa, com 2.763 anotações; (B) Alter Mais Densa, com 2.384 anotações; (C) FLONA TAPAJÓS, com 1.930 anotações.	44
Figura 18 – Exemplo de uma anotação de caixa de uma copa de árvore.	46

Figura 19 – Exemplo de patches de 400x400 pixels na resolução de 4cm/pixel com o IoU acima de 0,5 no item A, e abaixo de 0,5 no item B.....	47
Figura 20 – Exemplo de patches de 400x400 pixels na resolução de 4cm/pixel (A), resolução de 7cm/pixel (B) e de 10cm/pixel (C).....	48
Figura 21 - Box Plot do resultado de 10 execuções para o Conjunto de dados de Savana menos densa de Alter do Chão com 10 cm/pixel em relação ao número de épocas.....	52
Figura 22 - Box Plot do resultado de F1 Score de 10 execuções em 3 diferentes resoluções utilizando 30 épocas para o Conjunto de dados de Alter Menos Densa, Mais densa e FLONA TAPAJÓS.....	56

LISTA DE TABELAS

Tabela 1 – Resumo da Regulamentação da ANAC	25
Tabela 2 – Configurações de hardware utilizadas com o modelo DeepForest.....	45
Tabela 3 – Valores de média, mediana, máximo, mínimo e desvio padrão de 10 execuções para o Conjunto de dados de Savana menos densa de Alter do Chão com 10 cm/pixel em relação ao número de épocas.	51
Tabela 4 – Teste post hoc de Nemenyi para Conjunto de dados de Savana menos densa de Alter do Chão de 10 cm/pixel em relação ao número de épocas referente ao F1 Score.....	53
Tabela 5 – Valores de média, mediana, máximo, mínimo e desvio padrão para Precision, Recall e F1 Score de 10 execuções para os 3 conjuntos de Dados em 3 diferentes resoluções usando 30 épocas.	54
Tabela 6 – Teste post hoc de Nemenyi para os conjuntos de dados de Alter Menos Densa, Mais densa e FLONA TAPAJÓS em 3 diferentes resoluções referente ao F1 Score 30 épocas.	57

LISTA DE ABREVIATURAS

APA	Área de Proteção Ambiental
BVLOS	Beyond Visual Line-Of-Sight (Além da linha de visada visual)
CNN	Redes Neurais Convolucionais
DL	Deep Learning (Aprendizagem Profunda)
FLONA	Floresta Nacional
GSD	Ground Sample Distance (Distância da amostra do solo)
GPU	Graphics Processing Unit (Unidade de Processamento Gráfico)
IA	Inteligência Artificial
ML	Machine Learning (Aprendizagem de Máquina)
LiDAR	Light Detection and Ranging
NEON	National Ecological Observation Network
RNA	Rede Neural Artificial
RNP	Rede Neural Profunda
RPA	Aeronave Remotamente Pilotada
RGB	Red, Green e Blue (Vermelho, Verde e Azul)
SNUC	Sistema Nacional de Unidades de Conservação
SR	Sensoriamento Remoto
UAV	Unmanned Aerial Vehicle (Veículo aéreo não tripulado)
VANT	Veículo aéreo não tripulado
VLOS	Visual Line-Of-Sight (Linha de visada visual)

SUMÁRIO

1. INTRODUÇÃO	15
2. OBJETIVOS	19
2.1 Objetivo Geral	19
2.2 Objetivos Específicos	19
3. REFERENCIAL TEÓRICO	19
3.1 Amazônia: Biodiversidade e Florestas	19
3.2 Sensoriamento Remoto: VANTs	23
3.2.1 VANTs no Monitoramento Florestal	23
3.2.2 Tipos de VANTS	24
3.2.3 Normas e Requisitos para Operação de Voos com VANTs	24
3.2.4 Operações com VANTs e resolução espacial	26
3.2.5 Planejamento de voo	27
3.3 Inteligência Artificial	28
3.3.1 Machine Learning	29
3.3.2 Redes Neurais	33
3.3.3 Deep Learning	35
3.3.4 DeepForest	38
4. MATERIAL E MÉTODOS	40
4.1 Área de Estudo	41
4.2 Coleta e Pré-processamento dos dados	42
4.3 Treino e Teste	43
4.3.1 Anotações Manuais	44
4.3.2 Hardware Utilizado	45
4.3.3 Algoritmo supervisionado	46
4.3.4 Parâmetros utilizados	47
4.4 Avaliação dos modelos treinados	48
4.5 Análise Estatística	49

5. RESULTADOS	50
6. DISCUSSÃO	58
6. CONCLUSÕES	59
REFERÊNCIAS BIBLIOGRÁFICAS	61
APÊNDICES	71
ANEXOS	87

1. INTRODUÇÃO

A Amazônia, é reconhecida por sua incomparável biodiversidade e papel crucial nos processos ecológicos globais, conservação de espécies e manutenção dos ciclos do carbono e hidrológico (FEARNSIDE, 2021). No entanto, as crescentes pressões humanas, como o desmatamento e a degradação florestal, ameaçam esse ecossistema único, causando perda de biodiversidade (FEARNSIDE, 2005).

O sensoriamento remoto (SR) tem se mostrado uma ferramenta essencial nesse contexto, fornecendo dados críticos sobre a cobertura vegetal e o uso da terra. Programas como o PRODES, que monitora o desmatamento na Amazônia desde 1988, e o MapBiomas, que realiza o mapeamento anual do uso do solo, são exemplos que mostram a relevância dessas tecnologias no acompanhamento de mudanças ambientais em larga escala (MAURANO et al., 2019; MAPBIOMAS, 2019).

Além do monitoramento do desmatamento e da cobertura vegetal em escalas continentais, essas tecnologias também vêm sendo aplicadas na análise da estrutura das florestas, incluindo sua distribuição e composição. Pesquisadores têm desenvolvido métodos para caracterizar atributos como altura das árvores, diâmetro e área da copa, permitindo um entendimento mais preciso da dinâmica florestal (ALONZO et al., 2016, HU et al., 2018; PARIS et al., 2017; WEINSTEIN et al., 2019). Essas informações são essenciais para estimar densidade, biomassa, mapear variações na vegetação e monitorar mudanças ao longo do tempo, contribuindo para a conservação e o manejo sustentável dos ecossistemas (PANIGRAHY et al., 2010; ROY et al., 2012; SANKEY et al., 2017; VELASCO et al., 2016).

No entanto, a análise de áreas maiores, especialmente para identificar copas de árvores individuais, exige imagens de alta resolução e técnicas que superem as limitações dos métodos tradicionais, como parcelas permanentes, inventário por censo ou amostragem aleatória, que são demorados e difíceis de aplicar em campo. Frequentemente, a equipe de inventário negligencia a busca por indivíduos de interesse devido às dificuldades, como a transposição de cursos hídricos e o excesso de cipós e bambus, além das condições severas de trabalho, como o calor e a umidade (BENNETT et al., 2022; FIGUEIREDO et al., 2018).

Além dos métodos tradicionais de campo, existem métodos como a vetorização manual e a segmentação/classificação para identificar árvores dominantes em

imagens de alta resolução. A vetorização manual, é demorada e sujeita a erros humanos. Já a segmentação, especialmente com o algoritmo Geobia, tem se destacado como uma alternativa mais eficiente e precisa, permitindo a análise de imagens com resolução superior a 5 m (FIGUEIREDO et al., 2018).

Com os avanços em SR, especialmente a crescente disponibilidade de imagens de alta resolução e o uso de VANTs, surgiram novas possibilidades para o monitoramento florestal. A utilização de VANTs tem se mostrado especialmente promissora, pois sua alta resolução, leveza e baixo custo a tornam uma ferramenta ideal para o reconhecimento detalhado de características florestais, como a detecção de copas de árvores, estimativas de biomassa e volume, proteção da vida animal, além do monitoramento de saúde das plantas, ampliando as capacidades de análise e gestão ambiental (ALEXANDER et al., 2018; BHARDWAJ et al., 2016; DASH et al., 2017; MAIMAITIJIANG et al., 2019; LIU et al., 2018; REY et al., 2017).

Para otimizar ainda mais esses processos, as técnicas de Inteligência Artificial (IA), e em particular de Machine Learning (ML), têm se mostrado essenciais para o processamento eficiente de grandes volumes de dados e na automação de tarefas anteriormente feitas de forma manual (CHOLLET, 2018). O uso de algoritmos de Deep Learning (DL), em particular, tem se destacado na análise de imagens de SR, melhorando a precisão e a eficiência dos processos de detecção (ZHU et al., 2017).

Um dos sistemas mais proeminentes nessa área é o DeepForest, inicialmente treinado com dados florestais de diferentes regiões dos Estados Unidos, que oferece uma abordagem automatizada para a detecção de copas de árvores em imagens de alta resolução (WEINSTEIN et al., 2020). Aubry-Kientz et al. (2021) utilizaram VANTs equipados com câmeras Red, Green e Blue (RGB) e sensores multiespectrais para detectar copas de árvores em florestas tropicais aplicando no DeepForest, mostrando que os VANTs permitem monitorar grandes áreas remotas com maior eficiência e precisão.

Um estudo conduzido por Marin et al. (2023) aplicou o DeepForest para detecção e mapeamento de copas de oliveiras em diferentes pomares, adaptando o modelo original para uma nova base de dados de imagens de oliveiras, que apresentava variações sazonais e condições de iluminação. Este estudo mostrou que o DeepForest, ao ser ajustado com dados específicos de cada região, pode ser implementado para monitorar plantações agrícolas de maneira eficaz e detalhada. A

precisão do modelo foi particularmente significativa na detecção de copas individuais, mesmo em condições de superposição de copas e variações de idade e tamanho das árvores, evidenciando sua adaptabilidade em diferentes ecossistemas agrícolas.

No contexto de florestas urbanas, Dakov e Petrova-Antonova (2024) aplicaram o DeepForest na detecção automatizada de árvores na cidade de Sofia, Bulgária, com o objetivo de criar um inventário de vegetação urbana que apoiasse o planejamento de áreas verdes. Devido aos desafios específicos das áreas urbanas, como a presença de sombra de edifícios e a irregularidade na distribuição das árvores, o estudo desenvolveu uma abordagem híbrida que considera tanto árvores individuais quanto aglomerados de copas sobrepostas. O desempenho do modelo, em termos de precisão e abrangência, foi promissor, mostrando que o DeepForest pode ser reaproveitado para mapeamento urbano com ajustes no treinamento e parâmetros do modelo.

Ainda nesse contexto, Saheer e Shahawy (2021) utilizaram o DeepForest para detecção de árvores em imagens aéreas de Cambridge, visando monitorar a cobertura vegetal urbana e sua relação com a qualidade do ar. O modelo mostrou-se eficaz em mapear a vegetação urbana, superando desafios como sombra de edificações e variação de densidade, e pode ser adaptado para outras áreas urbanas sem grandes ajustes.

A Amazônia, devido à sua vastidão e complexidade, apresenta desafios específicos para a detecção e segmentação de árvores, em razão da alta densidade de copas, a presença de várias camadas de vegetação e as variações topográficas. A utilização de modelos de IA combinados com SR, em particular DL, para a análise de dados de SR podendo ser vantajoso em biomas como a Amazônia, onde a extensão e a complexidade exigem soluções automatizadas e escaláveis.

Dessa forma, o presente trabalho busca uma abordagem que integre o uso de VANTs e DL, especificamente o DeepForest, para monitoramento de copas de árvores na floresta amazônica. A inovação deste estudo está na utilização de tecnologias de SR e DL desenvolvidas para florestas temperadas, de forma a torná-las eficazes no contexto de florestas tropicais densas, enfrentando desafios como sobreposição de copas, alta biodiversidade e variabilidade ambiental. Utilizando VANTs equipados com sensores de alta resolução e um sistema de DL, buscamos melhorar a precisão e escalabilidade do mapeamento e monitoramento florestal de áreas da Amazônia,

sendo selecionada a Área de Proteção Ambiental de Alter do Chão e da Floresta Nacional do Tapajós.

A APA de Alter do Chão e a FLONA do Tapajós, são importantes unidades de conservação, que apresentam uma rica diversidade de vegetação e complexidade estrutural, com diferentes tipos de cobertura vegetal e densidade de copas. Além disso, essas áreas são de difícil acesso, o que torna o uso de VANTs uma solução eficiente para obter dados sobre a dinâmica das copas de árvores, essenciais para a conservação e manejo sustentável da região.

Portanto, o trabalho busca adaptar e implementar uma metodologia de monitoramento florestal, que atenda às demandas específicas da Amazônia. Na prática, foi realizado uma série de testes e ajustes no DeepForest, combinando com a coleta de dados via VANTs, para avaliar sua aplicabilidade em diferentes condições de densidade de vegetação e composição florestal.

A dissertação está organizada em 7 seções da seguinte forma: a Introdução apresenta o contexto e a relevância da pesquisa, explorando a importância da Amazônia, os desafios do desmatamento e o papel do sensoriamento remoto e da IA no monitoramento florestal. Os Objetivos detalham a finalidade de adaptar o modelo DeepForest à detecção de copas de árvores na Amazônia, considerando variáveis como resoluções de imagem e tipos de vegetação. O Referencial Teórico aborda conceitos sobre biodiversidade amazônica, o uso de VANTs, ML, DL e o modelo DeepForest. Na seção de Materiais e Métodos, são descritas as áreas de estudo, os procedimentos de coleta e pré-processamento de dados, as configurações do modelo e as análises estatísticas aplicadas. A seção de Resultados apresenta os dados obtidos nas análises, destacando o desempenho do modelo em diferentes cenários. A seção de Discussão é analisada esses resultados com base na literatura, relacionando-os às variáveis analisadas e às implicações para o monitoramento ambiental. Por fim, a seção de Conclusões sintetiza os achados e ressalta as contribuições da pesquisa para o avanço de metodologias de SR e DL no contexto amazônico.

2. OBJETIVOS

2.1 Objetivo Geral

Avaliar a aplicabilidade do modelo DeepForest em florestas ombrófilas densas e savanas amazônicas, com base em imagens RGB de alta resolução capturadas por VANTs.

2.2 Objetivos Específicos

- Examinar o efeito do número de épocas de treinamento sobre o desempenho do modelo DeepForest.
- Investigar como variações na resolução das imagens influenciam a eficácia do modelo DeepForest na detecção e segmentação de copas de árvores em áreas com diferentes densidades de vegetação.
- Analisar os resultados obtidos por meio dos testes estatísticos e determinar a quantidade de épocas e resolução que melhor se ajusta as imagens utilizadas.

3. REFERENCIAL TEÓRICO

3.1 Amazônia: Biodiversidade e Florestas

A Amazônia, com cerca de 5,5 milhões de km², é a maior floresta tropical do mundo, abrangendo nove países: Brasil, Equador, Venezuela, Colômbia, Peru, Bolívia, Suriname, Guiana e Guiana Francesa. O Brasil, no entanto, detém 61% dessa área, abrangendo nove estados: Acre, Amapá, Amazonas, Mato Grosso, Maranhão, Pará, Rondônia, Roraima e Tocantins (EMBRAPA, 2020; SILVA-SOUZA; SOUZA, 2020).

Reconhecida mundialmente pela sua incomparável biodiversidade, ela abriga cerca de 25% de toda a biodiversidade do planeta. Sua flora, com mais de 16.000 espécies conhecidas, tem mais da metade composta por espécies raras, o que a torna uma das regiões mais biodiversas do mundo (TER STEEGE et al., 2013). A diversidade de fauna é igualmente impressionante, abrangendo milhares de espécies

de mamíferos, aves, répteis e insetos. A riqueza biológica é crucial não apenas para a ecologia local, mas também para a economia global, já que muitas das espécies têm importância medicinal, alimentícia e comercial (DE SÁ et al., 2019; FEARNSIDE, 2021). Essa vasta região abriga uma enorme variedade de habitats, incluindo florestas tropicais, áreas de várzea e savanas, cada uma com características ecológicas únicas que favorecem a existência de nichos específicos e sustentam uma alta diversidade de espécies endêmicas (GUAYASAMIN et al., 2024; HOORN et al., 2023; RULL, 2020).


As florestas tropicais da Amazônia possuem uma estrutura densa e rica em espécies de árvores, animais e microorganismos essenciais para a ciclagem de nutrientes e o armazenamento de carbono (ANTONELLI et al., 2018). Já as florestas de várzea, sujeitas a inundações, ampliando a diversidade amazônica, pois espécies locais evoluíram para suportar ciclos de inundação e retração, contribuindo ainda mais para a complexidade e a diversidade amazônica (HESS et al., 2015; WITTMANN et al., 2013).

Em contraste, as áreas de savana amazônica, formadas em períodos de seca e favorecidas por mudanças do clima ao longo do tempo, abrigam espécies adaptadas a ambientes mais abertos e solos variados (SATO et al., 2021). Essas savanas adicionam uma camada distinta de biodiversidade à Amazônia, permitindo a coexistência de espécies com diferentes adaptações ecológicas, o que contribui ainda mais para a complexidade e riqueza do ecossistema amazônico (ARRUDA et al., 2018). A interação entre florestas tropicais, várzeas e savanas, torna essa região única, onde o equilíbrio entre esses habitats sustenta sua biodiversidade (GUAYASAMIN et al., 2024; HOORN et al., 2023; RULL, 2020).

Aproximadamente 40% das florestas tropicais remanescentes no mundo estão localizadas na Amazônia, e grande parte dessas florestas permanece relativamente intacta (HUBBELL et al., 2008). No entanto, essa área tem sofrido com pressões antropogênicas crescentes, impulsionadas pela demanda por recursos naturais, como madeira, produtos agrícolas e minerais (KARSENTY et al., 2017). Desde 1960, a Amazônia perdeu cerca de 20% de sua cobertura florestal, principalmente devido a desmatamentos e queimadas (ARRUDA et al., 2019). No ano de 2023, o MAPBIOMAS registrou 461.449,3 Hectares de desmatamento (Figura 1). A contínua degradação da floresta traz consigo uma série de consequências ambientais, incluindo a alteração

dos ciclos hidrológicos, erosão do solo, perda de biodiversidade, e redução dos serviços ecossistêmicos (LEITE-FILHO et al., 2019; MIYAMOTO, 2020).

Figura 1 – Mapa das unidades de conservação (em verde) e áreas de desmatamento (em vermelho) no bioma Amazônia, com dados do ano de 2023 extraídos do MapBiomas.



Fonte: MAPBIOMAS (2024)

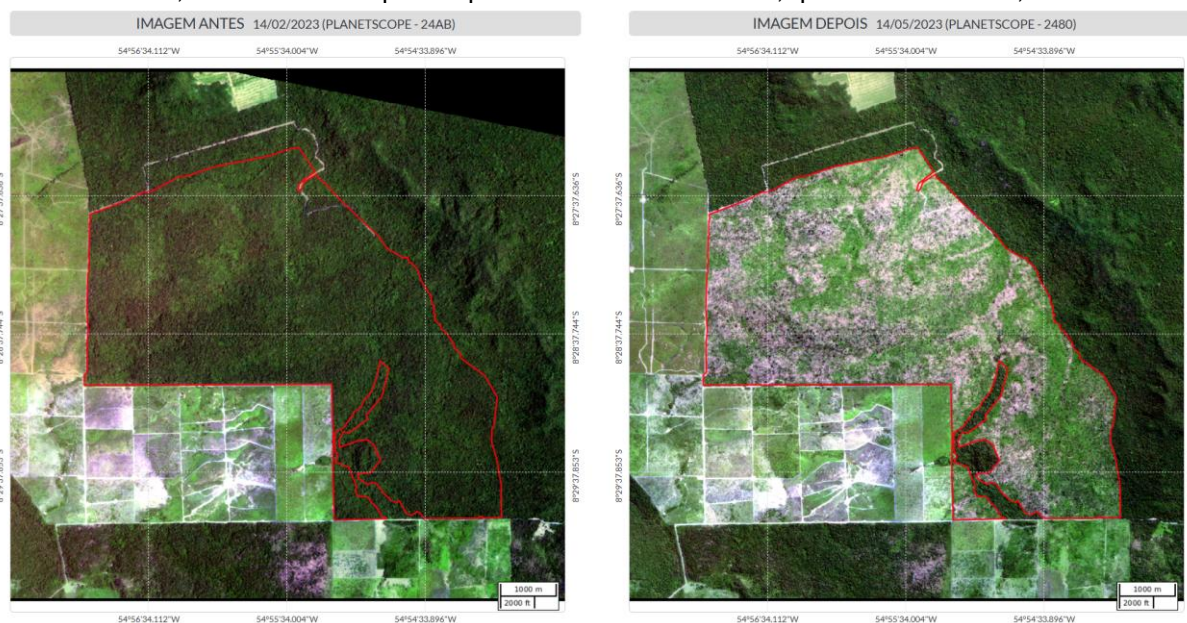
Além dos impactos diretos sobre a biodiversidade e os ciclos naturais, a degradação florestal também afeta os estoques de carbono da Amazônia. Como uma das maiores reservas de carbono do planeta, a perda de sua cobertura vegetal resulta na liberação de grandes quantidades de CO₂ para a atmosfera, exacerbando o efeito estufa e contribuindo para o aquecimento global (BARROS; FEARNSTIDE, 2019). Previsões indicam que até 2050, a degradação da Amazônia poderá atingir 40%, o que poderia resultar em um colapso ainda maior de sua biodiversidade (TER STEEGE et al., 2015).

Devido a esses fatores, a Amazônia tornou-se foco de discussões internacionais, principalmente no que diz respeito à sua conservação e à implementação de políticas para reduzir sua degradação (DOS SANTOS et al., 2021). Para proteger e garantir o uso sustentável da região, o Brasil criou o Sistema Nacional de Unidades de Conservação (SNUC), através da Lei nº 9.985 de 2000. As unidades de conservação, embora existissem antes da lei, passaram a obedecer a critérios mais rígidos de planejamento e gestão, visando assegurar a preservação dos ecossistemas naturais e promover a sustentabilidade (MERCADANTE, 2007).

No entanto, a vasta extensão geográfica da Amazônia dificulta a fiscalização em campo. Mesmo unidades de conservação específicas, como a Floresta Nacional do Tapajós, que ocupa cerca de 530.000 hectares, tornam-se um desafio para o monitoramento contínuo e efetivo (SANTOS et al., 2018). Nesse sentido, o monitoramento por sensoriamento remoto e a análise de dados espaciais emergem como ferramentas indispensáveis para a gestão dessas áreas protegidas.

Essas tecnologias permitem não apenas o rastreamento de impactos ambientais, mas também contribuem para a formulação de estratégias de mitigação que garantam a conservação dos recursos naturais da Amazônia (BRAGION et al., 2023). Para exemplificar a aplicação do SR no monitoramento e detecção de desmatamentos, em 2023, o maior desmatamento registrado no bioma Amazônia ocorreu em Altamira, Pará, abrangendo uma área de 2.683,41 hectares. Imagens de monitoramento destacam a rápida transformação da floresta no intervalo entre fevereiro e maio daquele ano (Figura 2).

Figura 2 – Comparação de imagens de satélite da área desmatada em Altamira, Pará, entre fevereiro e maio de 2023, destacando a rápida expansão do desmatamento, que totalizou 2.683,41 hectares.



Fonte: MAPBIOMAS (2024)

Apesar desses impactos, as dimensões completas da diversidade amazônica ainda permanecem amplamente subestimadas, mesmo após décadas de estudo intensivo. Nesse contexto, o uso de VANTs e imagens de satélite tem se mostrado essencial para monitorar a floresta e detectar alterações na cobertura vegetal,

incluindo atividades ilegais, como o desmatamento e queimadas (NEPSTAD et al., 2014). Além disso, a combinação de sensores multiespectrais com algoritmos de aprendizagem de máquina otimiza a análise de grandes volumes de dados, permitindo uma gestão mais precisa e eficiente das florestas tropicais (SIVANANDAM; LUCIEER, 2022; WEINSTEIN et al., 2020).

3.2 Sensoriamento Remoto: VANTs

O SR é essencial para a coleta de dados em florestas, permitindo o monitoramento de ecossistemas sem contato direto com os elementos observados e utilizando ondas eletromagnéticas para capturar informações sobre vegetação e solo (JENSEN; EPIPHANIO, 2009). Com os avanços tecnológicos, os VANTs têm se tornado ferramentas flexíveis e eficazes para monitoramento em áreas de difícil acesso e alta densidade vegetal, como a Amazônia (MATESE et al., 2015).

3.2.1 VANTs no Monitoramento Florestal

VANTs equipados com sensores LiDAR (Light Detection and Ranging) são amplamente utilizados para capturar a estrutura tridimensional da vegetação, auxiliando no mapeamento das copas de árvores, e permitindo identificar características como altura e densidade do dossel florestal (WEINSTEIN et al., 2020). O uso de LiDAR é particularmente eficaz em regiões onde a visualização direta é limitada, contribuindo para uma compreensão detalhada da estrutura e composição da floresta (WEINSTEIN et al., 2021a).

Além do LiDAR, o uso de câmeras RGB em VANTs possibilita o monitoramento da vegetação em alta resolução, capturando imagens que oferecem informações detalhadas sobre as copas e o estado geral das árvores. A simplicidade e o menor custo das câmeras RGB tornam esses VANTs acessíveis para monitoramento contínuo, sendo amplamente usados para mapear a cobertura e realizar a contagem de árvores individuais em áreas extensas (AUBRY-KIENTZ et al., 2021). As imagens RGB fornecem dados importantes para a detecção de mudanças na cobertura vegetal e ajudam a identificar áreas afetadas por desmatamento ou degradação florestal (JEMAA et al., 2023; KAPIL et al., 2024).

3.2.2 Tipos de VANTS

Os VANTS são divididos em dois tipos principais: asa-fixa e asa-rotativa (Figura 3). VANTS de asa-fixa são mais adequados para missões que exigem cobertura de grandes áreas em um único voo, porém demandam espaços amplos e desobstruídos para decolagem e pouso, o que pode limitar sua aplicação em ambientes com espaço restrito.

Figura 3 – VANT Asa-fixa Modelo eBee X da marca AgEagle (à esquerda) e VANT Asa-rotativa Modelo Air 2S da marca DJI (à direita).



Fonte: Adaptado de (AGEAGLE; DJI)

Já os VANTS de asa-rotativa, apesar de cobrirem áreas menores por voo, possuem maior flexibilidade operacional, com a capacidade de decolar e pousar em espaços reduzidos e irregulares, o que os torna ideais para ambientes desafiadores.

Essa versatilidade dos VANTS de asa-rotativa permite seu uso em uma ampla gama de cenários, especialmente onde as condições do terreno tornam inviável a utilização de VANTS de asa-fixa. Assim, cada tipo apresenta vantagens específicas, devendo a escolha ser feita com base nas características da área de interesse e nos objetivos da missão.

3.2.3 Normas e Requisitos para Operação de Voos com VANTS

A regulamentação sobre o uso de aeronaves não tripuladas no Brasil é um marco importante na aviação civil, tendo sido introduzida pela ANAC (2017) com o objetivo de garantir operações seguras e organizadas. Essa regulamentação reflete um esforço conjunto para alinhar-se às melhores práticas e normas internacionais, considerando a crescente popularidade do uso de VANTS tanto para fins recreativos quanto comerciais. Complementando essas regras, órgãos como o DECEA, ANATEL

e o Ministério da Defesa também estabelecem diretrizes específicas para garantir a segurança no espaço aéreo e o uso correto da tecnologia.

A ANAC define diferentes categorias para VANTs, incluindo aeromodelos (destinados ao lazer) e aeronaves remotamente pilotadas (RPA), que abrangem aplicações comerciais, corporativas ou experimentais. Para cada categoria, requisitos específicos são aplicados, como o registro obrigatório de aeronaves acima de 250 gramas e a necessidade de avaliação de risco para operações mais complexas. Além disso, a regulamentação destaca a importância de respeitar limites de distância de terceiros e áreas não autorizadas para pouso e decolagem.

A Tabela 1 apresenta um resumo das regulamentações estabelecidas pela ANAC para o uso de RPAs (aeronaves remotamente pilotadas) e aeromodelos, detalhando os requisitos para registro, certificação, habilitação e condições de operação.

Tabela 1 – Resumo da Regulamentação da ANAC

	RPA Classe 1	RPA Classe 2	RPA Classe 3	Aeromodelos
Registro da aeronave?	Sim	Sim	BVLOS: SIM VLOS: SIM	Sim
Aprovação ou autorização do projeto?	Sim	Sim	Apenas BVLOS ou acima de 400 pés.	Não
Limite de idade para operação?	Sim	Sim	Sim	Não
Certificado médico?	Sim	Sim	Não	Não
Licença e habilitação?	Sim	Sim	Apenas para operações acima de 400 pés.	Apenas para operações acima de 400 pés.
Local de Operação	A distância da aeronave não tripulada NÃO poderá ser inferior a 30 metros horizontais de pessoas não envolvidas e não anuentes com a operação.			

Fonte: Adaptado de ANAC (2017)


As aeronaves são divididas em três classes com base no peso máximo de decolagem, cada uma com exigências específicas. Aeromodelos, por exemplo, têm exigências mais simples, enquanto RPAs das Classes 2 e 1 demandam maior rigor, incluindo seguro obrigatório, certificações de aeronavegabilidade e registros detalhados de voo. Essa abordagem busca garantir um equilíbrio entre a segurança

operacional e a viabilidade das aplicações comerciais e científicas dos VANTs, alinhando-se às regulamentações globais e à rápida evolução tecnológica do setor.

3.2.4 Operações com VANTs e resolução espacial

Nas orientações da ANAC (2017), o termo GSD (Distância da amostra do solo) refere-se à resolução espacial das imagens obtidas por sensores embarcados em VANTs. O GSD representa a área real no solo correspondente a um único pixel da imagem capturada, sendo geralmente medido em centímetros ou metros (Figura 4). Por exemplo, um GSD de 10 cm significa que cada pixel da imagem representa 10 cm no terreno.

Figura 4 – Relação entre a altura de voo (H'), a distância focal (f) e o terreno na captura de imagens aéreas.



Fonte: Adaptado de ALBUQUERQUE (2022)

O GSD é influenciado pela altitude de voo, pelas características do sensor e pela lente da câmera. Altitudes mais altas resultam em um GSD maior, ou seja, menor nível de detalhe, enquanto altitudes mais baixas proporcionam maior resolução (GSD menor). De acordo com as orientações da ANAC, em operações de RPAs sem habilitação específica, o voo deve ser realizado em altitudes de até 120 metros (400 pés) acima do nível do solo.

Essa métrica é essencial para o planejamento de missões com VANTs, pois impacta diretamente a precisão das análises e o tamanho da área coberta em um único voo. Nas aplicações práticas, como na geração de mapas ou ortomosaicos, o GSD adequado permite capturar detalhes suficientes para atender aos objetivos do

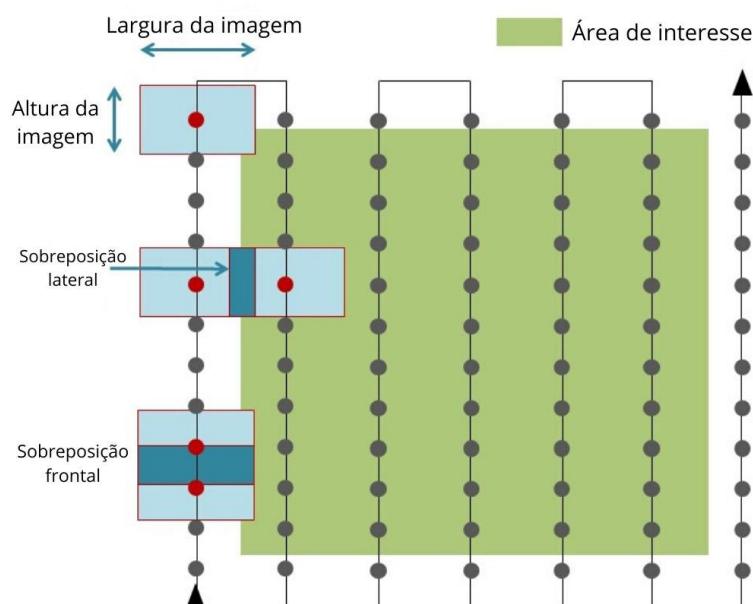
projeto, garantindo qualidade sem comprometer a eficiência operacional, ao mesmo tempo em que respeita os limites operacionais estabelecidos pela ANAC.

3.2.5 Planejamento de voo

O planejamento adequado é crucial no uso de VANTs no monitoramento florestal, garantindo que as missões atendam aos objetivos esperados com alta precisão. Além de assegurar a sobreposição ideal de imagens, o planejamento define rotas de voo eficientes e áreas de interesse prioritárias, otimizando o tempo e os recursos empregados. Esses VANTs possibilitam o mapeamento detalhado de áreas extensas, capturando imagens em alta resolução e proporcionando uma visão precisa da cobertura vegetal e da biodiversidade.

Durante a captura das imagens com os VANTs, a sobreposição de imagens é fundamental, pois garante a criação de mapas precisos e sem falhas. Durante o voo, o VANT captura fotos sequenciais com áreas comuns entre elas; essas áreas sobrepostas permitem que algoritmos identifiquem pontos em comum, unindo as imagens em um ortomosaico (Figura 5). Uma sobreposição inadequada pode resultar em erros, como buracos nos mapas ou falta de precisão nos projetos. A sobreposição de imagens é essencial para garantir a cobertura completa da área de interesse no mapeamento com VANTs.

Figura 5 – Planejamento de voo para captura de imagens aéreas automatizadas.



Fonte: MAPPA (2020)

A sobreposição frontal e lateral é demonstrada, destacando como as imagens capturadas pelo VANT possuem áreas comuns que permitem a união dos dados no processamento. Essa sobreposição é indispensável para a criação de ortomosaicos detalhados e precisos, evitando falhas ou lacunas nos mapas resultantes, especialmente em aplicações que exigem alta precisão, como monitoramento ambiental e análise de terrenos (MAPPA, 2020).

Para assegurar a qualidade do mapeamento, é essencial configurar corretamente a sobreposição de imagens antes do voo. Recomenda-se uma sobreposição frontal de 80% e lateral de 70%, parâmetros que podem ser ajustados em aplicativos de planejamento de missão. Essa configuração adequada facilita o processamento das imagens e a geração de mapas precisos, evitando problemas como a quebra do ortomosaico em blocos ou a falta de acurácia em projetos que utilizam pontos de controle.

Com esse aumento no volume de dados capturados por VANTs, a IA e DL tornaram-se essenciais para processar e interpretar grandes quantidades de informações de maneira automatizada (VONGKUSOLKIT et al., 2023). Essas tecnologias permitem a segmentação de copas e análise de grandes áreas, facilitando a detecção de atividades ilegais, como desmatamento e queimadas (SANTOS et al., 2018; DE ANDRADE et al., 2022). A combinação de VANTs com IA e DL otimiza o monitoramento e torna o uso de VANTs uma ferramenta para a conservação florestal, mesmo em regiões desafiadoras e densamente vegetadas (TOLAN et al., 2024).

3.3 Inteligência Artificial

A IA é uma área da ciência da computação que se dedica ao desenvolvimento de sistemas e algoritmos capazes de realizar tarefas que normalmente exigem inteligência humana, como percepção, aprendizado e tomada de decisão (KORTELING et al., 2021). Com o avanço das tecnologias e a capacidade de processar grandes volumes de dados, a IA tem se tornado cada vez mais presente em diversas áreas, transformando setores como saúde, finanças, transporte e, mais recentemente, o monitoramento ambiental. Desde os primeiros modelos teóricos de IA, nos anos 1940, até os sistemas modernos de aprendizado profundo, a evolução dessa tecnologia tem permitido a automação e a otimização de processos, resultando

em uma maior eficiência e precisão nas tarefas executadas (CHOLLET, 2018; HAYKIN, 1998).

Nesse contexto, a IA tem se destacado como uma ferramenta essencial no monitoramento ambiental, particularmente em ecossistemas florestais onde a complexidade e a escala de dados são desafiadoras (CAUSEVIC et al., 2024). Ela permite realizar tarefas como reconhecimento de padrões, análise de imagens e tomada de decisões de forma mais eficiente, contribuindo para a gestão sustentável das áreas florestais. A capacidade da IA de processar grandes volumes de dados com alta precisão tem sido crucial para lidar com os desafios ambientais contemporâneos, como a preservação da biodiversidade e o combate ao desmatamento (KORTELING et al., 2021).

No monitoramento florestal, a IA é usada para mapear áreas de vegetação, detectar sinais de degradação e auxiliar no planejamento e conservação de recursos naturais. Essa capacidade de IA em processar imagens aéreas e dados de sensores permite identificar alterações na cobertura vegetal da floresta de forma eficaz (WEINSTEIN et al., 2020). Aplicações específicas incluem a detecção precoce de desmatamento e a análise de parâmetros ambientais para otimização dos recursos florestais (ALBUQUERQUE, 2022).

Com avanço em *hardware*, como *Graphics Processing Units* (GPUs), e a introdução de algoritmos de IA mais sofisticados, a precisão na identificação de mudanças ambientais tem aumentado significativamente. Essas tecnologias tornam a IA uma aliada fundamental na conservação de florestas tropicais, proporcionando uma análise rápida e precisa que apoia a tomada de decisões para a preservação e recuperação de ecossistemas (ZHANG, 2019; SHI et al., 2007).

3.3.1 Machine Learning

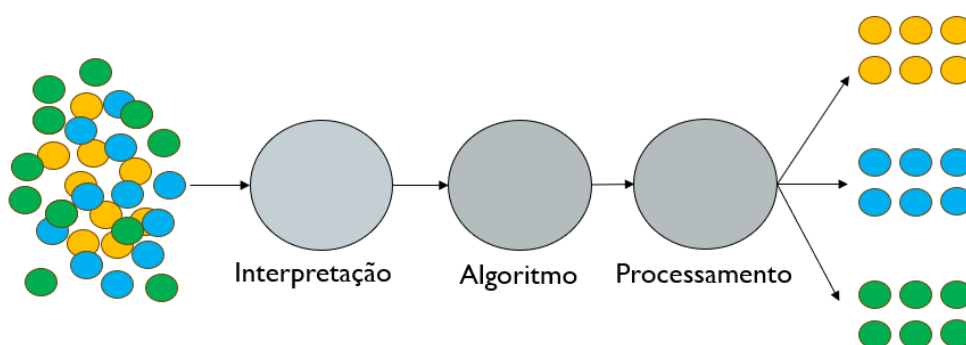
Machine Learning (ML) é uma subárea da IA que envolve a aplicação de algoritmos capazes de aprender diretamente a partir dos dados e aprimorar seu desempenho de maneira contínua, sem necessidade de uma programação explícita para cada tarefa (CHOLLET, 2018). Dentro do ML, os problemas são geralmente divididos em dois tipos principais: classificação e regressão. Na classificação, o modelo é treinado para identificar categorias discretas, como distinguir entre

diferentes tipos de vegetação (ex.: florestas naturais versus áreas de reflorestamento) (NAJAFABADI et al., 2015). Já na regressão, o objetivo é prever valores contínuos, como a estimativa de biomassa ou o teor de carbono em uma área florestal (WAGNER et al., 2019). Ambos os métodos se baseiam no conceito de minimização de erro, onde o modelo ajusta seus parâmetros para reduzir a diferença entre as previsões e os valores reais nos dados que foram rotulados.

Após definir se o problema envolve classificação ou regressão, a escolha do método de aprendizagem é essencial para o treinamento do modelo. O ML pode ser dividido em quatro categorias principais, de acordo com os métodos de aprendizagem: aprendizagem não supervisionado, supervisionado, semi-supervisionado e por reforço (BOSE, 2017). Cada um desses métodos tem aplicações específicas e oferece diferentes vantagens no processamento e análise de grandes volumes de dados.

A aprendizagem não supervisionada baseia-se na identificação de padrões e regularidades em dados sem a necessidade de rótulos prévios, permitindo que algoritmos descubram estruturas internas de forma autônoma (BARLOW, 1989). Essa abordagem é fundamentada na exploração da redundância presente nos dados sensoriais, possibilitando a construção de representações internas úteis para a interpretação e organização das informações. Por exemplo, na Figura 6, os dados de entrada, inicialmente desorganizados, são analisados e agrupados em categorias distintas (amarelo, azul e verde) com base em semelhanças detectadas pelo algoritmo.

Figura 6 – Esquema de um processo de aprendizagem não supervisionada.



Fonte: Adaptado de ZHOU et al., (2024)

Esse método é particularmente eficaz em cenários onde os dados são amplos e heterogêneos, como no sensoriamento remoto, onde imagens de satélite e dados

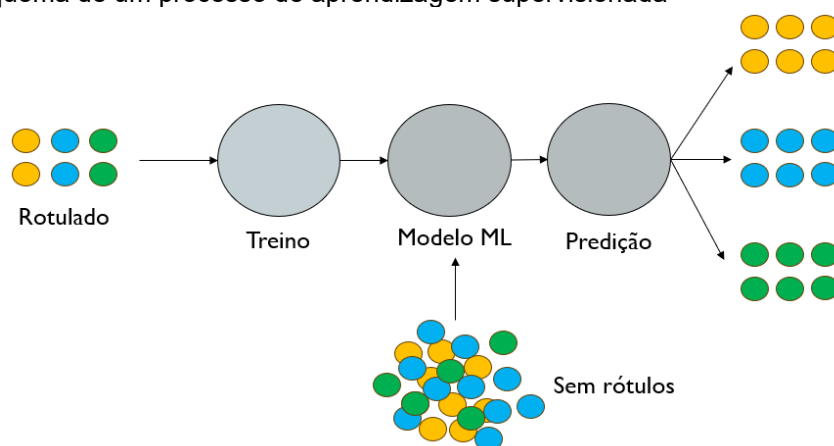
multiespectrais podem ser processados para identificar padrões de vegetação, densidade florestal ou áreas de degradação (HINTON; SEJNOWSKI, 1999). A aprendizagem não supervisionada também é essencial para detectar discrepâncias ou eventos inesperados nos dados, que podem indicar mudanças ambientais relevantes, como desmatamento ou alterações na cobertura vegetal.

Além disso, essa abordagem busca maximizar a independência entre os elementos representados, reduzindo a redundância e organizando os dados de maneira eficiente (BARLOW, 1989). Isso é fundamental para melhorar a compreensão e o armazenamento de informações, permitindo que sistemas computacionais lidem com grandes volumes de dados de forma mais eficaz.

A aprendizagem semi-supervisionada é uma abordagem intermediária entre a aprendizagem supervisionada e não supervisionada, aproveitando um pequeno conjunto de dados rotulados para guiar a classificação de uma grande quantidade de dados não rotulados. Esse método é especialmente útil em cenários onde a rotulagem manual dos dados é custosa, como na identificação de espécies florestais em imagens de satélite ou no mapeamento de áreas de desmatamento. Ao utilizar técnicas como propagação de rótulos e autoaprendizagem, o modelo pode inferir padrões e expandir seu conhecimento para novos dados, aumentando a precisão das previsões sem a necessidade de um grande volume de informações previamente classificadas (CHAPELLE et al., 2006).

Na aprendizagem supervisionada os algoritmos utilizam dados rotulados durante o treinamento, estabelecendo uma relação clara entre as variáveis de entrada (ex.: características do dado) e as variáveis de saída (ex.: categorias ou valores-alvo) (CUNNINGHAM et al. 2008). O objetivo desse tipo de aprendizagem é permitir que o modelo faça previsões precisas para novos dados, baseando-se nos padrões aprendidos.

A Figura 7 ilustra o processo de aprendizagem supervisionada, no qual os dados rotulados à esquerda são utilizados para treinar um modelo de Machine Learning (ML). Durante o treinamento, o modelo é ajustado para aprender as relações entre as entradas e saídas, permitindo que, posteriormente, aplique esse conhecimento a dados não rotulados. Esse processo resulta na classificação desses dados em categorias organizadas (amarelo, azul e verde), com base nos padrões identificados durante o treinamento.

Figura 7 – Esquema de um processo de aprendizagem supervisionada

Fonte: Adaptado de TALABANI (2024)

Para as Redes Neurais, durante o processo de Aprendizagem Supervisionada, o dataset completo é apresentado ao modelo durante cada iteração, com a finalidade de realizar o ajuste dos pesos. A esta iteração dá-se o nome de “época”. A importância de conhecer o número de épocas adequado ao modelo reside no fato de que um número baixo de épocas pode não ser suficiente para o ajuste dos pesos, enquanto um número excessivo pode levar a uma especialização do modelo em relação aos dados de treinamento, o que causaria em ambos os casos um pior desempenho para a utilização em dados futuros a serem apresentados à rede (por exemplo, dados de teste, validação ou produção, não utilizados no treinamento). Para maiores detalhes, v. Goodfellow, Bengio e Courville (2016).

Modelos como o Random Forest e o XGBoost são amplamente utilizados em tarefas de classificação e regressão dentro da aprendizagem supervisionada. O Random Forest utiliza uma coleção de árvores de decisão, cada uma treinada com subconjuntos aleatórios de dados, melhorando a precisão do modelo (HO, 1995). Sua capacidade de paralelização e as estimativas internas, como a importância das variáveis, tornam-no eficaz, especialmente em problemas com grandes volumes de dados e múltiplas variáveis (BREIMAN, 2001). Já o XGBoost é um sistema de aprendizado de máquina escalável e eficiente para tree boosting, amplamente reconhecido por sua aplicação bem-sucedida em diversos desafios de aprendizado de máquina e mineração de dados (CHEN e GUESTRIN, 2016). Ele se destaca pela sua escalabilidade, sendo capaz de processar bilhões de exemplos em configurações distribuídas ou com recursos limitados.

Por fim, a aprendizagem por reforço é uma abordagem dinâmica em que os algoritmos interagem com o ambiente para maximizar uma recompensa ao longo do tempo. Nesse método, o valor das recompensas guia a aprendizagem, permitindo que o modelo aprenda a tomar decisões otimizadas. Essa técnica é especialmente útil em cenários onde o modelo precisa adaptar suas ações com base em novas informações, como no gerenciamento florestal e na otimização de práticas de conservação (LAPEYROLERIE et al., 2022). Uma das principais questões enfrentadas na aprendizagem por reforço é o equilíbrio entre exploração e exploração, em que o agente deve explorar novas ações que possam levar a melhores recompensas futuras, ao mesmo tempo em que maximiza as recompensas obtidas pelas ações conhecidas (COLLINS; MOONS, 2019).

Com o crescente uso de grandes volumes de dados no monitoramento ambiental e na gestão de ecossistemas complexos, como a Amazônia, o ML tem se mostrado uma ferramenta essencial. Ele permite não apenas a análise detalhada de imagens aéreas e de VANTs, mas também a identificação de padrões sutis na vegetação e na saúde das florestas, contribuindo significativamente para a gestão sustentável de recursos naturais (ZHU et al., 2017). Neste estudo, utilizamos o modelo DeepForest, um algoritmo de ML baseado em DL para detecção e classificação de árvores. O modelo aproveita sua capacidade de aprendizagem tanto não supervisionada, identificando padrões a partir de dados sem rótulos prévios, quanto supervisionada, utilizando dados rotulados para realizar previsões mais precisas (WEINSTEIN et al., 2019). Essa abordagem flexível possibilita uma análise detalhada da vegetação florestal em imagens aéreas.

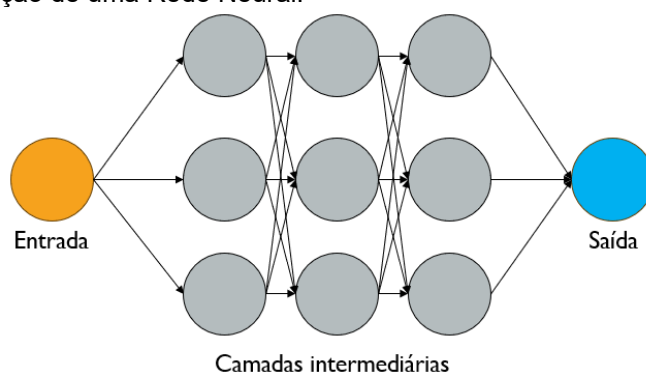
3.3.2 Redes Neurais

Redes Neurais Artificiais (RNAs) são sistemas computacionais inspirados no funcionamento do cérebro humano, compostos por unidades interligadas chamadas neurônios, que processam e transmitem dados por meio de ajustes nos pesos das conexões entre esses neurônios. Essas redes são particularmente eficientes na resolução de problemas complexos, como reconhecimento de padrões em grandes volumes de dados, e têm se destacado em áreas como visão computacional e processamento de imagens (HAYKIN, 1998). Com o avanço da tecnologia, as redes

neurais têm evoluído e hoje representam uma das principais ferramentas na área da IA (LECUN et al., 2015).

Uma característica importante das redes neurais é sua arquitetura, dividida em várias camadas, que inclui a camada de entrada, as camadas ocultas e a camada de saída (Figura 8). As camadas ocultas são responsáveis por transformar os dados de entrada em representações mais complexas e abstratas, tornando essas redes particularmente eficientes em tarefas como a classificação de imagens, onde podem identificar padrões, texturas e formas que não são imediatamente aparentes a olho nu. Entre as diversas arquiteturas de redes neurais, as Redes Neurais Convolucionais (CNNs) se destacam pelo seu uso eficaz na análise de imagens (ZHU et al., 2017).

Figura 8 – Representação de uma Rede Neural.



Fonte: Adaptado de ADEL e LEVENE (2023)

As CNNs são especialmente projetadas para lidar com dados estruturados em grades, como imagens, e são amplamente utilizadas em tarefas de reconhecimento de objetos, detecção de padrões e segmentação de imagens. A operação de convolução permite que as CNNs extraiam características relevantes da imagem, como bordas, texturas e formas, em diversas escalas, reduzindo a necessidade de pré-processamento (LECUN et al., 2015; ZHU et al., 2017). A arquitetura de camadas convolucionais empilhadas permite que a rede aprenda características hierárquicas, onde camadas mais profundas capturam padrões mais complexos e abstratos, essenciais para a compreensão visual de alto nível.

Dentro das arquiteturas de CNNs, a ResNet-50 foi criada para a extração de características em tarefas complexas de classificação e detecção de imagens. Proposta por He et al. (2016), é uma rede neural profunda com 50 camadas projetada para resolver problemas comuns em redes muito profundas, como a degradação de desempenho. Composta por blocos residuais, a ResNet-50 permite que a informação

pule algumas camadas, facilitando a aprendizagem de funções complexas sem que o desempenho decaia à medida que a profundidade aumenta (ZHANG et al., 2023). Essa estrutura permite que a rede capture características visuais em diferentes escalas e níveis de abstração, de bordas e texturas a padrões e formas mais complexas, tornando-a ideal para tarefas de reconhecimento e classificação de imagens (ANWER et al., 2018).

Por meio dessa arquitetura, a ResNet-50 alcança um equilíbrio notável entre profundidade e eficiência, permitindo que redes profundas aprendam com mais facilidade sem perda de precisão. A abordagem residual possibilita o treinamento eficiente em grandes datasets, como o ImageNet, onde a ResNet-50 demonstrou desempenho superior em reconhecimento de imagens em comparação com redes mais rasas e tradicionais (SHAFIQ; GU, 2022). Esta arquitetura tornou-se um modelo amplamente utilizado para aplicações que exigem alta precisão na análise de imagens, como monitoramento florestal, além de ser base para muitas inovações subsequentes no campo da visão computacional (HARINI et al., 2024; WAN et al., 2024).


3.3.3 Deep Learning

O DL é uma subárea do ML que utiliza modelos de redes neurais profundas para resolver problemas complexos, tornando-o uma das abordagens mais poderosas e escaláveis da IA. Embora o ML e o DL compartilhem o mesmo princípio básico de aprendizagem a partir de dados, eles se diferenciam em termos de capacidade e profundidade dos modelos utilizados. Enquanto o ML tradicional frequentemente requer a intervenção humana para selecionar as características mais relevantes dos dados, o DL é capaz de aprender essas características de forma autônoma, mesmo a partir de grandes volumes de dados não rotulados (CHOLLET, 2018). Isso torna o DL uma ferramenta indispensável para lidar com grandes conjuntos de dados e problemas de alta complexidade (SHARMA et al., 2021).

A Figura 9 ilustra uma Rede Neural Profunda (RNP) composta por múltiplas camadas de neurônios interconectados, característica fundamental que amplia a capacidade da rede de modelar padrões complexos e extrair características hierárquicas dos dados de entrada. Além disso, operações como convolução podem

ser integradas, aumentando ainda mais o número de parâmetros da rede e permitindo a detecção de padrões locais e estruturas espaciais. Esse aumento é o que caracteriza o DL, permitindo que a rede capture detalhes sutis e padrões complexos nos dados

Figura 9 – Estrutura de uma RNP.



Fonte: Adaptado de MERENDA et al., (2020)


Uma das principais vantagens do DL sobre outras abordagens de aprendizagem de máquina é sua capacidade de realizar aprendizagem não supervisionada, ou seja, sem a necessidade de rotulação manual dos dados. Redes neurais profundas podem aprender a partir de grandes quantidades de dados não rotulados, extraíndo automaticamente representações úteis para a tarefa de previsão ou classificação. Isso é particularmente importante no contexto de ecossistemas florestais, onde a quantidade de dados de sensoriamento remoto, como imagens de VANTs e LiDAR, é vasta, mas nem sempre rotulada com precisão (AGGARWAL et al., 2022).

As redes neurais profundas também utilizam técnicas avançadas de otimização, como o backpropagation e o gradiente descendente, que permitem o ajuste dos pesos dos neurônios com base nos erros cometidos durante as previsões. Esses ajustes são feitos em várias camadas, permitindo que a rede melhore sua capacidade de generalizar e fazer previsões mais precisas conforme recebe mais

dados para treinamento (MISHRA; DESAI, 2006). Esse processo iterativo é fundamental para o sucesso do DL em problemas de alta complexidade, como a segmentação de imagens e a detecção de objetos em florestas tropicais.

O DL tem mostrado um enorme potencial em aplicações ambientais, especialmente no monitoramento de florestas. Ele tem sido aplicado para detectar e classificar automaticamente copas de árvores em imagens aéreas (Figura 10) de alta resolução, medir a biomassa florestal e identificar áreas de desmatamento (ZHU et al., 2017). Além disso, o DL permite que essas tarefas sejam realizadas com alta precisão e em tempo real, o que é essencial para o monitoramento contínuo e a preservação de ecossistemas como a Amazônia.

Figura 10 – Esquema ilustrativo do processo de detecção de copas de árvores utilizando DL.



Fonte: Autor (2023)

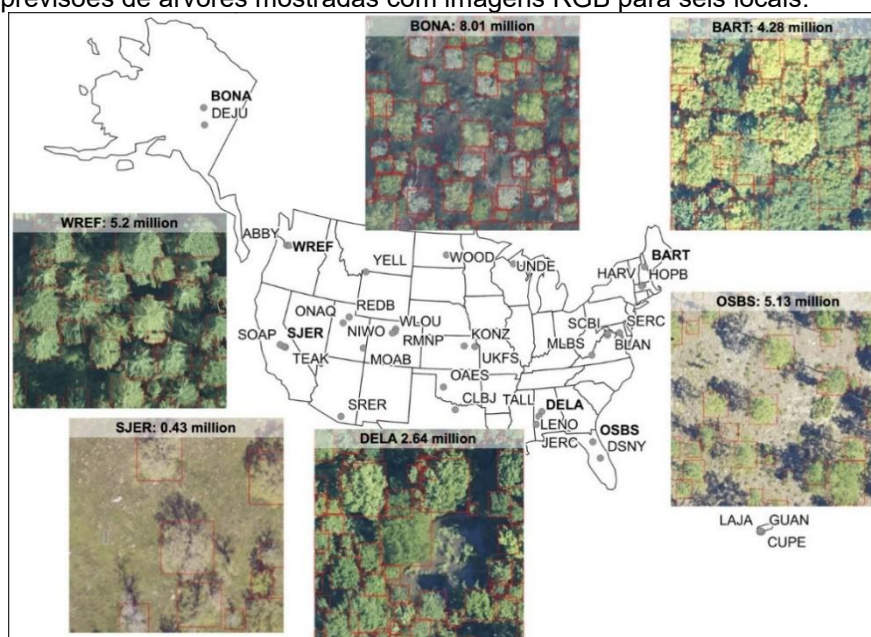
Dessa forma, o DL oferece uma abordagem poderosa e escalável para a análise de dados ambientais. Ao automatizar processos complexos de análise, como a detecção de padrões em grandes volumes de dados não estruturados, o DL desempenha um papel central no desenvolvimento de soluções inovadoras para o monitoramento e conservação das florestas tropicais (LECUN et al., 2015; NAMATÈVS, 2017). A capacidade dessas redes de aprender com dados brutos, sem a necessidade de intervenção humana constante, possibilita a aplicação eficiente de técnicas de IA em grandes áreas de difícil acesso e com alta variabilidade, como a Amazônia. Um exemplo dessa aplicação é o DeepForest, que utiliza DL para detectar e quantificar árvores em imagens aéreas, proporcionando uma ferramenta eficiente e automatizada para o monitoramento florestal.

3.3.4 DeepForest

O *DeepForest* é um pacote Python de código aberto, projetado para a detecção automática de copas de árvores utilizando técnicas de DL. Ele foi desenvolvido com o objetivo de facilitar a previsão e a detecção de copas individuais de árvores a partir de imagens aéreas em alta resolução, geralmente no espectro RGB (WEINSTEIN et al., 2019). O modelo utiliza como base o detector de objetos *RetinaNet*, implementado via *keras-retinanet*, e tem o *ResNet-50* como backbone de classificação, pré-treinado no conjunto de dados *ImageNet*. Esse pré-treinamento inicial é essencial para reduzir o tempo de treinamento e minimizar o overfitting, especialmente quando se trabalha com conjuntos de dados menores (HE et al., 2016; REN et al., 2015).

O *DeepForest* foi inicialmente treinado com dados de *LiDAR* de 22 locais da *National Ecological Observation Network* (NEON), que forneceram milhões de anotações automáticas de copas de árvores de qualidade inferior (Figura 11). Essas anotações foram utilizadas para treinar o modelo de detecção de copas RGB. O uso de dados *LiDAR* foi fundamental para criar uma base inicial para o modelo, fornecendo anotações não supervisionadas que, apesar de limitadas em precisão, oferecem informações valiosas para a aprendizagem das redes neurais (WEINSTEIN et al., 2019; WEINSTEIN et al., 2020).

Figura 11 – Mapa de localização das áreas da NEON incluídos no conjunto de dados de copas e exemplos de previsões de árvores mostradas com imagens RGB para seis locais.

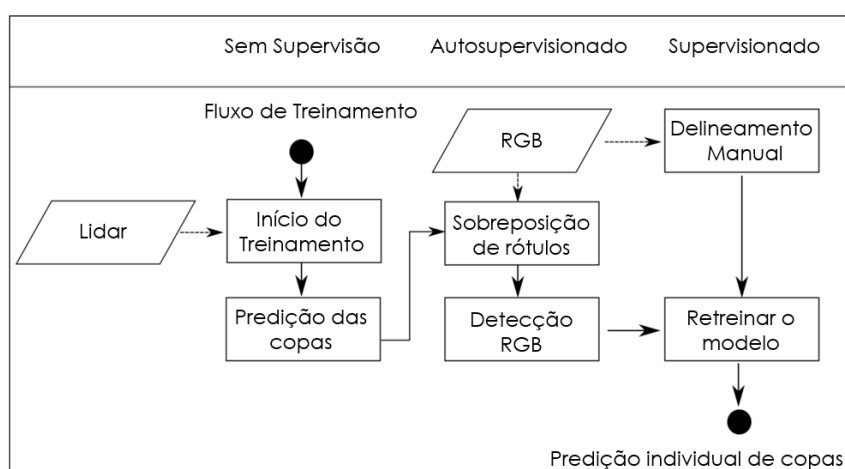


Fonte: WEINSTEIN et al., (2021b)

Após essa fase inicial, o modelo foi refinado e retreinado com imagens RGB de alta resolução e anotações manuais de copas de árvores de seis locais da NEON (LENO, MLBS, NIWO, OSBS, SJER, TEAK). Essas anotações manuais, cerca de 10.000 no total, foram cruciais para aprimorar a precisão do modelo e garantir que ele fosse capaz de realizar detecções mais precisas em diferentes tipos de florestas e condições ambientais (WEINSTEIN et al., 2020).

A Figura 12 ilustra o fluxo de trabalho completo do modelo DeepForest. O processo começa com a coleta de dados LiDAR, que são usados para gerar anotações automáticas das copas. Essa etapa inicial, classificada como Sem Supervisão, fornece uma base inicial de aprendizagem para o modelo. No estágio Autosupervisionado, as anotações de rótulos automáticos gerados pelo LiDAR são sobrepostas com dados de imagens RGB, permitindo que o modelo refine suas previsões. No estágio final, supervisionado, as anotações manuais detalhadas são utilizadas para retreinar o modelo, ajustando suas previsões e aumentando a precisão.

Figura 12 – Fluxo de trabalho do modelo pré-construído DeepForest



Fonte: Adaptado de WEINSTEIN et al., (2019)

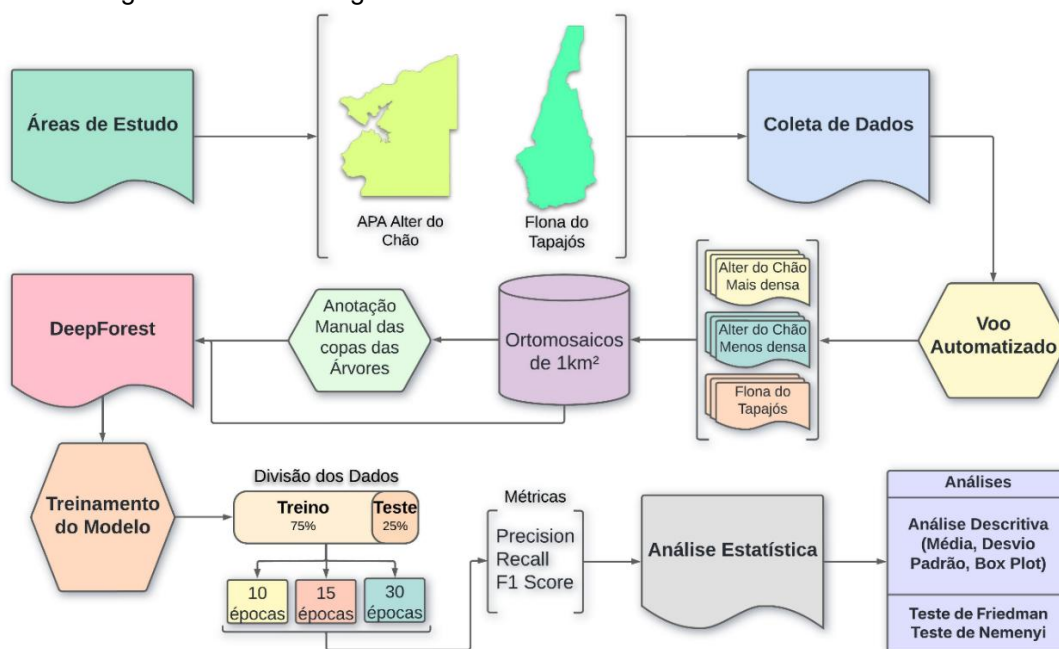
Ao utilizar esse modelo pré-construído, os usuários podem fornecer novas imagens RGB de alta resolução e realizar a detecção automatizada de copas com base no modelo pré-treinado. Além disso, existe a opção de ajustar o desempenho do modelo com base em novos dados locais, inserindo anotações manuais de copas de árvores, o que torna o DeepForest altamente adaptável a diferentes regiões e tipos de floresta.

O DeepForest representa uma importante contribuição para o monitoramento florestal, pois automatiza a detecção de copas de árvores em grandes áreas florestais, economizando tempo e recursos em relação aos métodos tradicionais de delineamento manual. Isso facilita a análise de mudanças na cobertura florestal e contribui para a conservação de ecossistemas em regiões críticas, como a Amazônia.

4. MATERIAL E MÉTODOS

Um diagrama conceitual foi elaborado para ilustrar o processo metodológico do estudo (Figura 13). A pesquisa foi conduzida em duas áreas localizadas no estado do Pará: a Área de Proteção Ambiental (APA) Alter do Chão e a Floresta Nacional (FLONA) do Tapajós. Nessas áreas, foram realizadas coletas de imagens RGB utilizando Veículos Aéreos Não Tripulados (VANTs) com voo automatizado. Os dados capturados foram processados no software Agisoft Metashape, resultando na geração de ortomosaicos com resolução de 1km².

Figura 13 – Diagrama da Metodologia.



Fonte: Autor (2024)

Os ortomosaicos foram utilizados para a anotação manual das copas de árvores, que serviram como base para o treinamento e validação do modelo DeepForest. Os dados foram divididos em 75% para treino e 25% para teste, com

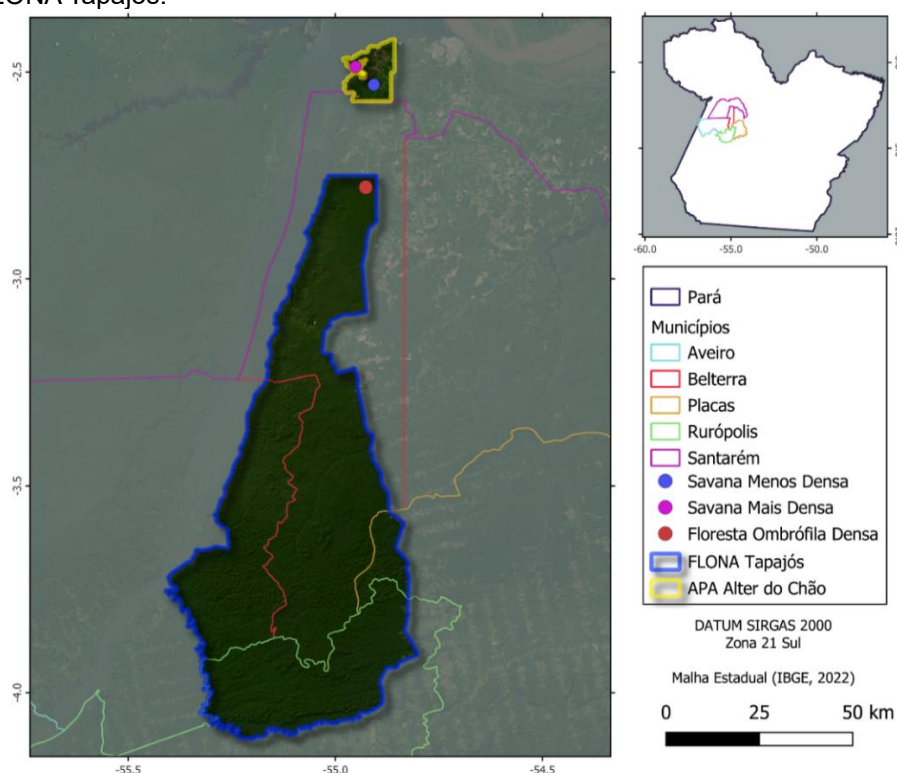
diferentes configurações de épocas de treinamento (10, 15 e 30 épocas), cada uma repetida 10 vezes para garantir a robustez das análises.

Para avaliar o desempenho do modelo na detecção de árvores, foram utilizadas as métricas de *Recall*, *Precision* e *F1 Score*. As análises estatísticas incluíram métodos descritivos, como cálculo de média, desvio padrão e construção de box plots, além do teste de Friedman, utilizado para verificar a significância estatística entre as diferentes configurações de épocas e áreas analisadas (Alter do Chão Mais Densa, Alter do Chão Menos Densa e FLONA Tapajós). O teste post hoc de Nemenyi foi então aplicado para analisar as diferenças entre os grupos.

4.1 Área de Estudo

A primeira área de estudo escolhida foi a APA Alter do Chão (Figura 14), localizada no município de Santarém, no estado do Pará com uma extensão territorial aproximada de 16.180 hectares (VALENTE; TESTON, 2023). Nessa área, foram selecionadas duas áreas com vegetação de savana amazônica, classificadas como de vegetação mais densa e menos densa.

Figura 14 – Mapa da área de estudo localizada no estado do Pará, Brasil, incluindo a APA Alter do Chão e a FLONA Tapajós.



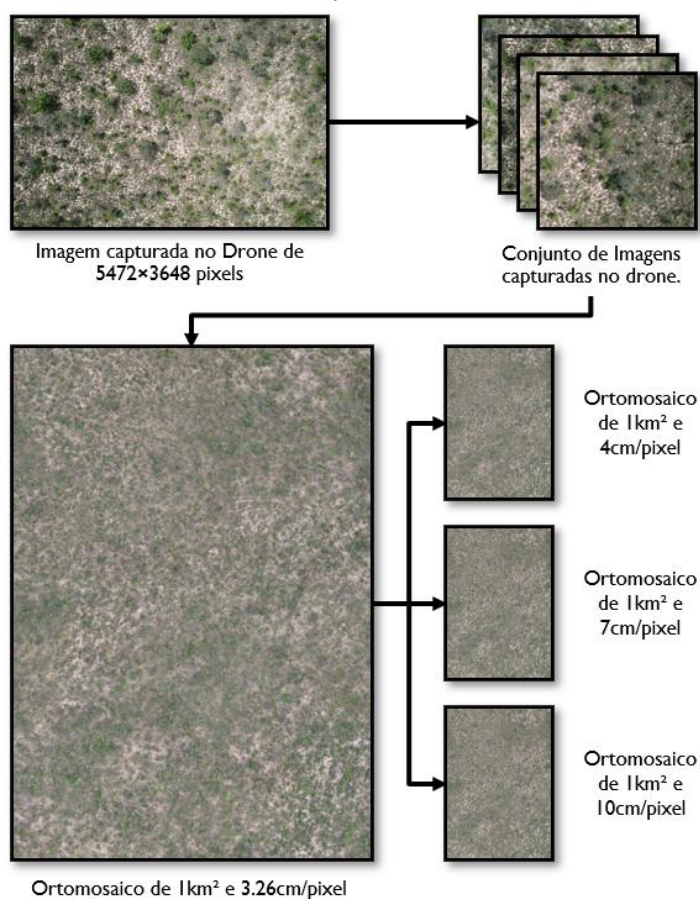
Fonte: Autor (2024)

A segunda área de estudo foi a FLONA Tapajós FLONA, com uma área de 530.000 hectares, no estado do Pará, abrangendo os municípios de Aveiro, Belterra, Placas e Rurópolis (SANTOS et al., 2018). A vegetação predominante é classificada como Floresta Ombrófila Densa (GONÇALVES; SANTOS, 2008; VELOSO et al., 1991). A região estudada apresenta um clima Am, segundo a Classificação de Köppen, com temperatura média anual de 25,5°C e precipitação média anual de 1.820 mm. A maior incidência de chuvas ocorre entre os meses de janeiro e maio (IBAMA, 2004).

4.2 Coleta e Pré-processamento dos dados

Para a coleta dos dados, foi utilizado um VANT modelo Air 2S para capturar imagens RGB com tamanho da imagem de 5472×3648 pixels, com voo automatizado pelo aplicativo Dronelink sobre cada área de 120ha a 115m de altura, com sobreposição frontal de 80% e lateral de 65% (Figura 15).


Figura 15 – Diagrama da Coleta de dados e Pré-processamento.



Fonte: Autor (2024)

As imagens foram processadas no software Agisoft Metashape Professional, resultando após o recorte de bordas em 1 ortomosaico de 1km² no formato Geotiff de GSD de 3,26cm/pixel para cada área, e posteriormente sendo exportado os ortomosaicos em resoluções diferentes, com o GSD de 4cm/pixel, 7cm/pixel e 10cm/pixel. Foram gerados ortomosaicos de 1 km² para cada resolução, em três áreas distintas: duas na APA Alter do Chão, com vegetação de savana, sendo uma de savana menos densa e outra mais densa, e uma terceira na FLONA Tapajós, caracterizada pela vegetação de Floresta Ombrófila Densa (Figura 16). Resultando em um total de 9 ortomosaicos, 3 para cada área.

Figura 16 – Área de vegetação de Savana menos densa (A), Savana mais densa (B) e Floresta Ombrófila densa (C).



Fonte: Autor (2024)

4.3 Treino e Teste

O treinamento e teste do modelo DeepForest envolveram diversas etapas de processamento, desde a utilização de ortomosaicos gerados a partir de imagens capturadas por VANTs até a execução em diferentes plataformas computacionais. Foram utilizados um PC pessoal, o Cluster Tapajós da UFOPA e o Google Colab, cada um com configurações específicas de hardware, garantindo uma infraestrutura capaz de suportar análises complexas. O processamento incluiu a separação dos dados em


75% para treino/teste e 25% para validação, assegurando um modelo supervisionado ajustado com precisão.

4.3.1 Anotações Manuais

Foram realizadas anotações manuais nas áreas de estudo com o objetivo de identificar e delimitar as copas de árvores de forma precisa, utilizando dados locais no Software QGIS versão 3.34.11. Esse processo foi essencial para criar um conjunto de dados confiável, necessário para ajustar e validar o modelo DeepForest em cenários específicos da região amazônica. As anotações foram realizadas em imagens de alta resolução e utilizando o modelo digital de elevação respectivo, permitindo capturar características únicas de cada área e gerando informações detalhadas para a análise.

Na área de Alter Menos Densa, foram realizadas 2.763 anotações, destacando-se por uma vegetação mais espaçada e copas de diâmetros menores, o que facilita o processo de identificação e delimitação das copas (Figura 17). Já em Alter Mais Densa, foram anotadas 2.384 árvores, com maior dificuldade devido à alta concentração de vegetação, que gera sobreposições e exige maior atenção para separar as copas de maneira adequada.

Figura 17 – Anotações manuais de copas de árvores realizadas nas três áreas de estudo. (A) Alter Menos Densa, com 2.763 anotações; (B) Alter Mais Densa, com 2.384 anotações; (C) FLONA TAPAJÓS, com 1.930 anotações.



Fonte: Autor (2024)

Por sua vez, a FLONA Tapajós apresentou 1.930 anotações, refletindo um ambiente de alta densidade de copas e complexidade estrutural. A menor quantidade de árvores anotadas nessa área, em comparação com Alter do Chão, destaca os desafios adicionais impostos pela topografia e pela densidade da vegetação, sobreposição e copas de diâmetros maiores. As informações obtidas por meio dessas anotações serviram como base para avaliar e aprimorar a eficácia do modelo de detecção no contexto amazônico.

4.3.2 Hardware Utilizado

Com os ortomosaicos formados, foi realizada a etapa de processamento dos dados e a utilização do modelo DeepForest. O pacote foi executado em CPU e GPU, utilizando um computador pessoal, o Cluster Tapajós da UFOPA e o serviço Google Colab (Tabela 2).

Tabela 2 – Configurações de hardware utilizadas com o modelo DeepForest

Nome	Configuração
RTX 3080	1 Processador AMD RYZEN 5600 32 GB de Memória RAM Placa de vídeo NVIDIA RTX 3080 com 12gb de memória
Cluster UFOPA	2 Processadores AMD EPYC 7532 – 32 Cores e 64 Threads 250 GB de Memória RAM Placa de vídeo NVIDIA Tesla V100s com 32gb de memória
Colab T4 RAM Alta	Processador Intel Xeon Family 6 Model 63 - (E5-2670 v3) 51 GB de Memória RAM Placa de vídeo NVIDIA Tesla T4 com 15 GB de memória
Colab T4	Processador Intel Xeon Family 6 Model 85 - (Intel Xeon Gold 6138) 12.7 GB de Memória RAM Placa de vídeo NVIDIA Tesla T4 com 15 GB de memória
Colab L4	Processador Intel Xeon Family 6 Model 85 (Intel Xeon Gold 6240) 53 GB de Memória RAM Placa de vídeo NVIDIA L4 com 23 GB de memória
Colab A100	Processador Intel Xeon Family 6 Model 85 (Intel Xeon Gold 6240) 83.5 GB de Memória RAM Placa de vídeo NVIDIA A100 com 40 GB de memória

Fonte: Autor (2024)

As configurações dos hardwares incluem um PC pessoal com processador AMD Ryzen 5600, 32 GB de RAM e uma placa de vídeo NVIDIA RTX 3080 de 12 GB. O Cluster Tapajós, que possui o maior sistema de computação de alto desempenho do Oeste do Pará, e atinge 100 TFLOPS, realizando 100 trilhões de operações por segundo. Sua infraestrutura possui 08 Nós de Cálculo com 2 processadores AMD 7532 (128 núcleos, 256GB RAM) e 01 Nó de Cálculo Acelerado com 1 GPU NVIDIA V100 32GB. No Google Colab, diferentes instâncias foram utilizadas, com processadores Intel Xeon, entre 12,7 GB e 83,5 GB de RAM, e placas de vídeo NVIDIA Tesla T4, L4 e A100, com até 40 GB de memória.

4.3.3 Algoritmo supervisionado

Neste estudo foi utilizado o modelo DeepForest na etapa supervisionada. Nesta etapa foi realizado a detecção manual das árvores com a anotação das caixas nos ortomosaios (Figura 18) utilizando o software QGIS e exportando em formato GeoJSON, visando realizar o ajuste fino do modelo com base em dados locais manuais. Na execução do modelo, os dados foram separados em 75% para treino e teste, e 25% para validação.

Figura 18 – Exemplo de uma anotação de caixa de uma copa de árvore.



Fonte: Autor (2024)

4.3.4 Parâmetros utilizados

Para a aplicação do modelo DeepForest, foram realizados alguns ajustes importantes nos parâmetros de treinamento. Primeiramente, os ortomosaios resultantes do pré-processamento foram divididos em *patches* de 400x400 pixels, com o limite de interseção sobre união (*Intersection over Union* – IoU) de 0,5 (Figura 19).

Figura 19 – Exemplo de patches de 400x400 pixels na resolução de 4cm/pixel com o IoU acima de 0,5 no item A, e abaixo de 0,5 no item B.



Fonte: Autor (2024)

Dois testes distintos foram realizados para avaliar o desempenho do modelo em diferentes cenários. O primeiro teste focou em avaliar o impacto do número de épocas no desempenho do modelo. Foram testadas três configurações: 10, 15 e 30 épocas de treinamento. Cada configuração foi executada 10 vezes para garantir a robustez das estimativas e permitir a avaliação estatística que indicaria o número de épocas mais confiável para o modelo. Essa variação nas épocas de treinamento foi aplicada nos dois conjuntos de dados (APAAlter do Chão e FLONA do Tapajós), a fim de identificar a quantidade de épocas que resultava em melhor desempenho de detecção.

O segundo teste visou avaliar o efeito da resolução das imagens no desempenho do modelo. Foram utilizados três diferentes *datasets* com resoluções variadas para testar o modelo DeepForest em 30 épocas (Figura 20). Esse teste buscou identificar como a variação da resolução afeta a acurácia do modelo, utilizando as mesmas métricas de avaliação descritas anteriormente (*Recall*, *Precision* e *F1 Score*), permitindo assim uma análise mais abrangente sobre o comportamento do

modelo em cenários com resoluções distintas. Esses conjuntos de dados foram aplicados nos mesmos locais de estudo.

Figura 20 – Exemplo de patches de 400x400 pixels na resolução de 4cm/pixel (A), resolução de 7cm/pixel (B) e de 10cm/pixel (C).



Fonte: Autor (2024)

Ambos os testes foram repetidos e os resultados comparados para verificar o impacto das épocas de treinamento e da resolução das imagens nos diferentes *datasets*.

4.4 Avaliação dos modelos treinados

A avaliação dos modelos treinados em ambos os experimentos foi realizada na etapa supervisionada, utilizando as três métricas principais: *Recall*, *Precision* e *F1 Score*. Estas métricas são utilizadas em estudos envolvendo o DeepForest, devido à sua eficácia na medição da qualidade de detecção de objetos como copas de árvores (GAN et al., 2023; WEINSTEIN et al., 2019; WEINSTEIN et al., 2020).

O *Precision* é a métrica que indica a proporção de identificações positivas (neste caso, árvores detectadas) que estavam realmente corretas. É calculada como o número de verdadeiros positivos (TP) dividido pela soma dos verdadeiros positivos e falsos positivos (FP), ou seja, o total de árvores que o modelo identificou (Equação 1).

$$Precision = \frac{TP}{TP+FP} \quad (1)$$

O *Recall* é a métrica que indica a proporção de árvores reais que foram identificadas corretamente. É calculada como o número de verdadeiros positivos (TP) dividido pela soma dos verdadeiros positivos e falsos negativos (FN), ou seja, o total de árvores reais (Equação 2).

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

E o *F1 Score* é uma média harmônica entre as métricas de *Precision* e *Recall* (Equação 3).

$$F1\ Score = \frac{2 \times Recall \times Precision}{Recall + Precision} \quad (3)$$

Os modelos treinados com diferentes épocas e resoluções foram comparados de maneira estatística para avaliar a significância das variações observadas nos resultados.

4.5 Análise Estatística

Uma análise estatística foi realizada nos resultados dos dois experimentos, utilizando estatísticas descritivas, como média, desvio padrão, para avaliar a estabilidade e o desempenho do modelo nas diferentes execuções. Em seguida, foi aplicado o teste de Friedman para identificar diferenças estatisticamente significativas entre os modelos considerando os múltiplos conjuntos de dados.

Na comparação do desempenho para diferentes épocas e resoluções, os resultados dos modelos foram transformados em classificações (ranks) e avaliados com base no teste de Friedman. Na primeira fase, os resultados são transformados em classificações (ranks), que variam de 1 a k, onde k representa o número de modelos comparados. Cada conjunto de dados é avaliado separadamente e, em caso de empates, uma classificação média é atribuída (DEMŠAR, 2006).

A estatística de Friedman, X_F^2 , é calculada pela seguinte fórmula:

$$X_F^2 = \frac{12}{N \cdot K \cdot (K+1)} \left[\sum_j R_j^2 - \frac{k(k+1)^2}{4} \right] \quad (4)$$

com $k-1$ graus de liberdade, onde R_j é o rank médio dos modelos.

A hipótese nula do teste sugere que não há diferenças significativas entre os modelos. Um valor de p é calculado, e, se $p < 0,05$, a hipótese nula é rejeitada, indicando que pelo menos um dos modelos é significativamente diferente. Isso permitiu ordenar os resultados e determinar qual configuração (número de épocas ou resolução) apresentava os melhores desempenhos em termos de *Precision*, *Recall* e *F1 Score*. Para comparações adicionais entre as configurações, foi utilizado o teste post hoc de Nemenyi (NEMENYI, 1963; BARROW et al., 2013), que identifica diferenças estatisticamente significativas entre pares de grupos. Os testes foram conduzidos no software R.

5. RESULTADOS

O presente estudo avaliou o desempenho do modelo DeepForest na detecção de copas de árvores, com foco em diferentes configurações de treinamento, como número de épocas e resoluções de imagem. Todos os testes foram feitos na etapa supervisionada, embora, em outra ocasião, tenha sido empregado também na etapa não supervisionada, conforme descrito no Anexo A. Na seção 5.1, será apresentado a influência da quantidade de épocas (10, 15 e 30) no desempenho do modelo, analisando as métricas de *Precision*, *Recall* e *F1 Score* para Alter do Chão menos densa. A seção 5.2, por sua vez, abordará o impacto das resoluções de imagem (4cm, 7cm e 10cm) nos resultados do modelo, comparando a eficiência das imagens em três conjuntos de dados distintos. Ambos os testes incluem análises estatísticas.

Os testes realizados apresentaram variações nos tempos de execução, como demonstrado pelos resultados dos diferentes ambientes de processamento no Apêndice A. O hardware, como a GPU utilizada e a quantidade de memória RAM, tem um impacto direto no tempo de execução. Além disso, parâmetros como o número de épocas, a resolução do dataset e a quantidade de anotações também influenciam os tempos de execução.

Por exemplo, com uma GPU RTX 3080 no PC, teve uma variação do tempo de execução entre 13 minutos e 55 minutos, enquanto o Cluster UFOPA com V100 teve uma performance mais rápida, variando de 7 minutos a 40 minutos. No Colab, o T4

teve uma variação de 25 minutos a 1 hora e 30 minutos. A utilização de GPUs mais poderosas, como a A100, reduziu bastante o tempo, variando de 3 minutos a 30 minutos.

5.1 Avaliação do Desempenho do Modelo DeepForest com Diferentes Configurações de Épocas

Os testes realizados fornecem uma visão abrangente sobre os resultados do modelo *DeepForest* aplicado na detecção de copas de árvores na área de Alter do Chão, com foco em diferentes quantidades de épocas de treinamento e resoluções. O objetivo principal foi avaliar o desempenho do modelo ao longo de 10, 15 e 30 épocas, utilizando métricas padrão como *Precision*, *Recall* e *F1 Score*, de forma a compreender como o número de épocas afeta o desempenho do modelo.

A Tabela 3 apresenta valores detalhados de média, mediana, máximo, mínimo e desvio padrão para cada métrica em três diferentes quantidades de épocas (10, 15 e 30). O *Precision*, atinge uma média de 0,7566 em 30 épocas, demonstrando um aumento expressivo em relação às 10 épocas, que apresentou uma média de 0,6604. Além disso, o *Recall*, que mede a proporção de árvores reais que foram corretamente identificadas pelo modelo, também aumenta, atingindo 0,9169 em 30 épocas.

Tabela 3 – Valores de média, mediana, máximo, mínimo e desvio padrão de 10 execuções para o Conjunto de dados de Savana menos densa de Alter do Chão com 10 cm/pixel em relação ao número de épocas.


	Épocas	Média	Mediana	Máximo	Mínimo	Desvio Padrão
<i>Precision</i>	10	0,6604	0,6645	0,6804	0,6384	0,0127
	15	0,6931	0,6866	0,7263	0,6734	0,0182
	30	0,7566	0,7595	0,7792	0,7238	0,0159
<i>Recall</i>	10	0,8551	0,8572	0,8688	0,8251	0,0134
	15	0,8866	0,8862	0,8971	0,8749	0,0080
	30	0,9169	0,9165	0,9318	0,9067	0,0076
<i>F1 Score</i>	10	0,7451	0,7451	0,7539	0,7348	0,0074
	15	0,7778	0,7735	0,7993	0,7662	0,0112
	30	0,8290	0,8308	0,8487	0,8050	0,0124

Fonte: Autor (2024)

Isso indica que, com mais tempo de treinamento, o modelo DeepForest se torna mais capaz de identificar copas de árvores de forma precisa, especialmente em áreas complexas de florestas. O *F1 Score*, também aumenta com o número de épocas, chegando a 0,8290 em 30 épocas, o que demonstra que o modelo melhora tanto na identificação de árvores reais quanto na minimização de falsas detecções.

A Figura 21 exibe os mesmos resultados em um box plot, permitindo uma visualização clara da dispersão dos dados. É notável que, à medida que o número de épocas aumenta, o desempenho do modelo aumenta. Esse padrão se repete tanto para os dados de Alter do Chão Mais Densa (Apêndice B) quanto para os da FLONA (Apêndice C). Em ambos os casos, observa-se que métricas como *Precision*, *Recall* e *F1 Score* apresentam melhor desempenho com 30 épocas. Esses resultados reforçam a tendência de que maior número de épocas contribui para um desempenho mais robusto do modelo, mesmo em cenários com diferentes características ambientais, como densidade florestal e complexidade dos dados.

Figura 21 - Box Plot do resultado de 10 execuções para o Conjunto de dados de Savana menos densa de Alter do Chão com 10 cm/pixel em relação ao número de épocas.



Fonte: Autor (2024)

O gráfico de *Precision*, por exemplo, mostra o maior desempenho nos resultados com 30 épocas, indicando que o modelo apresenta previsões melhores com mais tempo de treinamento. O *Recall* também apresenta uma melhora com 30

épocas, o que reforça a capacidade do modelo em detectar copas de árvores de maneira consistente, mesmo em condições de vegetação menos densa, como observado em Alter do Chão.

O gráfico do *F1 Score* segue uma tendência semelhante, indicando que o modelo atinge um equilíbrio ideal entre *Precision* e *Recall* à medida que o número de épocas aumenta. O teste de Friedman resultou em um valor $p = 0,0498$, indicando que há, de fato, uma diferença significativa entre o desempenho do modelo ao longo das diferentes quantidades de épocas (10, 15 e 30). A Tabela 4 apresenta os resultados do teste post hoc de Nemenyi, que foram aplicados para avaliar se as diferenças no desempenho do modelo em relação ao número de épocas eram estatisticamente significativas.

Tabela 4 – Teste post hoc de Nemenyi para Conjunto de dados de Savana menos densa de Alter do Chão de 10 cm/pixel em relação ao número de épocas referente ao *F1 Score*.

	10 Épocas	15 Épocas
15 Épocas	0,4380	
30 Épocas	0,0380	0,4380

Fonte: Autor (2024)

O teste post hoc de Nemenyi, por sua vez, comparou diretamente os resultados entre as diferentes quantidades de épocas. Ao comparar 30 épocas com 10 épocas, o teste revelou um valor $p = 0,0380$, sugerindo que o aumento no número de épocas resulta em uma melhoria estatisticamente significativa no desempenho do modelo.

Os resultados fornecem uma análise detalhada de como o número de épocas afeta o desempenho do modelo DeepForest. Os resultados indicam que, com mais épocas de treinamento, o modelo melhora o *Precision*, *Recall* e *F1 Score*, tornando-se mais estável e consistente.

5.2 Avaliação do Desempenho do Modelo DeepForest com Diferentes Resoluções

Os resultados a seguir ilustram a análise do desempenho do modelo DeepForest utilizando 30 épocas em diferentes resoluções (4cm, 7cm e 10cm) para

três conjuntos de dados (Alter Menos Densa, Alter Mais Densa e FLONA Tapajós) utilizando os valores de *Precision*, *Recall* e *F1 Score* (Tabela 5).

Tabela 5 – Valores de média, mediana, máximo, mínimo e desvio padrão *para Precision, Recall e F1 Score* de 10 execuções para os 3 conjuntos de Dados em 3 diferentes resoluções usando 30 épocas.

		Resolução	Média	Mediana	Máximo	Mínimo	Desvio Padrão
Precision	Alter Menos Densa	4cm	0,7297	0,7368	0,7644	0,6792	0,0262
		7cm	0,8222	0,8241	0,8354	0,8021	0,0084
		10cm	0,7566	0,7594	0,7792	0,7238	0,0151
	Alter Mais Densa	4cm	0,8275	0,8308	0,8735	0,7610	0,0336
		7cm	0,7080	0,7013	0,7898	0,6680	0,0368
		10cm	0,6655	0,6633	0,6887	0,6428	0,0158
	FLONA Tapajós	4cm	0,6760	0,6712	0,7852	0,6133	0,0519
		7cm	0,7088	0,7093	0,7364	0,6754	0,0185
		10cm	0,6673	0,6721	0,6961	0,6303	0,0202
Recall	Alter Menos Densa	4cm	0,9933	0,9933	0,9948	0,9921	0,0008
		7cm	0,8464	0,8460	0,8652	0,8343	0,0086
		10cm	0,9169	0,9165	0,9318	0,9067	0,0072
	Alter Mais Densa	4cm	0,9923	0,9925	0,9947	0,9893	0,0013
		7cm	0,9861	0,9865	0,9887	0,9825	0,0022
		10cm	0,9132	0,9120	0,9244	0,9020	0,0057
	FLONA Tapajós	4cm	0,9783	0,9770	0,9858	0,9715	0,0041
		7cm	0,7805	0,7850	0,7976	0,7627	0,0127
		10cm	0,8114	0,8107	0,8367	0,7870	0,0148
F1 Score	Alter Menos Densa	4cm	0,8411	0,8460	0,8638	0,8070	0,0184
		7cm	0,8341	0,8361	0,8453	0,8206	0,0074
		10cm	0,8290	0,8308	0,8487	0,8050	0,0124
	Alter Mais Densa	4cm	0,9021	0,9045	0,9289	0,8613	0,0119
		7cm	0,8237	0,8196	0,8768	0,7964	0,0211
		10cm	0,7698	0,7706	0,7869	0,7542	0,0257
	FLONA Tapajós	4cm	0,7984	0,7959	0,8706	0,7549	0,0376
		7cm	0,7428	0,7415	0,7622	0,7203	0,0138
		10cm	0,7321	0,7375	0,7465	0,7000	0,0154

Fonte: Autor (2024)

A análise é detalhada em termos de média, mediana, máximo, mínimo e desvio padrão para cada resolução, com gráficos de box plot e testes estatísticos adicionais para validar os resultados, como o teste de Friedman e o teste post hoc de Nemenyi. Além disso, foram realizados os mesmos testes utilizando 10 e 15 épocas, cujos resultados encontram-se nos Apêndices D, E, F e G.

Os resultados indicam que a resolução de 4cm é a que apresenta o melhor desempenho geral, destacando-se com os maiores valores médios de *F1 Score* em Alter Menos Densa (0,8411), Alter Mais Densa (0,9021) e FLONA Tapajós (0,7984). Esses valores refletem a capacidade dessa resolução em fornecer mais detalhes nas imagens, o que facilita a identificação de copas de árvores pelo modelo.

No caso do *Precision*, a resolução de 7cm se destaca em Alter Menos Densa, com uma média de 0,8222, e na FLONA Tapajós, com 0,7088. Entretanto, a resolução de 4cm obteve o melhor desempenho em Alter Mais Densa, alcançando uma média de 0,8275. Em contraste, a resolução de 10cm apresenta os piores valores em todos os conjuntos de dados, com quedas significativas no *Precision*, especialmente em Alter Mais Densa (0,6655) e na FLONA Tapajós (0,6673).

Os resultados de *Recall* confirmam a superioridade da resolução de 4cm, que apresentou os melhores valores médios em todos os conjuntos: 0,9933 em Alter Menos Densa, 0,9925 em Alter Mais Densa e 0,9783 na FLONA Tapajós. A resolução de 7cm também apresentou resultados consistentes e próximos aos de 4cm, enquanto a de 10cm mostrou desempenho inferior, especialmente em FLONA Tapajós, onde o *Recall* médio foi de apenas 0,8114.

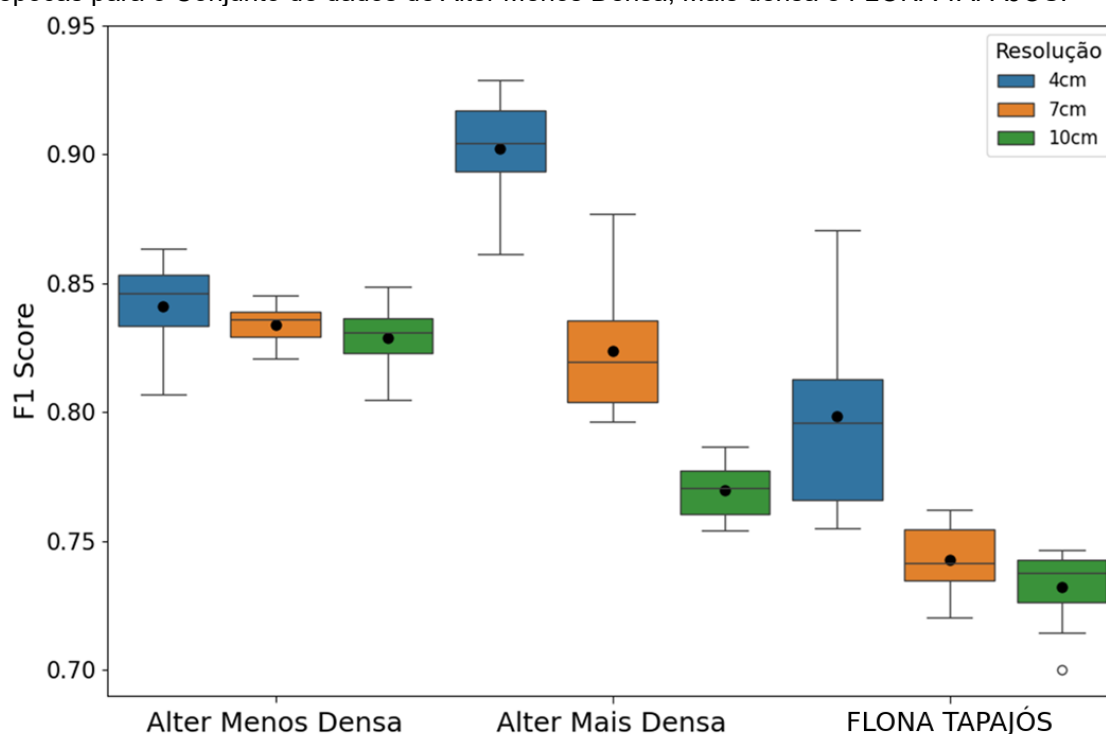
O *F1 Score*, por ser uma média harmônica, destaca que a resolução de 4 cm é a mais adequada, pois apresenta os melhores resultados em todos os conjuntos de dados. No entanto, ao analisar os resultados de *Precision* separadamente, observa-se que a resolução de 4 cm não oferece o melhor desempenho para todos os conjuntos. Isso mostra que, embora o *Precision* e *Recall* possa variar, o *F1 Score* fornece uma visão mais equilibrada e abrangente, reforçando a superioridade dessa resolução.

A resolução de 7cm apresentou desempenho intermediário, enquanto a resolução de 10cm registrou os piores resultados, com um *F1 Score* médio de 0,7321 na FLONA Tapajós. Esses resultados evidenciam que imagens de maior resolução fornecem mais informações detalhadas, permitindo que o modelo de Deep Learning

tenha um desempenho significativamente superior. Por outro lado, a menor resolução (10cm) compromete a detecção precisa de copas de árvores, especialmente em áreas mais densas, como Alter Mais Densa e FLONA Tapajós, destacando a importância da qualidade das imagens para vegetações mais densas.

A Figura 22 apresenta o box plot dos resultados de *F1 Score* para as três resoluções em cada conjunto de dados para 30 épocas. A visualização clara da dispersão dos resultados permite observar como a variabilidade é impactada pela resolução das imagens. Novamente, a resolução de 4cm apresenta os valores mais altos de *F1 Score*, especialmente em Alter Mais Densa, reforçando a eficácia das imagens de maior resolução. O conjunto de dados FLONA Tapajós, no entanto, apresenta maior variabilidade nos resultados, mesmo com a resolução de 4cm. Esse comportamento pode ser explicado pela densidade variável da floresta e a complexidade da vegetação, podendo gerar maior dificuldade na detecção de copas, mesmo com imagens de alta resolução.

Figura 22 - Box Plot do resultado de *F1 Score* de 10 execuções em 3 diferentes resoluções utilizando 30 épocas para o Conjunto de dados de Alter Menos Densa, Mais densa e FLONA TAPAJÓS.



Fonte: Autor (2024)

Além disso, mesmo em resoluções melhores o box plot mostram uma alta dispersão nos resultados, sugerindo que o modelo tem dificuldade em manter a

consistência mesmo em imagens de maior qualidade. O teste de Friedman revelou um valor $p = 0,0498$, o que indica que há diferenças significativas no desempenho do modelo quando se utiliza diferentes resoluções de imagem utilizando o *F1 Score*. A Tabela 6 apresenta os resultados do teste post hoc de Nemenyi, que foram aplicados para verificar se as diferenças de desempenho entre as resoluções são estatisticamente significativas.

Tabela 6 – Teste post hoc de Nemenyi para os conjuntos de dados de Alter Menos Densa, Mais densa e FLONA TAPAJÓS em 3 diferentes resoluções referente ao *F1 Score* 30 épocas.

	4 cm	7 cm
7 cm	0,4380	
10 cm	0,0380	0,4380

Fonte: Autor (2024)

O teste post hoc de Nemenyi foi então utilizado para realizar comparações par a par entre as resoluções. Os resultados mostram que a diferença entre 4cm e 10cm é particularmente significativa, com um valor de $p = 0,0380$. Isso reforça a importância de utilizar resoluções mais altas para garantir um desempenho mais eficaz do modelo, especialmente em regiões florestais complexas como as analisadas neste estudo. A Tabela 6 de ranking também destaca que, em todos os grupos (Alter Menos Densa, Alter Mais Densa e FLONA Tapajós), a resolução de 4cm apresenta os melhores resultados, reforçando que imagens de alta resolução são essenciais para o sucesso de tarefas de detecção baseadas em DL.

Os resultados demonstram que a resolução das imagens desempenha um papel importante no desempenho do modelo DeepForest para a detecção de copas de árvores. Resoluções mais altas, como 4cm, fornecem resultados melhores em termos de *F1 Score*, enquanto resoluções mais baixas, como 7cm e 10cm, resultam em uma queda no desempenho. A análise estatística mostra que essas diferenças são estatisticamente significativas, e ao utilizar imagens de alta qualidade é obtido uma melhora na acurácia e consistência dos modelos de DL aplicados à ecologia florestal. Todos os demais resultados estão nos Apêndices H a P.

6. DISCUSSÃO

No presente trabalho, o modelo DeepForest foi avaliado para a detecção de copas de árvores em florestas tropicais de diferentes densidades, considerando o número de épocas de treinamento e a resolução das imagens, utilizando imagens RGB de alta resolução. O aumento no número de épocas melhorou métricas como *Precision*, *Recall* e *F1 Score*, em áreas menos densas, como na área de Alter Menos Densa. Esses resultados são consistentes com estudos que demonstraram que períodos de treinamento mais longos permitem que o modelo aprenda melhor padrões complexos, como é observado em florestas tropicais (REIERSEN et al., 2022; WEINSTEIN et al., 2022).

Imagens com resolução de 4 cm apresentaram os melhores desempenhos em todos os conjuntos de dados, confirmando que resoluções mais altas aprimoram a identificação de detalhes das copas, como observado por Aubry-Kientz et al. (2021), Sivanandam e Lucieer (2022) e Gan et al. (2023). Tolan et al. (2024) também relataram que o uso de imagens de alta resolução aumentou a consistência nas métricas de desempenho, reforçando a importância de dados de maior qualidade para análises mais precisas.

Por outro lado, resoluções de 10 cm resultaram em desempenho reduzido, evidenciando a dificuldade do modelo em captar detalhes em áreas densas, um comportamento também observado em estudos realizados em florestas temperadas (GAN et al., 2023). Marvasti-Zadeh et al. (2021), relataram problemas semelhantes, onde resoluções mais baixas comprometeram a capacidade do modelo de segmentar copas em florestas com alta densidade de vegetação.

Além disso, o aumento da variabilidade em 10 cm, observado neste estudo, reforça as limitações do modelo ao lidar com ambientes heterogêneos, como a FLONA Tapajós, corroborando achados de Tolan et al. (2024), que destacaram que resoluções inferiores aumentam a inconsistência nos resultados em ecossistemas complexos.

Os resultados também indicam que o impacto da redução de resolução é mais evidente em ambientes densos, como a FLONA Tapajós e Alter Mais Densa, enquanto áreas menos densas, como Alter Menos Densa, são menos sensíveis a essa mudança de resolução. Velasquez-Camacho et al. (2023) também observaram que, em locais

menos complexos, o modelo DeepForest mantém um desempenho consistente, mesmo ao utilizar imagens com resoluções menores.

O desempenho do DeepForest é influenciado pela resolução das imagens e pelo número de épocas. Resoluções de 4 cm e treinamento com 30 épocas mostraram-se mais adequadas para áreas mais densas, enquanto resoluções menores e menos épocas podem ser suficientes para áreas menos densas. Esses resultados, alinhados à literatura, reforçam a importância de ajustar os parâmetros do modelo às características do ecossistema para garantir maior eficiência.

Os resultados obtidos evidenciam a contribuição deste estudo para a utilização do modelo DeepForest às particularidades do bioma amazônico, caracterizado por alta densidade da vegetação, grande biodiversidade e variações topográficas. O trabalho aborda desafios importantes associados ao monitoramento florestal em uma região de grande complexidade ambiental. Embora estudos prévios tenham aplicado o modelo em outros contextos, não há registros de sua utilização nas condições da Amazônia. Isso ressalta a importância dos ajustes realizados com base em imagens obtidas localmente, os quais permitiram alcançar resultados mais precisos e alinhados às particularidades desses locais.

6. CONCLUSÕES

Este estudo destacou a importância do uso de tecnologias de SR, aliadas a modelos de DL como o DeepForest, para a detecção de copas de árvores na Amazônia. Os testes realizados com diferentes épocas de treinamento evidenciaram que o aumento no número de épocas melhora significativamente as métricas de desempenho, como *Precision*, *Recall* e *F1 Score*. Além disso, imagens de maior resolução (4 cm) se mostraram mais eficazes na detecção precisa, especialmente em áreas de vegetação densa, conforme confirmado por análises estatísticas. Esses resultados evidenciam a eficácia do emprego do modelo DeepForest para dados de florestas tropicais, viabilizando o monitoramento preciso e detalhado de ecossistemas complexos, como o da Amazônia.

Além disso, a identificação de espécies surge como o próximo avanço no uso de tecnologias como SR e modelos de DL. A capacidade de diferenciar espécies a partir de características obtidas por SR abre novas possibilidades para análises mais

detalhadas da biodiversidade em florestas tropicais. Essa abordagem permitiria não apenas mapear espécies de interesse, mas também aprimorar a estimativa de biomassa ao associar grupos de espécies com suas respectivas capacidades de estocagem de carbono. A integração desses métodos reforça a potencialidade do monitoramento ambiental em detalhar aspectos críticos dos ecossistemas e contribuir para sua conservação.

REFERÊNCIAS BIBLIOGRÁFICAS

ADEL, T.; LEVENE, M. A General Model for Side Information in Neural Networks. **Algorithms**, v. 16, n. 11, p. 526, 2023.

AGEAGLE. eBee X. Disponível em: <<https://ageagle.com/pt-br/drones/drone-de-mapeamento-ebex/>>. Acesso em: 05 de dez. de 2024.

AGGARWAL, K.; MIJWIL, M. M.; AL-MISTAREHI, A. H.; ALOMARI, S.; GÖK, M.; ALAABDIN, A. M. Z.; ABDULRHMAN, S. H. Has the future started? The current growth of artificial intelligence, machine learning, and deep learning. **Iraqi Journal for Computer Science and Mathematics**, v. 3, n. 1, p. 115-123, 2022.

ALBUQUERQUE, R. W. **Aplicação de aeronaves remotamente pilotadas e fotogrametria para avaliação e monitoramento de áreas em processo de restauração florestal**. 2022. Tese de Doutorado. Universidade de São Paulo.

ALEXANDER, C.; KORSTJENS, A. H.; HANKINSON, E.; USHER, G.; HARRISON, N.; NOWAK, M. G.; HILL, R. A. Locating emergent trees in a tropical rainforest using data from an Unmanned Aerial Vehicle (UAV). **International journal of applied earth observation and geoinformation**, v. 72, p. 86-90, 2018.

ALONZO, M.; MCFADDEN, J. P.; NOWAK, D. J.; ROBERTS, D. A. Mapping urban forest structure and function using hyperspectral imagery and lidar data. **Urban forestry & urban greening**, v. 17, p. 135-147, 2016.

ANAC. **Orientações para usuários de Drones**. 2017. Disponível em: <https://www.gov.br/anac/pt-br/assuntos/drones/orientacoes_para_usuarios.pdf> 10 de dez. de 2024.

ANTONELLI, A.; ZIZKA, A.; CARVALHO, F. A.; SCHARN, R.; BACON, C. D.; SILVESTRO, D.; CONDAMINE, F. L. Amazonia is the primary source of Neotropical biodiversity. **Proceedings of the National Academy of Sciences**, v. 115, n. 23, p. 6034-6039, 2018.

ANWER, R. M.; KHAN, F. S.; VAN DE WEIJER, J.; MOLINIER, M.; Laaksonen, J. Binary patterns encoded convolutional neural networks for texture recognition and remote sensing scene classification. **ISPRS journal of photogrammetry and remote sensing**, v. 138, p. 74-85, 2018.

ARRUDA, D. M.; SCHAEFER, C. E.; FONSECA, R. S.; SOLAR, R. R.; FERNANDES-FILHO, E. I. Vegetation cover of Brazil in the last 21 ka: New insights into the Amazonian refugia and Pleistocenic arc hypotheses. **Global Ecology and Biogeography**, v. 27, n. 1, p. 47-56, 2018.

ARRUDA, D.; CANDIDO, H. G.; FONSECA, R. Amazon fires threaten Brazil's agribusiness. **Science**, v. 365, n. 6460, p. 1387-1387, 2019.

AUBRY-KIENTZ, M.; LAYBROS, A.; WEINSTEIN, B.; BALL, J. G.; JACKSON, T.; COOMES, D.; VINCENT, G. Multisensor data fusion for improved segmentation of

individual tree crowns in dense tropical forests. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 14, p. 3927-3936, 2021.

BARLOW, H. B. Unsupervised learning. **Neural computation**, v. 1, n. 3, p. 295-311, 1989.

BARROS, H. S.; FEARNSTIDE, P. M. Soil carbon is decreasing under “undisturbed” Amazonian forest. **Soil Science Society of America Journal**, v. 83, n. 6, p. 1779-1785, 2019.

BARROW, D.; DRAYER, I.; ELLIOTT, P.; GAUT, G.; OSTING, B. Ranking rankings: an empirical comparison of the predictive power of sports ranking methods. **Journal of Quantitative Analysis in Sports**, v. 9, n. 2, p. 187-202, 2013.

BENNETT, L.; WILSON, B.; SELAND, S.; QIAN, L.; WOOD, M.; ZHAO, H.; BOISVERT, J. Image to attribute model for trees (ITAM-T): individual tree detection and classification in Alberta boreal forest for wildland fire fuel characterization. **International Journal of Remote Sensing**, v. 43, n. 5, p. 1848-1880, 2022.

BHARDWAJ, A.; SAM, L.; MARTÍN-TORRES, F. J.; KUMAR, R. UAVs as remote sensing platform in glaciology: Present applications and future prospects. **Remote sensing of environment**, v. 175, p. 196-204, 2016.

BOSE, B.K. Artificial intelligence techniques in smart grid and renewable energy systems—Some example applications. **Proceedings of the IEEE**, v. 105, n. 11, p. 2262-2273, 2017.

BRAGION, G. D. R.; DAL’ASTA, A. P.; AMARAL, S. Bringing to Light the Potential of Angular Nighttime Composites for Monitoring Human Activities in the Brazilian Legal Amazon. **Remote Sensing**, v. 15, n. 14, p. 3515, 2023.

BREIMAN, L. Random forests. **Machine learning**, v. 45, p. 5-32, 2001.

CAUSEVIC, A.; CAUSEVIC, S.; FIELDING, M.; BARROTT, J. Artificial intelligence for sustainability: opportunities and risks of utilizing Earth observation technologies to protect forests. **Discover Conservation**, v. 1, n. 1, p. 2, 2024.

CHAPELLE, O.; SCHOLKOPF, B.; ZIEN, A. **Semi-supervised learning**. The MIT Press, 2006.

CHEN, T.; GUESTRIN, C. Xgboost: A scalable tree boosting system. In: **Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining**. 2016. p. 785-794.

CHOLLET, F. **Deep learning with Python**. Simon and Schuster, 2018.

COLLINS, G. S.; MOONS, K. G. M. Reporting of artificial intelligence prediction models. **The Lancet**, v. 393, n. 10181, p. 1577-1579, 2019.

CUNNINGHAM, P.; CORD, M.; DELANY, S. J. Supervised learning. In: **Machine learning techniques for multimedia: case studies on organization and retrieval**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008. p. 21-49.

DAKOV, V; PETROVA-ANTONOVA, D. Urban Tree Detection from Remote Sensing Data based on DeepForest Model. **ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 10, p. 35-41, 2024.

DASH, J. P.; WATT, M. S.; PEARSE, G. D.; HEAPHY, M.; DUNGEY, H. S. Assessing very high resolution UAV imagery for monitoring forest health during a simulated disease outbreak. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 131, p. 1-14, 2017.

DE ANDRADE, R. B.; MOTA, G. L. A.; DA COSTA, G. A. O. P. Deforestation Detection in the Amazon Using DeepLabv3+ Semantic Segmentation Model Variants. **Remote Sensing**, v. 14, n. 19, p. 4694, 2022.

DE SÁ, R. J. D. S.; FÉLIX, I. B.; DE SOUZA, G. B.; DOS SANTOS SILVA, A. P.; DE SOUZA, A. G. S.; RIBEIRO, J. M. F. A importância da biodiversidade amazônica. **Multidisciplinary Reviews**, v. 2, p. e2019011-e2019011, 2019.

DEMŠAR, J. Statistical comparisons of classifiers over multiple data sets. **The Journal of Machine learning research**, v. 7, p. 1-30, 2006.

DJI. DJI Air 2s. Disponível em: <<https://www.dji.com/br/support/product/air-2s>>. Acesso em: 05 de dez. de 2024.

DOS SANTOS, A. M.; DA SILVA, C. F. A.; DE ALMEIDA JUNIOR, P. M.; RUDKE, A. P.; DE MELO, S. N. Deforestation drivers in the Brazilian Amazon: Assessing new spatial predictors. **Journal of environmental management**, v. 294, p. 113020, 2021.

EMBRAPA. Sistema Interativo de Análise Geoespacial da Amazônia Legal. 2020. Disponível em: <https://www.amazonia.cnptia.embrapa.br/>. Acesso em: 04 mai. 2023.

FEARNSIDE, P. M. Desmatamento na Amazônia brasileira: história, índices e consequências. **Destruição e Conservação da Floresta Amazônica**, v. 1, p. 7-19, 2005.

FEARNSIDE, P. M. The intrinsic value of Amazon biodiversity. **Biodiversity and Conservation**, v. 30, n. 4, p. 1199-1202, 2021.

FIGUEIREDO, E.; FIGUEIREDO, S. D. M.; OLIVEIRA, M. D.; DOS SANTOS, E. K. M. **Manejo florestal 4.0: calendário preliminar de inventário florestal com aeronaves remotamente pilotadas**. 2018.

GAN, Y.; WANG, Q.; IIO, A. Tree Crown Detection and Delineation in a Temperate Deciduous Forest from UAV RGB Imagery Using Deep Learning Approaches: Effects of Spatial Resolution and Species Characteristics. **Remote Sensing**, v. 15, n. 3, p. 778, 2023.

GONÇALVES, F. G.; SANTOS, J.R. Composição florística e estrutura de uma unidade de manejo florestal sustentável na Floresta Nacional do Tapajós, Pará. **Acta Amazonica**, v. 38, n. 2, p. 229-244, 2008.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge, MA, USA: MIT press, 2016.

GUAYASAMIN, J. M.; RIBAS, C. C.; CARNAVAL, A. C.; CARRILLO, J. D.; HOORN, C.; LOHMANN, L. G.; ALBERT, J. S. Evolution of Amazonian biodiversity: A review. **Acta Amazonica**, v. 54, n. spe1, p. e54bc21360, 2024.

HARINI, M.; SELVAVARSHINI, S.; NARMATHA, P.; ANITHA, V.; SELVI, S. K.; MANIMARAN, V. Resnet-50 Integrated with Attention Mechanism for Remote Sensing Classification. In: **International Conference on Advances in Distributed Computing and Machine Learning**. Singapore: Springer Nature Singapore, 2024. p. 255-265.

HAYKIN, S. **Neural networks: a comprehensive foundation**. Prentice Hall PTR, 1998.

HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. 2016. p. 770-778.

HESS, L. L.; MELACK, J. M.; AFFONSO, A. G.; BARBOSA, C.; GASTIL-BUHL, M.; NOVO, E. M. Wetlands of the lowland Amazon basin: Extent, vegetative cover, and dual-season inundated area as mapped with JERS-1 synthetic aperture radar. **Wetlands**, v. 35, p. 745-756, 2015.

HINTON, G.; SEJNOWSKI, T. J. **Unsupervised learning: foundations of neural computation**. MIT press, 1999.

HO, T. K. Random decision forests. In: **Proceedings of 3rd international conference on document analysis and recognition**. IEEE, 1995. p. 278-282.

HOORN, C.; LOHMANN, L. G.; BOSCHMAN, L. M.; CONDAMINE, F. L. Neogene history of the Amazonian flora: a perspective based on geological, palynological, and molecular phylogenetic data. **Annual Review of Earth and Planetary Sciences**, v. 51, n. 1, p. 419-446, 2023.

HU, R.; BOURNEZ, E.; CHENG, S.; JIANG, H.; NERRY, F.; LANDES, T.; ... YAN, G. Estimating the leaf area of an individual tree in urban areas using terrestrial laser scanner and path length distribution model. **ISPRS journal of photogrammetry and remote sensing**, v. 144, p. 357-368, 2018.

HUBBELL, S. P.; HE, F.; CONDIT, R.; BORDA-DE-ÁGUA, L.; KELLNER, J.; TER STEEGE, H. How many tree species are there in the Amazon and how many of them will go extinct?. **Proceedings of the National Academy of Sciences**, v. 105, n. supplement_1, p. 11498-11504, 2008.

IBAMA (Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis). 2004. **Floresta Nacional do Tapajós – Plano de Manejo**. IBAMA, Belterra, Pará. 373pp.

JEMAA, H.; BOUACHIR, W.; LEBLON, B.; LAROCQUE, A.; HADDADI, A.; BOUGUILA, N. Uav-based computer vision system for orchard apple tree detection and health assessment. **Remote Sensing**, v. 15, n. 14, p. 3558, 2023.

JENSEN, J. R.; EPIPHANIO, J. C. N. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. 2009.

KAPIL, R.; MARVASTI-ZADEH, S. M.; ERBILGIN, N.; RAY, N. Shadowsense: Unsupervised domain adaptation and feature fusion for shadow-agnostic tree crown detection from rgb-thermal drone imagery. In: **Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision**. 2024. p. 8266-8276.

KARSENTY, A.; ROMERO, C.; CERUTTI, P. O.; DOUCET, J. L.; PUTZ, F. E.; BERNARD, C.; DE WASSEIGE, C. Deforestation and timber production in Congo after implementation of sustainable management policy: A reaction to the article by JS Brandt, C. Nolte and A. Agrawal (Land Use Policy 52: 15–22). **Land use policy**, v. 65, p. 62-65, 2017.

KORTELING, J.H.; VAN DE BOER-VISSCHEDIJK, G.C.; BLANKENDAAL, R.A.; BOONEKAMP, R.C.; EIKELBOOM, A.R. Human-versus artificial intelligence. **Frontiers in artificial intelligence**, v. 4, p. 622364, 2021.

LAPEYROLERIE, M.; CHAPMAN, M. S.; NORMAN, K. E.; BOETTIGER, C. Deep reinforcement learning for conservation decisions. **Methods in Ecology and Evolution**, v. 13, n. 11, p. 2649-2662, 2022.

LEITE-FILHO, A. T.; DE SOUSA PONTES, V. Y.; COSTA, M. H. Effects of deforestation on the onset of the rainy season and the duration of dry spells in southern Amazonia. **Journal of Geophysical Research: Atmospheres**, v. 124, n. 10, p. 5268-5281, 2019.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436-444, 2015.

LIU, K.; SHEN, X.; CAO, L.; WANG, G.; CAO, F. Estimating forest structural attributes using UAV-LiDAR data in Ginkgo plantations. **ISPRS journal of photogrammetry and remote sensing**, v. 146, p. 465-482, 2018.

MAIMAITIJIANG, M.; SAGAN, V.; SIDIKE, P.; MAIMAITIYIMING, M.; HARTLING, S.; PETERSON, K. T.; FRITSCHI, F. B. Vegetation index weighted canopy volume model (CVMVI) for soybean biomass estimation from unmanned aerial system-based RGB imagery. **ISPRS journal of photogrammetry and remote sensing**, v. 151, p. 27-41, 2019.

MAPBIOMAS. O Projeto. 2019. Disponível em: <https://mapbiomas.org/o-projeto/>. Acesso em: 27 jul. 2023.

MAPBIOMAS. RAD2023: Relatório Anual do Desmatamento no Brasil 2023 - São Paulo, Brasil - MapBiomias, 2024 - 154 páginas Disponível em: https://alerta.mapbiomas.org/wp-content/uploads/sites/17/2024/10/RAD2023_COMPLETO_15-10-24_PORTUGUES.pdf. Acesso em: 19 nov. 2024.

MAPPA. **Sobreposição de imagens: por que ela é importante?** 2020. Disponível em: <https://mappa.ag/blog/sobreposicao-de-imagens-por-que-ela-e-importante/#:~:text=Se%20a%20sobreposi%C3%A7%C3%A3o%20de%20imagens,erros%20no%20processamento%20de%20imagens.>>. Acesso em: 27 jul. 2024.

MARIN, I.; GOTOVAC, S.; PAPIĆ, V. Development and Analysis of Models for Detection of Olive Trees. **Advances in science, technology and engineering systems journal**, v. 8, p. 87-96, 2023.

MARVASTI-ZADEH, S. M.; GOODSMAN, D.; RAY, N.; ERBILGIN, N. Crown-CAM: Interpretable visual explanations for tree crown detection in aerial images. **IEEE Geoscience and Remote Sensing Letters**, v. 20, p. 1-5, 2023.

MATESE, A.; TOSCANO, P.; DI GENNARO, S. F.; GENESIO, L.; VACCARI, F. P.; PRIMICERIO, J.; GIOLI, B. Intercomparison of UAV, aircraft and satellite remote sensing platforms for precision viticulture. **Remote Sensing**, v. 7, n. 3, p. 2971-2990, 2015.

MAURANO, L. E. P.; ESCADA; M. I. S.; RENNO, C. D. Padrões espaciais de desmatamento e a estimativa da exatidão dos mapas do PRODES para Amazônia Legal Brasileira. **Ciência florestal**, v. 29, p. 1763-1775, 2019.

MERCADANTE, M. Avanços na implementação do SNUC e desafios para o futuro. **Brasília, DF**, 2007.

MERENDA, M.; PORCARO, C.; IERO, D. Edge machine learning for ai-enabled iot devices: A review. **Sensors**, v. 20, n. 9, p. 2533, 2020.

MISHRA, A. K.; DESAI, V. R. Drought forecasting using feed-forward recursive neural network. **ecological modelling**, v. 198, n. 1-2, p. 127-138, 2006.

MIYAMOTO, M. Poverty reduction saves forests sustainably: Lessons for deforestation policies. **World Development**, v. 127, p. 104746, 2020.

NAJAFABADI, M. M.; VILLANUSTRE, F.; KHOSHGOFTAAR, T. M.; SELIYA, N.; WALD, R.; MUHAREMAGIC, E. Deep learning applications and challenges in big data analytics. **Journal of big data**, v. 2, n. 1, p. 1-21, 2015.

NAMATÈVS, I. Deep convolutional neural networks: Structure, feature extraction and training. **Information Technology and Management Science**, v. 20, n. 1, p. 40-47, 2017.

NEPSTAD, D.; MCGRATH, D.; STICKLER, C.; ALENCAR, A.; AZEVEDO, A.; SWETTE, B.; HESS, L. Slowing Amazon deforestation through public policy and interventions in beef and soy supply chains. **Science**, v. 344, n. 6188, p. 1118-1123, 2014.

NEMENYI, P. B. **Distribution-free multiple comparisons**. Princeton University, 1963.

PANIGRAHY, R. K.; KALE, M. P.; DUTTA, U.; MISHRA, A.; BANERJEE, B.; SINGH, S. Forest cover change detection of Western Ghats of Maharashtra using satellite remote sensing based visual interpretation technique. **Current Science**, p. 657-664, 2010.

PARIS, C.; KELBE, D.; VAN AARDT, J.; BRUZZONE, L. A novel automatic method for the fusion of ALS and TLS LiDAR data for robust assessment of tree crown structure. **IEEE Transactions on Geoscience and Remote Sensing**, v. 55, n. 7, p. 3679-3693, 2017.

REIERSEN, G.; DAO, D.; LÜTJENS, B.; KLEMMER, K.; AMARA, K.; STEINEGGER, A.; ZHU, X. ReforesTree: A dataset for estimating tropical forest carbon stock with deep learning and aerial imagery. In: **Proceedings of the AAI Conference on Artificial Intelligence**. 2022. p. 12119-12125.

REN, S.; HE, K.; GIRSHICK, R.; SUN, J. Faster r-cnn: Towards real-time object detection with region proposal networks. **Advances in neural information processing systems**, v. 28, 2015.

REY, N.; VOLPI, M.; JOOST, S.; TUIA, D. Detecting animals in African Savanna with UAVs and the crowds. **Remote Sensing of Environment**, v. 200, p. 341-351, 2017.

ROY, S.; BYRNE, J.; PICKERING, C. A systematic quantitative review of urban tree benefits, costs, and assessment methods across cities in different climatic zones. **Urban forestry & urban greening**, v. 11, n. 4, p. 351-363, 2012.

RULL, V. Neotropical diversification: historical overview and conceptual insights. **Neotropical diversification: Patterns and processes**, p. 13-49, 2020.

SAHEER, L. B.; SHAHAWY, M. Self-supervised approach for urban tree recognition on aerial images. In: **IFIP International Conference on Artificial Intelligence Applications and Innovations**. Cham: Springer International Publishing, 2021. p. 476-486.

SANKEY, T.; DONAGER, J.; MCVAY, J.; SANKEY, J. B. UAV lidar and hyperspectral fusion for forest monitoring in the southwestern USA. **Remote Sensing of Environment**, v. 195, p. 30-43, 2017.

SANTOS, F. G.; CAMARGO, P. B. de; OLIVEIRA JUNIOR, R. C. de. Estoque e dinâmica de biomassa arbórea em Floresta Ombrófila Densa na Flona Tapajós: Amazônia Oriental. **Ciência Florestal**, v. 28, n. 3, p. 1049-1059, 2018.

SATO, H.; KELLEY, D. I.; MAYOR, S. J.; MARTIN CALVO, M.; COWLING, S. A.; PRENTICE, I. C. Dry corridors opened by fire and low CO₂ in Amazonian rainforest during the Last Glacial Maximum. **Nature Geoscience**, v. 14, n. 8, p. 578-585, 2021.

SHAFIQ, M.; GU, Z. Deep residual learning for image recognition: A survey. **Applied Sciences**, v. 12, n. 18, p. 8972, 2022.

SHARMA, N.; SHARMA, R.; JINDAL, N. Machine learning and deep learning applications-a vision. **Global Transitions Proceedings**, v. 2, n. 1, p. 24-28, 2021.

SHI, Z.; HUANG, Y.; HE, Q.; XU, L.; LIU, S.; QIN, L.; ZHAO, L. MSMiner—a developing platform for OLAP. **Decision Support Systems**, v. 42, n. 4, p. 2016-2028, 2007.

SILVA-SOUZA, K. J.; SOUZA, A. F. Woody plant subregions of the Amazon forest. **Journal of Ecology**, v. 108, n. 6, p. 2321-2335, 2020.

SIVANANDAM, P.; LUCIEER, A. Tree Detection and Species Classification in a Mixed Species Forest Using Unoccupied Aircraft System (UAS) RGB and Multispectral Imagery. **Remote Sensing**, v. 14, n. 19, p. 4963, 2022.

TALABANI, H. S. Machine learning-based cloud computing and IOT: A. **International Journal of Cloud Computing and Database Management**. 5(2) 77-84, 2024.

TER STEEGE, H. et al. Hyperdominance in the Amazonian tree flora. **Science**, 342(6156), p.1243092, 2013.

TER STEEGE, H. et al. Estimating the global conservation status of more than 15,000 Amazonian tree species. **Science advances**, v. 1, n. 10, p. e1500936, 2015.

TOLAN, J.; YANG, H. I.; NOSARZEWSKI, B.; COUAIRON, G.; VO, H. V.; BRANDT, J.; COUPRIE, C. Very high resolution canopy height maps from RGB imagery using self-supervised vision transformer and convolutional decoder trained on aerial lidar. **Remote Sensing of Environment**, v. 300, p. 113888, 2024.

VALENTE, D. M. P.; TESTON, J. A. Arctiini Leach,[1815](Lepidoptera, Erebidae, Arctiinae) in a savanna areas of the Environmental Protection Area Alter do Chão, Santarém, Pará, Brazil. **Revista Ciência e Natura**, v. 44, 2022.

VELASCO, E.; ROTH, M.; NORFORD, L.; MOLINA, L. T. Does urban vegetation enhance carbon sequestration?. **Landscape and urban planning**, v. 148, p. 99-107, 2016.

VELASQUEZ-CAMACHO, L.; ETXEGARAI, M.; DE-MIGUEL, S. Implementing Deep Learning algorithms for urban tree detection and geolocation with high-resolution aerial, satellite, and ground-level images. **Computers, Environment and Urban Systems**, v. 105, p. 102025, 2023.

VELOSO, H.P.; RANGEL FILHO, A.L.R.; LIMA, J.C.A. 1991. **Classificação da vegetação brasileira, adaptada a um sistema universal**. IBGE, Rio de Janeiro, Rio de Janeiro. 123pp.

VONGKUSOLKIT, J.; PENG, B.; WU, M.; HUANG, Q.; ANDRESEN, C. G. Near Real-Time Flood Mapping with Weakly Supervised Machine Learning. **Remote Sensing**, v. 15, n. 13, p. 3263, 2023.

WAGNER, F. H. et al. Individual tree crown delineation in a highly diverse tropical forest using very high resolution satellite images. **ISPRS journal of photogrammetry and remote sensing**, v. 145, p. 362-377, 2018.

WAN, J.; LI, B.; WANG, K.; TENG, X.; WANG, T.; MAO, B. An Improved ResNet50 for Environment Image Classification. **Procedia Computer Science**, v. 242, p. 1000-1007, 2024.

WEINSTEIN, B. G.; MARCONI, S.; BOHLMAN, S.; ZARE, A.; WHITE, E. Individual tree-crown detection in RGB imagery using semi-supervised deep learning neural networks. **Remote Sensing**, v. 11, n. 11, p. 1309, 2019.

WEINSTEIN, B. G.; MARCONI, S.; AUBRY-KIENTZ, M.; VINCENT, G.; SENYONDO, H.; WHITE, E. DeepForest: A Python package for RGB deep learning tree crown delineation. **Methods in Ecology and Evolution**, v. 11, n. 12, p. 1743-1751, 2020.

WEINSTEIN, B. G.; GRAVES, S. J.; MARCONI, S.; SINGH, A.; ZARE, A.; STEWART, D.; WHITE, E. P. A benchmark dataset for canopy crown detection and delineation in co-registered airborne RGB, LiDAR and hyperspectral imagery from the National Ecological Observation Network. **PLoS computational biology**, v. 17, n. 7, p. e1009180, 2021a.

WEINSTEIN, B. G.; MARCONI, S.; BOHLMAN, S. A.; ZARE, A.; SINGH, A.; GRAVES, S. J.; WHITE, E. P. A remote sensing derived data set of 100 million individual tree crowns for the National Ecological Observatory Network. **Elife**, v. 10, p. e62922, 2021b.

WEINSTEIN, B. G.; MARCONI, S.; GRAVES, S. J.; ZARE, A.; SINGH, A.; BOHLMAN, S. A.; WHITE, E. P. Capturing long-tailed individual tree diversity using an airborne multi-temporal hierarchical model. **bioRxiv**, p. 2022.12.07.519493, 2022.

WITTMANN, F.; HOUSEHOLDER, E.; PIEDADE, M. T.; DE ASSIS, R. L.; SCHÖNGART, J.; PAROLIN, P.; JUNK, W. J. Habitat specificity, endemism and the neotropical distribution of Amazonian white-water floodplain trees. **Ecography**, v. 36, n. 6, p. 690-707, 2013.

ZHANG, C. Research on the fluctuation and factors of China TFP of IT industry. **Journal of Industrial Integration and Management**, v. 4, n. 04, p. 1950013, 2019.

ZHANG, L.; BIAN, Y.; JIANG, P.; ZHANG, F. A transfer residual neural network based on ResNet-50 for detection of steel surface defects. **Applied Sciences**, v. 13, n. 9, p. 5260, 2023.

ZHOU, H.; XU, J.; LIN, H.; NIE, Z.; ZHENG, L. IndustrialNeRF: Accurate 3D Industrial Digital Twin Based on Integrating Neural Radiance Fields Using Unsupervised Learning. **Applied Sciences**, v. 14, n. 12, p. 5336, 2024.


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.

APÊNDICES


APÊNDICE A - Tempo médio de execução do algoritmo DeepForest em diferentes configurações de hardware.

	Épocas	Alter do Chão menos Densa	Alter do Chão Mais Densa	FLONA TAPAJÓS
PC – RTX 3080	10	00:13:24	00:11:38	00:07:12
	15	00:27:49	00:22:15	00:15:33
	30	00:54:32	00:45:47	00:30:29
Cluster UFOPA (V100)	10	00:07:15	00:06:41	00:04:23
	15	00:18:32	00:15:57	00:10:49
	30	00:39:47	00:34:28	00:23:56
Colab – T4	10	00:25:39	00:20:22	00:14:48
	15	00:46:21	00:36:49	00:25:12
	30	01:29:53	01:11:37	00:50:24
Colab – T4 + RAM	10	00:21:17	00:17:05	00:12:36
	15	00:37:43	00:30:31	00:21:18
	30	01:13:29	00:59:52	00:42:43
Colab – L4	10	00:18:12	00:15:28	00:10:37
	15	00:35:56	00:28:14	00:20:21
	30	01:01:08	00:50:39	00:36:58
Colab – A100	10	00:06:27	00:05:16	00:03:05
	15	00:14:11	00:11:03	00:09:36
	30	00:30:43	00:21:32	00:17:51

APÊNDICE B - Box Plot do resultado de 10 execuções para o Conjunto de dados de Savana mais densa de Alter do Chão em relação ao número de épocas.



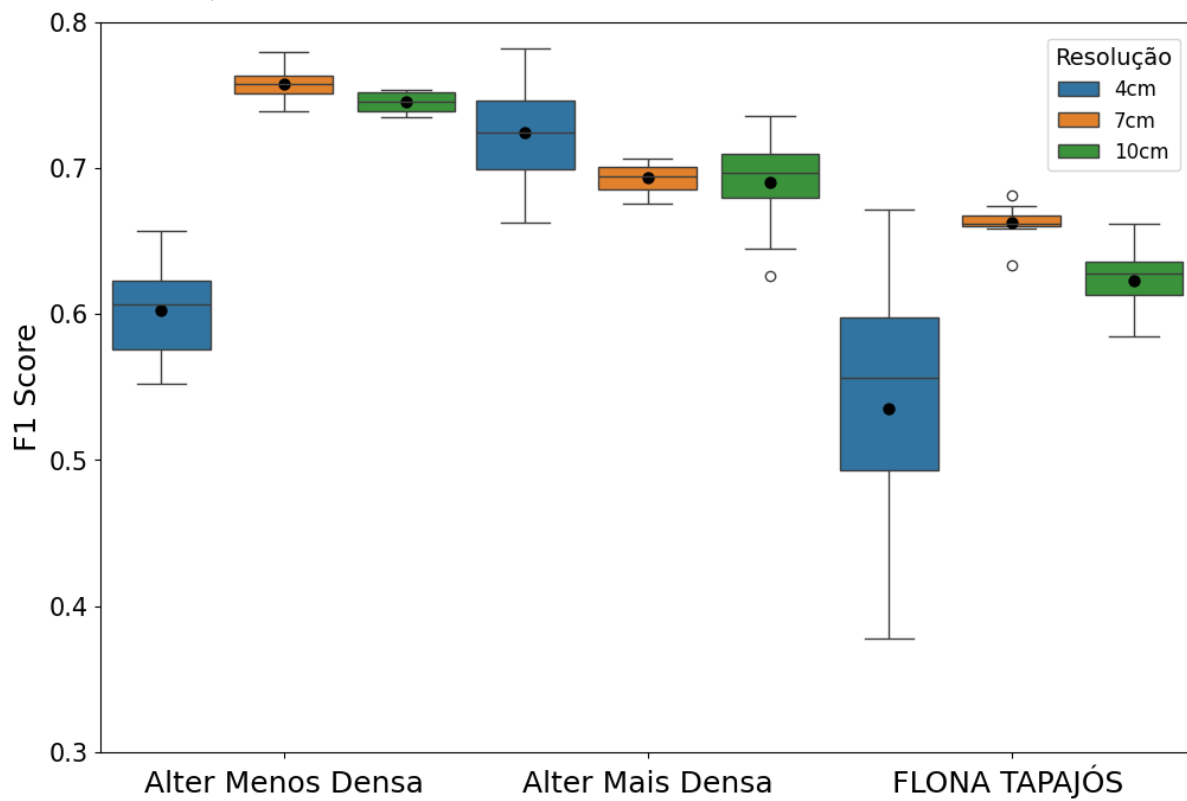
APÊNDICE C - Box Plot do resultado de 10 execuções para o Conjunto de dados da FLONA TAPAJÓS em relação ao número de épocas.



APÊNDICE D – Valores de média, mediana, máximo, mínimo e desvio padrão para *Precision*, *Recall* e *F1 Score* de 10 execuções para os 3 conjuntos de Dados em 3 diferentes resoluções usando 10 épocas.

		Resolução	Média	Mediana	Máximo	Mínimo	Desvio Padrão
<i>Precision</i>	Alter Menos Densa	4cm	0,4385	0,4422	0,4974	0,3865	0,0339
		7cm	0,6252	0,6247	0,6520	0,6028	0,0136
		10cm	0,6604	0,6645	0,6804	0,6384	0,0121
	Alter Mais Densa	4cm	0,5839	0,5855	0,6491	0,5044	0,0443
		7cm	0,6245	0,6243	0,6547	0,5958	0,0152
		10cm	0,5838	0,5978	0,6468	0,5086	0,0427
	FLONA Tapajós	4cm	0,3873	0,4049	0,5221	0,2410	0,0877
		7cm	0,6534	0,6565	0,6773	0,6308	0,0153
		10cm	0,5373	0,5334	0,6155	0,4950	0,0328
<i>Recall</i>	Alter Menos Densa	4cm	0,9651	0,9646	0,9696	0,9586	0,0029
		7cm	0,9619	0,9612	0,9685	0,9542	0,0044
		10cm	0,8551	0,8572	0,8688	0,8251	0,0127
	Alter Mais Densa	4cm	0,9575	0,9577	0,9833	0,9312	0,0172
		7cm	0,7799	0,7797	0,8109	0,7308	0,0243
		10cm	0,8464	0,8526	0,8685	0,8131	0,0187
	FLONA Tapajós	4cm	0,8895	0,8821	0,9409	0,8062	0,0407
		7cm	0,6727	0,6689	0,7204	0,6313	0,0251
		10cm	0,7445	0,7338	0,7988	0,7128	0,0323
<i>F1 Score</i>	Alter Menos Densa	4cm	0,6022	0,6066	0,6568	0,5518	0,0322
		7cm	0,7578	0,7573	0,7794	0,7389	0,0112
		10cm	0,7451	0,7451	0,7539	0,7348	0,0070
	Alter Mais Densa	4cm	0,7245	0,7245	0,7817	0,6626	0,0370
		7cm	0,6932	0,6942	0,7068	0,6755	0,0102
		10cm	0,6901	0,6971	0,7356	0,6258	0,0316
	FLONA Tapajós	4cm	0,5348	0,5562	0,6716	0,3773	0,0937
		7cm	0,6625	0,6621	0,6810	0,6333	0,0118
		10cm	0,6232	0,6281	0,6622	0,5846	0,0219


APÊNDICE E – Box Plot do resultado de F1 Score de 10 execuções em 3 diferentes resoluções usando 10 épocas para o Conjunto de dados de Alter Menos Densa, Mais densa e FLONA TAPAJÓS.



APÊNDICE F – Valores de média, mediana, máximo, mínimo e desvio padrão para Precision, Recall e F1 Score de 10 execuções para os 3 conjuntos de Dados em 3 diferentes resoluções usando 15 épocas.

		Resolução	Média	Mediana	Máximo	Mínimo	Desvio Padrão
<i>Precision</i>	Alter Menos Densa	4cm	0,5034	0,4929	0,5962	0,4457	0,0473
		7cm	0,7542	0,7555	0,7739	0,7287	0,0134
		10cm	0,6931	0,6865	0,7263	0,6734	0,0173
	Alter Mais Densa	4cm	0,6539	0,6592	0,7674	0,5070	0,0712
		7cm	0,6701	0,6788	0,7135	0,6320	0,0284
		10cm	0,6001	0,5972	0,6333	0,5744	0,0208
	FLONA Tapajós	4cm	0,4827	0,4559	0,6295	0,3721	0,0794
		7cm	0,6950	0,6958	0,7158	0,6775	0,0106
		10cm	0,6054	0,6067	0,6439	0,5512	0,0245
<i>Recall</i>	Alter Menos Densa	4cm	0,9779	0,9788	0,9910	0,9605	0,0083
		7cm	0,8214	0,8192	0,8355	0,8141	0,0073
		10cm	0,8865	0,8862	0,8971	0,8749	0,0076
	Alter Mais Densa	4cm	0,9843	0,9890	0,9949	0,9607	0,0112
		7cm	0,8040	0,8063	0,8587	0,7629	0,0262
		10cm	0,8810	0,8873	0,9037	0,8284	0,0220
	FLONA Tapajós	4cm	0,9305	0,9352	0,9680	0,8774	0,0299
		7cm	0,6821	0,6827	0,7083	0,6566	0,0164
		10cm	0,7728	0,7737	0,8076	0,7025	0,0278
<i>F1 Score</i>	Alter Menos Densa	4cm	0,6633	0,6548	0,7424	0,6118	0,0407
		7cm	0,7862	0,7881	0,7938	0,7752	0,0062
		10cm	0,7778	0,7735	0,7993	0,7662	0,0106
	Alter Mais Densa	4cm	0,7836	0,7871	0,8657	0,6680	0,0538
		7cm	0,7301	0,7295	0,7567	0,7107	0,0125
		10cm	0,7134	0,7090	0,7328	0,7017	0,0104
	FLONA Tapajós	4cm	0,6329	0,6106	0,7625	0,5276	0,0730
		7cm	0,6884	0,6883	0,7031	0,6726	0,0099
		10cm	0,6781	0,6808	0,6954	0,6529	0,0115

APÊNDICE G – Box Plot do resultado de F1 Score de 10 execuções em 3 diferentes resoluções usando 15 épocas para o Conjunto de dados de Alter Menos Densa, Mais densa e FLONA TAPAJÓS.



APÊNDICE H – Valores de *Precision*, *Recall* e *F1 Score* de 10 execuções em três diferentes quantidades de épocas (10, 15 e 30) para APA Alter do Chão Menos Densa com 4cm de resolução.

10 Épocas				15 Épocas				30 Épocas			
Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>	Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>	Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>
1	0,4630	0,9637	0,6255	1	0,4893	0,9867	0,6542	1	0,7408	0,9935	0,8487
2	0,3865	0,9644	0,5518	2	0,5962	0,9834	0,7424	2	0,7168	0,9938	0,8329
3	0,4377	0,9678	0,6028	3	0,5004	0,9729	0,6609	3	0,6792	0,9940	0,8070
4	0,4209	0,9586	0,5850	4	0,5489	0,9910	0,7065	4	0,6926	0,9927	0,8159
5	0,4466	0,9636	0,6103	5	0,4613	0,9813	0,6275	5	0,7559	0,9931	0,8584
6	0,4765	0,9696	0,6390	6	0,4477	0,9774	0,6141	6	0,7496	0,9921	0,8540
7	0,3965	0,9676	0,5625	7	0,5584	0,9605	0,7062	7	0,7198	0,9935	0,8348
8	0,4076	0,9643	0,5730	8	0,4457	0,9754	0,6118	8	0,7644	0,9926	0,8637
9	0,4974	0,9663	0,6568	9	0,4921	0,9801	0,6552	9	0,7329	0,9929	0,8433
10	0,4523	0,9647	0,6158	10	0,4938	0,9698	0,6544	10	0,7448	0,9948	0,8518

APÊNDICE I – Valores de *Precision*, *Recall* e *F1 Score* de 10 execuções em três diferentes quantidades de épocas (10, 15 e 30) para APA Alter do Chão Menos Densa com 7cm de resolução.

10 Épocas			15 Épocas				30 Épocas				
Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>	Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>	Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>
1	0,6520	0,9685	0,7794	1	0,7647	0,8157	0,7894	1	0,8021	0,8400	0,8206
2	0,6239	0,9596	0,7561	2	0,7287	0,8281	0,7752	2	0,8263	0,8479	0,8370
3	0,6225	0,9592	0,7550	3	0,7350	0,8216	0,7759	3	0,8165	0,8381	0,8272
4	0,6103	0,9591	0,7459	4	0,7502	0,8314	0,7887	4	0,8243	0,8343	0,8293
5	0,6327	0,9638	0,7639	5	0,7589	0,8181	0,7874	5	0,8354	0,8462	0,8408
6	0,6028	0,9542	0,7389	6	0,7500	0,8355	0,7904	6	0,8175	0,8421	0,8296
7	0,6155	0,9580	0,7495	7	0,7605	0,8142	0,7864	7	0,8272	0,8457	0,8363
8	0,6259	0,9671	0,7600	8	0,7677	0,8202	0,7931	8	0,8230	0,8565	0,8394
9	0,6405	0,9665	0,7705	9	0,7739	0,8146	0,7938	9	0,8263	0,8652	0,8453
10	0,6256	0,9628	0,7584	10	0,7522	0,8141	0,7820	10	0,8239	0,8481	0,8358

APÊNDICE J – Valores de *Precision*, *Recall* e *F1 Score* de 10 execuções em três diferentes quantidades de épocas (10, 15 e 30) para APA Alter do Chão Menos Densa com 10cm de resolução.

10 Épocas				15 Épocas				30 Épocas			
Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>	Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>	Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>
1	0,6512	0,8517	0,7381	1	0,6837	0,8830	0,7707	1	0,7617	0,9158	0,8317
2	0,6642	0,8596	0,7494	2	0,6767	0,8831	0,7662	2	0,7568	0,9123	0,8273
3	0,6706	0,8251	0,7399	3	0,7019	0,8892	0,7846	3	0,7579	0,9171	0,8299
4	0,6492	0,8627	0,7409	4	0,6855	0,8941	0,7760	4	0,7238	0,9067	0,8050
5	0,6804	0,8417	0,7525	5	0,6788	0,8898	0,7701	5	0,7610	0,9187	0,8325
6	0,6647	0,8688	0,7532	6	0,6962	0,8796	0,7772	6	0,7474	0,9115	0,8213
7	0,6686	0,8544	0,7502	7	0,7207	0,8970	0,7993	7	0,7405	0,9100	0,8166
8	0,6496	0,8548	0,7382	8	0,7263	0,8749	0,7937	8	0,7679	0,9261	0,8396
9	0,6669	0,8669	0,7539	9	0,6876	0,8777	0,7711	9	0,7792	0,9318	0,8487
10	0,6384	0,8655	0,7348	10	0,6734	0,8971	0,7693	10	0,7698	0,9187	0,8377

APÊNDICE K – Valores de *Precision*, *Recall* e *F1 Score* de 10 execuções em três diferentes quantidades de épocas (10, 15 e 30) para APA Alter do Chão Mais Densa com 4cm de resolução.

10 Épocas				15 Épocas				30 Épocas			
Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>	Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>	Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>
1	0,6491	0,9823	0,7817	1	0,5070	0,9790	0,6680	1	0,7860	0,9935	0,8776
2	0,5658	0,9581	0,7115	2	0,6100	0,9947	0,7562	2	0,8275	0,9925	0,9025
3	0,5816	0,9700	0,7272	3	0,6905	0,9842	0,8116	3	0,8341	0,9925	0,9064
4	0,5536	0,9338	0,6951	4	0,7674	0,9929	0,8657	4	0,8509	0,9893	0,9149
5	0,5316	0,9464	0,6808	5	0,5964	0,9890	0,7441	5	0,8098	0,9947	0,8928
6	0,5044	0,9653	0,6626	6	0,7089	0,9949	0,8279	6	0,8535	0,9926	0,9178
7	0,6019	0,9573	0,7391	7	0,7182	0,9914	0,8330	7	0,8636	0,9921	0,9234
8	0,5894	0,9312	0,7218	8	0,6221	0,9607	0,7552	8	0,8735	0,9917	0,9289
9	0,6180	0,9476	0,7481	9	0,6858	0,9674	0,8026	9	0,7610	0,9920	0,8612
10	0,6433	0,9833	0,7778	10	0,6326	0,9890	0,7716	10	0,8156	0,9925	0,8954

APÊNDICE L – Valores de *Precision*, *Recall* e *F1 Score* de 10 execuções em três diferentes quantidades de épocas (10, 15 e 30) para APA Alter do Chão Mais Densa com 7cm de resolução.

10 Épocas			15 Épocas				30 Épocas				
Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>	Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>	Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>
1	0,6357	0,7959	0,7068	1	0,6880	0,7727	0,7279	1	0,7490	0,9835	0,8504
2	0,6346	0,7308	0,6793	2	0,6942	0,7629	0,7269	2	0,7293	0,9872	0,8389
3	0,5958	0,7798	0,6755	3	0,6450	0,8128	0,7192	3	0,6699	0,9825	0,7967
4	0,6194	0,7627	0,6837	4	0,7135	0,8056	0,7567	4	0,6996	0,9831	0,8175
5	0,6080	0,8109	0,6949	5	0,6846	0,8071	0,7408	5	0,6680	0,9859	0,7964
6	0,6547	0,7535	0,7006	6	0,6972	0,7824	0,7373	6	0,6881	0,9882	0,8113
7	0,6196	0,8063	0,7007	7	0,6396	0,8587	0,7331	7	0,7029	0,9887	0,8217
8	0,6283	0,8036	0,7053	8	0,6338	0,8087	0,7107	8	0,7898	0,9854	0,8768
9	0,6270	0,7758	0,6935	9	0,6730	0,8005	0,7312	9	0,7091	0,9878	0,8256
10	0,6216	0,7796	0,6917	10	0,6320	0,8289	0,7172	10	0,6741	0,9884	0,8016

APÊNDICE M – Valores de *Precision*, *Recall* e *F1 Score* de 10 execuções em três diferentes quantidades de épocas (10, 15 e 30) para APA Alter do Chão Mais Densa com 10cm de resolução.

10 Épocas			15 Épocas			30 Épocas					
Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>	Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>	Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>
1	0,6468	0,8527	0,7356	1	0,5981	0,8643	0,7070	1	0,6783	0,9118	0,7779
2	0,6105	0,8447	0,7088	2	0,5750	0,9003	0,7017	2	0,6712	0,9169	0,7750
3	0,6164	0,8364	0,7098	3	0,5847	0,9015	0,7093	3	0,6543	0,9244	0,7662
4	0,6051	0,8139	0,6941	4	0,5864	0,8946	0,7084	4	0,6428	0,9122	0,7542
5	0,5904	0,8596	0,7000	5	0,6258	0,8840	0,7328	5	0,6887	0,9114	0,7846
6	0,6171	0,8567	0,7174	6	0,5963	0,8905	0,7143	6	0,6750	0,9127	0,7761
7	0,5550	0,8685	0,6773	7	0,6286	0,8744	0,7314	7	0,6876	0,9197	0,7869
8	0,5693	0,8658	0,6869	8	0,5744	0,9037	0,7023	8	0,6526	0,9093	0,7598
9	0,5189	0,8525	0,6451	9	0,5982	0,8688	0,7086	9	0,6489	0,9020	0,7548
10	0,5086	0,8131	0,6258	10	0,6333	0,8284	0,7178	10	0,6554	0,9116	0,7626

APÊNDICE N – Valores de *Precision*, *Recall* e *F1 Score* de 10 execuções em três diferentes quantidades de épocas (10, 15 e 30) para FLONA TAPAJÓS com 4cm de resolução.

10 Épocas				15 Épocas				30 Épocas			
Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>	Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>	Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>
1	0,4222	0,8784	0,5703	1	0,6295	0,9666	0,7625	1	0,7852	0,9770	0,8706
2	0,4484	0,9407	0,6073	2	0,3721	0,9062	0,5276	2	0,6763	0,9784	0,7998
3	0,3358	0,8858	0,4869	3	0,4561	0,9214	0,6102	3	0,6615	0,9808	0,7901
4	0,4135	0,8764	0,5619	4	0,5651	0,9584	0,7110	4	0,6978	0,9749	0,8134
5	0,5221	0,9409	0,6716	5	0,5945	0,9680	0,7366	5	0,6151	0,9770	0,7549
6	0,2410	0,8686	0,3773	6	0,4211	0,8909	0,5719	6	0,7305	0,9858	0,8391
7	0,3963	0,9015	0,5505	7	0,4336	0,9459	0,5947	7	0,6133	0,9846	0,7558
8	0,3734	0,8062	0,5104	8	0,4583	0,9428	0,6168	8	0,6951	0,9715	0,8104
9	0,2431	0,8578	0,3788	9	0,4408	0,8774	0,5868	9	0,6188	0,9771	0,7577
10	0,4768	0,9389	0,6325	10	0,4556	0,9275	0,6111	10	0,6662	0,9764	0,7920

APÊNDICE O – Valores de *Precision*, *Recall* e *F1 Score* de 10 execuções em três diferentes quantidades de épocas (10, 15 e 30) para FLONA TAPAJÓS com 7cm de resolução.

10 Épocas				15 Épocas				30 Épocas			
Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>	Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>	Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>
1	0,6678	0,6524	0,6600	1	0,6944	0,7017	0,6980	1	0,7110	0,7852	0,7462
2	0,6486	0,6742	0,6611	2	0,6924	0,6689	0,6804	2	0,7169	0,7627	0,7391
3	0,6308	0,6887	0,6585	3	0,7158	0,6656	0,6898	3	0,7268	0,7911	0,7576
4	0,6624	0,7006	0,6810	4	0,6775	0,6678	0,6726	4	0,7364	0,7847	0,7598
5	0,6773	0,6553	0,6661	5	0,6996	0,6947	0,6971	5	0,6864	0,7902	0,7347
6	0,6652	0,6553	0,6602	6	0,6783	0,6878	0,6830	6	0,6754	0,7716	0,7203
7	0,6506	0,6852	0,6675	7	0,6955	0,6566	0,6755	7	0,6976	0,7647	0,7296
8	0,6354	0,6313	0,6333	8	0,6961	0,6777	0,6868	8	0,7077	0,7640	0,7348
9	0,6333	0,7204	0,6741	9	0,6979	0,7083	0,7031	9	0,7004	0,7930	0,7439
10	0,6624	0,6636	0,6630	10	0,7025	0,6920	0,6973	10	0,7299	0,7976	0,7622

APÊNDICE P – Valores de *Precision*, *Recall* e *F1 Score* de 10 execuções em três diferentes quantidades de épocas (10, 15 e 30) para FLONA TAPAJÓS com 10cm de resolução.

10 Épocas				15 Épocas				30 Épocas			
Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>	Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>	Execução	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>
1	0,5516	0,7128	0,6219	1	0,5978	0,7685	0,6725	1	0,6303	0,7870	0,7000
2	0,6155	0,7165	0,6622	2	0,6180	0,7617	0,6823	2	0,6961	0,8048	0,7465
3	0,5201	0,7539	0,6155	3	0,5910	0,8076	0,6825	3	0,6948	0,8044	0,7456
4	0,5618	0,7366	0,6374	4	0,6066	0,7938	0,6877	4	0,6748	0,8256	0,7426
5	0,5362	0,7128	0,6121	5	0,5869	0,7759	0,6683	5	0,6769	0,8221	0,7425
6	0,5271	0,7988	0,6351	6	0,6259	0,7632	0,6878	6	0,6465	0,8367	0,7294
7	0,4977	0,7311	0,5922	7	0,5512	0,8006	0,6529	7	0,6513	0,7908	0,7143
8	0,4950	0,7140	0,5846	8	0,6068	0,7714	0,6793	8	0,6545	0,8127	0,7251
9	0,5305	0,7956	0,6366	9	0,6439	0,7025	0,6719	9	0,6781	0,8216	0,7430
10	0,5380	0,7725	0,6343	10	0,6257	0,7826	0,6954	10	0,6695	0,8086	0,7325

ANEXOS

ANEXO A - Trabalho publicado no congresso: XXVI Encontro Nacional de Modelagem Computacional e XIV Encontro de Ciência e Tecnologia dos Materiais – 2023.

XXVI ENMC, XIV ECTM
25 a 27 de outubro de 2023



IDENTIFICAÇÃO DE COPAS DE ÁRVORES EM IMAGENS AÉREAS USANDO DEEP LEARNING

Jefferson Rossy Pereira da Silva^{1,2} – j.rossy95@gmail.com

Célia Yasmin Sousa Pereira¹ – celia.pereira@discente.ufopa.edu.br

Christiano Jorge Gomes Pinheiro³ – christiano.pinheiro@ufes.br

Kemuel Maciel Freitas^{1,2} – kemuel.macielf@gmail.com

Gilson Fernandes da Silva³ – fernandes5012@gmail.com

Anderson Alvarenga de Moura Meneses^{1,2} – anderson.meneses@ufopa.edu.br

¹ Universidade Federal do Oeste do Pará, Laboratório de Inteligência Computacional – Santarém, PA, Brasil

² Universidade Federal do Oeste do Pará, Programa de Pós-Graduação em Recursos Naturais da Amazônia, Instituto de Engenharia e Geociências – Santarém, PA, Brasil

³ Universidade Federal do Espírito Santo – Alegre, ES, Brasil

Resumo. A detecção de árvores individuais e sua quantificação é uma etapa importante na ecologia, sendo fundamental para o manejo de florestas, e vem sendo um desafio automatizar esse processo. O objetivo deste trabalho foi analisar a detecção de árvores com Deep Learning em imagens aéreas RGB. Foi realizado um estudo de caso, utilizando um conjunto de dados existente do San Joaquin Experimental Range localizado nos Estados Unidos, para avaliação do modelo DeepForest. O conjunto de dados possui 91 imagens no formato tiff de 1km² com resolução espacial de 10cm/pixel. Foram utilizadas para treinamento dos modelos 10, 15 e 30 épocas. Os modelos foram avaliados utilizando o Recall, Precision e F1 Score, sendo obtido as estatísticas descritivas oriundas das 30 execuções cada. Os resultados obtidos mostram um aumento de Recall, Precision e F1 score conforme aumenta-se o número de épocas, contudo é observado um decréscimo desses valores quando utilizamos 30 épocas. Foi realizado o teste de Kruskal-Wallis e Dunn, havendo diferença estatisticamente significativa entre os números de épocas utilizados, sendo 15 épocas a melhor opção. O modelo DeepForest demonstra ser uma abordagem eficaz de detecção de árvores.

Palavras-chave: DeepForest, Aprendizado por Transferência, Sensoriamento Remoto, RGB.