

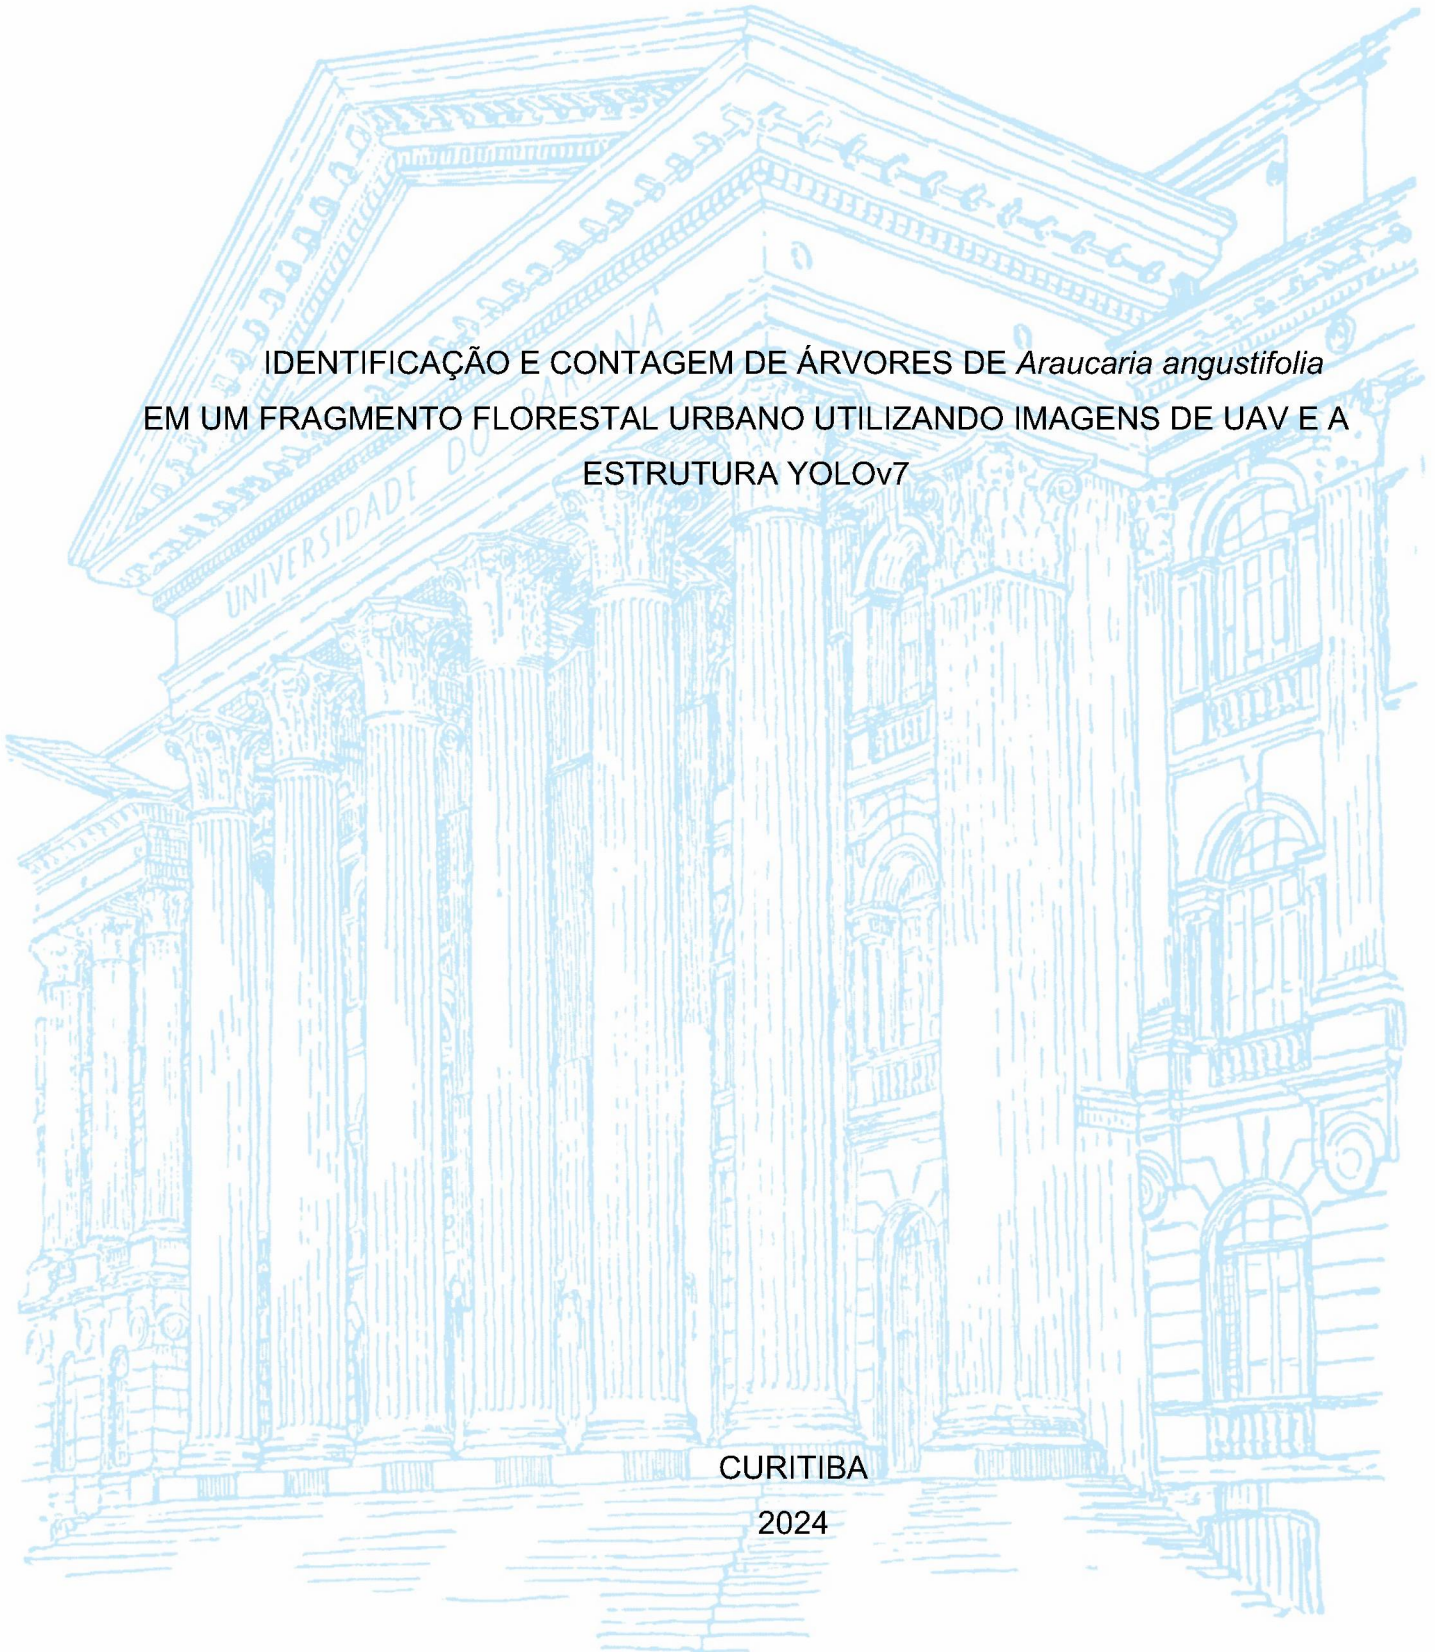
UNIVERSIDADE FEDERAL DO PARANÁ

ALAN D'OLIVEIRA CORREA

IDENTIFICAÇÃO E CONTAGEM DE ÁRVORES DE *Araucaria angustifolia*
EM UM FRAGMENTO FLORESTAL URBANO UTILIZANDO IMAGENS DE UAV E A
ESTRUTURA YOLOV7

CURITIBA

2024



ALAN D'OLIVEIRA CORREA

IDENTIFICAÇÃO E CONTAGEM DE ÁRVORES DE *Araucaria angustifolia*
EM UM FRAGMENTO FLORESTAL URBANO UTILIZANDO IMAGENS DE UAV E A
ESTRUTURA YOLOv7

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

Orientador: Prof. Dr. Allan Libanio Pelissari

Coorientador: Prof. Dr. Vinicius da Costa Cysneiros

CURITIBA

2024

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

Correa, Alan D'Oliveira

Identificação e contagem de árvores de Araucaria angustifolia em um fragmento florestal urbano utilizando imagens de UAV e a estrutura YOLOv7 / Alan D'Oliveira Correa. - Curitiba, 2024.

1 recurso on-line : PDF

Orientador: Prof. Dr. Allan Libanio Pelissari

Coorientador: Prof. Dr. Vinicius da Costa Cysneiros

Dissertação (Mestrado) - Universidade Federal do Paraná, Setor de Ciências Agrárias. Programa de Pós-Graduação em Engenharia Florestal. Defesa: Curitiba, 02/08/2024.

1. Florestas urbanas - Curitiba (PR). 2. Araucaria angustifolia - Identificação. 3. Araucaria angustifolia - Medição. 4. Levantamentos florestais. 5. Imagens de sensoriamento remoto. 6. Visão por computador. 7. Redes neurais (Computação). 8. Drone. I. Pelissari, Alan Libanio. II. Cysneiros, Vinicius da Costa. III. Universidade Federal do Paraná, Setor de Ciências Agrárias. IV. Título.

CDD - 634.9
621.367809152
CDU - 634.0.524.6
528.8

Bibliotecária: Marilene do Rocio Veiga - CRB9/424



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

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação ENGENHARIA FLORESTAL da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **ALAN D'OLIVEIRA CORREA** intitulada: **IDENTIFICAÇÃO E CONTAGEM DE ÁRVORES DE *Araucaria angustifolia* EM UM FRAGMENTO FLORESTAL URBANO, UTILIZANDO IMAGENS DE UAV E A ESTRUTURA YOLOv7**, sob orientação do Prof. Dr. ALLAN LIBANIO PELISSARI, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

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

CURITIBA, 02 de Agosto de 2024.

ALLAN LIBANIO PELISSARI

Presidente da Banca Examinadora

JONATHAN WILLIAM TRAUTENMÜLLER

Avaliador Externo (UNIVERSIDADE FEDERAL DO PARANÁ)

ANGELO AUGUSTO EBLING

Avaliador Externo (UNIVERSIDADE FEDERAL DO MATO GROSSO)

Dedico este trabalho aos meus pais, Iracema e Orlando.

AGRADECIMENTOS

Aos meus pais, pelo apoio incondicional em todas as minhas decisões, tanto no aspecto financeiro quanto emocional.

Ao meu grande amigo Matheus Kopp Prandini, pelo companheirismo e constante apoio ao longo desta jornada.

À Universidade Federal do Paraná (UFPR), pela oportunidade de realizar minha graduação e pós-graduação, proporcionando um ambiente de aprendizado e crescimento.

Ao meu orientador, Prof. Dr. Allan Libanio Pelissari, pela orientação, acompanhamento e amizade; e ao meu coorientador, Prof. Dr. Vinicius Costa Cysneiros, pela valiosa contribuição e suporte.

Aos colegas do Laboratório de Manejo Florestal, pelo espírito de equipe e colaboração.

Ao Vinicius Henrique Gris, pela disponibilização do drone e pela ajuda essencial na captura das imagens da área de estudo.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo apoio financeiro indispensável para a realização deste trabalho.

Por fim, agradeço a todos que, de forma direta ou indireta, contribuíram para a concretização deste trabalho.

“Nem pensa, só vai!” (Brendon Bressan)

RESUMO

As florestas urbanas são essenciais para a conservação da biodiversidade local e o bem-estar humano, mas enfrenta desafios devido à expansão urbana e à conversão do uso da terra para agricultura. Algumas espécies nativas, como a *Araucaria angustifolia*, estão criticamente ameaçadas, exigindo ações e estratégias para sua conservação. O objetivo deste estudo foi utilizar imagens de Veículo Aéreo Não Tripulado (VANT) e a técnica de visão computacional do modelo YOLOv7 para a identificação e contagem de indivíduos de *A. angustifolia* em um fragmento de floresta urbana, especificamente na Floresta Ombrófila Mista (FOM), em Curitiba, Paraná, Brasil. O YOLOv7, consiste numa arquitetura baseada em Redes Neurais Convolucionais (CNNs), foi escolhido por sua capacidade de detecção. O YOLOv7 é especialmente eficaz na detecção de uma ampla variedade de objetos, incluindo pessoas, veículos, animais, objetos domésticos, placas de sinalização e muito mais, tornando-o uma escolha ideal para identificar espécies de árvores em ambientes urbanos. Os dados foram obtidos por um VANT DJI Mavic 3, com o qual a área de estudo da floresta urbana foi sobrevoada, gerando uma ortomosaico que foi posteriormente dividido em 14 partes para treinamento, validação e teste. O modelo YOLOv7 foi treinado com as imagens para detectar árvores de *A. angustifolia* presentes na área. Além disso, no âmbito da investigação de métodos de predição do DAP da *A. angustifolia* com base na área da copa, utilizando modelos de regressão linear, foi realizado um estudo comparativo dos modelos propostos. Os resultados mostram que o modelo alcançou uma precisão de 79,3% (proporção de detecções corretas entre todas as detecções feitas), recall de 86,8% (capacidade de identificar corretamente todas as instâncias positivas) e precisão média de 87% (média da precisão para várias classes e limiares de confiança) durante o treinamento. A pontuação F1, que combina as medidas de precisão e recall em um único valor, evidenciou um valor médio de 77,16%, com 91,01% das imagens obtendo valores superiores a 60%. A análise comparativa com dados de inventário florestal revela desempenho promissor na detecção de árvores de *A. angustifolia*. A confiança média da classificação do modelo foi de $76,18 \pm 12,88\%$. Essa abordagem fornece uma ferramenta importante para estratégias de conservação voltadas para avaliar e gerenciar a biodiversidade de árvores em remanescentes de florestas urbanas. A análise comparativa dos modelos revelou que o modelo logarítmico atendeu

adequadamente às suposições da regressão linear, demonstrando linearidade, homocedasticidade, normalidade dos resíduos e independência dos resíduos. A integração da tecnologia de VANT, modelo YOLOv7 e aprendizado profundo (CNNs) mostrou-se eficaz para detecção e quantificação de árvores, essencial para a conservação da biodiversidade em remanescentes de florestas urbanas.

Palavras-chave: YOLO; detecção de árvores; ecossistemas urbanos.

ABSTRACT

Urban forests are essential for the conservation of local biodiversity and human well-being, but they face challenges due to urban expansion and land-use conversion for agriculture. Some native species, such as *Araucaria angustifolia*, are critically endangered, requiring actions and strategies for their conservation. The objective of this study was to use Unmanned Aerial Vehicle (UAV) imagery and the YOLOv7 model computer vision technique to identify and count *A. angustifolia* individuals in an urban forest fragment, specifically in the Mixed Ombrophilous Forest (MOF) in Curitiba, Paraná, Brazil. YOLOv7, which is based on a Convolutional Neural Network (CNN) architecture, was chosen for its detection capabilities. YOLOv7 is especially effective in detecting a wide range of objects, including people, vehicles, animals, household items, and traffic signs, making it an ideal choice for identifying tree species in urban environments. The data were collected using a DJI Mavic 3 UAV, which flew over the urban forest study area, generating an orthomosaic that was later divided into 14 parts for training, validation, and testing. The YOLOv7 model was trained with the images to detect *A. angustifolia* trees present in the area. Furthermore, as part of the investigation into predicting the DBH of *A. angustifolia* based on canopy area, using linear regression models, a comparative study of the proposed models was conducted. The results show that the model achieved an accuracy of 79.3% (the proportion of correct detections among all detections made), a recall of 86.8% (the ability to correctly identify all positive instances), and an average precision of 87% (the mean precision across multiple classes and confidence thresholds) during training. The F1 score, which combines precision and recall into a single value, had an average of 77.16%, with 91.01% of images scoring above 60%. Comparative analysis with forest inventory data reveals promising performance in detecting *A. angustifolia* trees. The model's average classification confidence was $76.18 \pm 12.88\%$. This approach provides an important tool for conservation strategies aimed at assessing and managing tree biodiversity in urban forest remnants. The comparative analysis of the models revealed that the logarithmic model adequately met the assumptions of linear regression, demonstrating linearity, homoscedasticity, normality of residuals, and independence of residuals. The integration of UAV technology, the YOLOv7 model, and deep learning (CNNs) proved effective for tree detection and quantification, essential for biodiversity conservation in urban forest remnants.

Keywords: YOLO; tree detection; urban ecosystems.

LISTA DE FIGURAS

FIGURA 1 - LOCALIZAÇÃO DA ÁREA DE ESTUDO EM UM FRAGMENTO DE FLORESTA OMBRÓFILA MISTA, CURITIBA, PARANÁ, BRASIL ...	33
FIGURA 2 - DIVISÃO DO ORTOMOSAICO DA ÁREA DE ESTUDO EM FRAGMENTOS MENORES NO QGIS PARA PROCESSAMENTO E TREINAMENTO DO MODELO YOLOV7 NO ROBOFLOW, EM UM FRAGMENTO DE FLORESTA OMBRÓFILA MISTA, CURITIBA, PR	34
FIGURA 3 - PROCEDIMENTO DE ROTULAÇÃO DAS IMAGENS, TREINAMENTO, VALIDAÇÃO E TESTE DO MODELO YOLOV7 PARA DETECÇÃO DE <i>Araucaria angustifolia</i> EM FRAGMENTOS DE FLORESTA OMBRÓFILA MISTA, CURITIBA, PR	37
FIGURA 4 - MATRIZ DE CONFUSÃO DO MODELO YOLOV7	40
FIGURA 5 - FLUXOGRAMA DA METODOLOGIA.....	41
FIGURA 6 - DESEMPENHO DO MODELO YOLOV7 EM RELAÇÃO À MÉTRICA MAP DURANTE OS PERÍODOS DE TREINAMENTO	46
FIGURA 7 - CURVAS DE DESEMPENHO DO MODELO YOLOV7 DURANTE AS ETAPAS DE TREINAMENTO E VALIDAÇÃO.....	47
FIGURA 8 - PONTUAÇÃO F1 DO MODELO YOLOV7 PARA DETECÇÃO DE <i>A. angustifolia</i>	48
FIGURA 9 - ESTATÍSTICAS DESCRITIVAS PARA ERRO MÍNIMO, ÁREA DA COPA E DAP	49
FIGURA 10 – RESULTADOS DA CLASSIFICAÇÃO DO MODELO YOLOV7 NA IDENTIFICAÇÃO DE ÁRVORES DE <i>Araucaria angustifolia</i> EM UMA FLORESTA URBANA EM CURITIBA, PARANÁ, BRASIL	49
FIGURA 11 – GRÁFICOS DOS RESÍDUOS ESTUDENTIZADOS EM RELAÇÃO AOS VALORES ESTIMADOS DOS MODELOS DE REGRESSÃO PARA A PREDIÇÃO DO DAP DE <i>Araucaria angustifolia</i> EM FRAGMENTOS DE FLORESTA OMBRÓFILA MISTA, CURITIBA, PR	51
FIGURA 12 – GRÁFICOS QUANTIL-QUANTIL (Q-Q) PARA AVALIAÇÃO DA NORMALIDADE DOS RESÍDUOS DOS MODELOS DE REGRESSÃO NA PREDIÇÃO DO DAP DE <i>Araucaria angustifolia</i> EM	

FRAGMENTOS DE FLORESTA OMBRÓFILA MISTA, CURITIBA, PR
..... 52

FIGURA 13 – MODELOS DE REGRESSÃO LOGARÍTMICA E PARABÓLICA PARA
A RELAÇÃO ENTRE O DAP E A ÁREA DA COPA DE *Araucaria*
angustifolia EM FRAGMENTOS DE FLORESTA OMBRÓFILA MISTA,
CURITIBA, PR 53

LISTA DE TABELAS

TABELA 1 - MODELOS ESTATÍSTICOS DE REGRESSÃO AJUSTADOS PARA A ESTIMATIVA DO DAP (DIÂMETRO À ALTURA DO PEITO) DE ÁRVORES DE <i>Araucaria angustifolia</i> A PARTIR DA ÁREA DE COPA EM FRAGMENTOS DE FLORESTA OMBRÓFILA MISTA, CURITIBA, PR.....	41
TABELA 2 - MODELOS DE REGRESSÃO AJUSTADOS PARA A PREDIÇÃO DO DAP DE <i>Araucaria angustifolia</i> COM BASE NA ÁREA DA COPA, EM FRAGMENTOS DE FLORESTA OMBRÓFILA MISTA, CURITIBA, PR	50

SUMÁRIO

1 INTRODUÇÃO	16
1.1 OBJETIVOS	18
1.1.1 Objetivo geral	18
1.1.2 Objetivos específicos	18
2 REVISÃO DE LITERATURA	20
2.1 MATA ATLÂNTICA.....	20
2.2 FRAGMENTOS FLORESTAIS URBANOS	21
2.3 FLORESTA OMBRÓFILA MISTA	22
2.4 MONITORAMENTO E IDENTIFICAÇÃO DE ESPÉCIES EM FLORESTAS NATIVAS	23
2.5 APRENDIZADO DE MÁQUINA.....	25
2.6 APRENDIZADO PROFUNDO (<i>DEEP LEARNING</i>)	26
2.7 REDES NEURAS CONVOLUCIONAIS	27
2.8 <i>KERNELS</i> CONVOLUCIONAIS	28
2.9 OPERAÇÕES DE CONVOLUÇÃO EM REDES NEURAS CONVOLUCIONAIS	29
2.10 FUNÇÕES DE ATIVAÇÃO EM REDES NEURAS CONVOLUCIONAIS	29
2.11 YOLO - UMA EVOLUÇÃO NA DETECÇÃO DE OBJETOS	30
3 METODOLOGIA	32
3.1 ÁREA DE ESTUDO.....	32
3.2 OBTENÇÃO DOS DADOS.....	33
3.3 TREINAMENTO DO MODELO	35
3.4 GEORREFERENCIAMENTO DAS IMAGENS.....	37
3.5 DESCRIÇÃO DOS DADOS DE CAMPO E COMPARAÇÃO COM O MODELO	38
3.6 MÉTRICAS DE DESEMPENHO DO MODELO	38
3.7 MODELAGEM DO DAP DAS ÁRVORES DE <i>A. angustifolia</i> POR MEIO DA ÁREA DA COPA OBTIDA PELO YOLOV7	41
4 RESULTADOS	46
4.1 DESEMPENHO DO MODELO.....	46
4.2 AVALIAÇÃO E COMPARAÇÃO DOS MODELOS DE REGRESSÃO	50
5 DISCUSSÃO	54
6 CONCLUSÃO	57
REFERÊNCIAS	58

1 INTRODUÇÃO

Os fragmentos florestais urbanos são remanescentes de florestas nativas que sofreram alterações devido às atividades humanas (Haddad et al., 2015). Esses remanescentes representam vestígios da vegetação original e desempenham um papel crucial na conservação da biodiversidade local, constituindo os remanescentes da cobertura vegetal nativa que uma vez dominou a paisagem (Lindenmayer; Fischer, 2013). A existência desses fragmentos oferece a oportunidade de entender como a natureza pode se adaptar e coexistir em ambientes urbanizados, além de destacar a importância de conservar esses locais para o bem-estar das comunidades e a sustentabilidade ambiental (Mullaney; Lucke; Trueman, 2015).

A Floresta Ombrófila Mista (FOM), também conhecida como Floresta com Araucária, é uma das principais formações do bioma Mata Atlântica, que foi fortemente impactada ao longo do século XX (Medeiros, 2005). Esta floresta ocupava extensas áreas dos planaltos do Sul do Brasil, representando aproximadamente 200.000 km², dos quais 40% estão localizados no estado do Paraná (Maack, 1949; Klein, 1960). *Araucaria angustifolia* (Bertol.) Kuntze, popularmente conhecida como araucária, é a espécie arbórea dominante no estrato superior da FOM e que pode atingir mais de 30 m de altura (Scheeren et al., 1999; Chassot et al., 2011; Fedrizzi, 2018).

No entanto, ao longo do último século, *A. angustifolia* foi extensivamente explorada devido à qualidade de sua madeira para construção e seu alto teor de celulose, amplamente utilizado na fabricação de papel (Eira et al., 1994). Estima-se que, entre 1930 e 1990, cerca de 100 milhões de árvores de *A. angustifolia* foram derrubadas (BRASIL, 2005). No estado do Paraná, Sul do Brasil, um inventário revelou que Florestas de Araucária primárias ou intocadas não existem mais, restando apenas 0,8% (66.109 hectares) de áreas florestadas em estágio avançado de sucessão (Castella; Britez, 2004). Esses fatores levaram à inclusão de *A. angustifolia* na lista de espécies ameaçadas pela União Internacional para Conservação da Natureza e dos Recursos Naturais - IUCN, onde é classificada como criticamente ameaçada (Farjon, 2006). A espécie também está na Lista Oficial de Espécies Ameaçadas da Flora Brasileira (MEIO AMBIENTE, 2008).

Portanto, o diagnóstico preciso e o monitoramento contínuo de *A. angustifolia* em remanescentes florestais são cruciais para a conservação ambiental. Com os avanços tecnológicos, os Veículos Aéreos Não Tripulados (VANTs), ou *drones*,

toraram-se cada vez mais versáteis e acessíveis como ferramentas de pesquisa nesse campo, possibilitando o mapeamento e monitoramento de árvores e florestas (Saad et al., 2021; Ecke et al., 2022; Cunha et al., 2023). Além disso, técnicas de visão computacional usadas para analisar imagens de sensores remotos, particularmente aquelas baseadas em aprendizado profundo, mais especificamente Redes Neurais Convolucionais (CNNs), têm mostrado seu potencial no reconhecimento de espécies de árvores em regiões florestais (Knauer et al., 2019; Santos et al., 2019). Essas técnicas envolvem a aplicação de modelos de aprendizado de máquina capazes de extrair características das imagens e classificar objetos, como árvores, de acordo com sua espécie (Wagner et al., 2020; Albuquerque et al., 2022). Tais técnicas oferecem a vantagem de processar imagens em tempo real e com alta precisão, superando os métodos tradicionais baseados em análise manual ou estatística.

O YOLO (*You Only Look Once*) é um exemplo de técnicas de visão computacional baseadas em aprendizado profundo, que utiliza uma CNN para segmentar imagens em regiões menores e estimar caixas delimitadoras, bem como as probabilidades da presença de objetos nessas caixas e sua identificação específica (Redmon et al., 2016). O YOLO demonstrou capacidade de detectar uma ampla variedade de objetos em imagens e quadros de vídeo, mantendo um alto nível de precisão (Redmon et al., 2016).

Diversos pesquisadores têm aplicado essas técnicas em: detecção e medição de copas (Wu et al., 2020; Sun et al., 2022; Chen, 2023); classificação de espécies de árvores (Knauer et al., 2019; Santos et al., 2019; Wang et al., 2019; Hamraz et al., 2019; Cao; Zheng; Fang, 2023); contagem de árvores (Hani et al., 2023; Putra; Wijayanto, 2023); identificação de doenças em árvores (Jemaa et al., 2023; Mamalis et al., 2023; Wu et al., 2023); e estimativa de DAP (Guterres, 2023). Esses estudos representam uma ampla gama de aplicações e indicam a versatilidade e utilidade dessas técnicas para diversos fins, contribuindo para o aprimoramento das práticas de monitoramento e conservação em ecossistemas florestais.

Em resumo, os remanescentes da FOM em ecossistemas urbanos enfrentam desafios significativos de conservação, nos quais técnicas de visão computacional, como CNNs e YOLO, estão emergindo como ferramentas para identificar e monitorar espécies de árvores, contribuindo para a avaliação e gestão de remanescentes florestais. A integração da tecnologia de VANTs com o método de identificação YOLOv7 apresenta uma abordagem inovadora para a conservação, oferecendo

perspectivas promissoras para proteger a biodiversidade e promover a sustentabilidade ambiental (Díaz-Delgado; Múcher, 2019; Lun et al., 2023; Mou et al., 2024).

Além disso, é possível empregar variáveis extraídas por meio das técnicas de visão computacional, como covariáveis em modelos estatísticos, para a estimação de atributos quantitativos da floresta. Esse modelo de regressão é crucial, pois permite inferir características importantes das árvores com base em medições que podem ser realizadas de maneira não invasiva e eficiente, especialmente em áreas urbanas onde a conservação dos remanescentes florestais é vital para a sustentabilidade ambiental e o bem-estar das comunidades locais.

Nesse contexto, o principal objetivo deste trabalho foi obter imagens de alta resolução de uma FOM em floresta urbana usando um VANT para detectar indivíduos de *A. angustifolia* com o modelo computacional YOLOv7. Esta pesquisa proporciona uma integração de avanços tecnológicos com uma aplicação que pode contribuir para esforços mais amplos de conservação e a formulação de planos públicos para garantir a manutenção das florestas urbanas.

1.1 OBJETIVOS

1.1.1 Objetivo geral

Desenvolver uma metodologia de identificação e contagem de indivíduos de *Araucaria angustifolia* por meio de imagens aéreas obtidas com veículos aéreos não tripulados (VANTs). O método visa a identificação da área de copa das árvores em fragmentos urbanos de Floresta Ombrófila Mista, utilizando a estrutura de rede neural YOLOv7 para detecção.

1.1.2 Objetivos específicos

- Analisar métricas de desempenho do modelo YOLOv7, incluindo precisão, recall, mAP e F1 score durante as etapas de treinamento e validação;
- Avaliar a discrepância entre as coordenadas previstas pelo modelo e as coordenadas reais identificadas no inventário florestal;

- Desenvolver modelos de regressão linear para avaliar as associações entre as variáveis e desenvolver uma equação de predição do diâmetro a 1,3 m das árvores a partir da área da copa.
- Verificar as suposições de regressão linear para cada modelo ajustado, selecionando o modelo de regressão mais adequado e validar sua robustez.

2 REVISÃO DE LITERATURA

2.1 MATA ATLÂNTICA

A Mata Atlântica, um dos seis biomas brasileiros, desempenha um papel crucial na biodiversidade global, abrigando uma riqueza inestimável de vida animal e vegetal (Aleixo et al., 2010). No entanto, essa biodiversidade excepcional enfrenta ameaças contínuas devido às atividades humanas. Entre os principais catalisadores dessas ameaças, pode-se citar os modelos convencionais de produção agropecuária (Paludo; Costabeber, 2012) e a expansão desenfreada do desenvolvimento urbano (Silva et al., 2018).

De acordo com Myers et al. (2000), tanto o Cerrado quanto a Mata Atlântica são considerados "*Hotspots*" da biodiversidade, representando áreas com concentrações únicas de espécies endêmicas que enfrentam uma perda incomum de habitat. A Mata Atlântica, em particular, sofreu uma redução drástica, com apenas cerca de 7,5% de sua cobertura original remanescente e apenas 35,9% dessa área sob alguma forma de proteção (Myers et al., 2000). Além disso, as áreas remanescentes são frequentemente fragmentadas em remanescentes menores do que 100 hectares, embora ainda abriguem uma impressionante diversidade de espécies, incluindo cerca de 20.000 espécies de plantas, das quais 40% são endêmicas (Ranta et al., 1998; Myers et al., 2000).

Os dados do Ministério do Meio Ambiente revelam que 2.528 municípios brasileiros compartilham território com a Mata Atlântica, abrangendo 46% das cidades do país (Ci-Brasil, 2000; DA, 2000). Esse bioma é habitado por aproximadamente 60% da população brasileira e é responsável por cerca de 70% do Produto Interno Bruto (PIB) nacional (Pinto et al., 2006).

Para garantir a conservação a longo prazo dessa biodiversidade única na Mata Atlântica, Pinto et al. (2006) enfatizam a importância do manejo adequado do ecossistema e das espécies. No entanto, essa tarefa é um desafio considerável, dada a intensa pressão da atividade humana sobre essas regiões (Koelhert; Holanda, 2014). Proteger e restaurar esse "*Hotspot*" da biodiversidade tornou-se uma prioridade vital em face das ameaças em curso.

Além da redução drástica na cobertura florestal, os fragmentos remanescentes na Mata Atlântica enfrentam desafios adicionais. A fragmentação florestal resultante

da expansão do desenvolvimento humano frequentemente leva à diminuição da conectividade entre os remanescentes florestais, isolando populações de animais e plantas e reduzindo suas chances de sobrevivência a longo prazo (Pardini et al., 2010). A perda de habitat, o aumento das bordas das florestas e a exposição a ameaças externas, como espécies invasoras e incêndios florestais, são questões críticas enfrentadas por esses fragmentos (Hanski, 2011). Portanto, a proteção e a restauração dos fragmentos florestais na Mata Atlântica não apenas contribuem para a conservação de sua diversidade única, mas também são fundamentais para a promoção da conectividade ecológica e da resiliência dos ecossistemas em um cenário cada vez mais fragmentado.

2.2 FRAGMENTOS FLORESTAIS URBANOS

Os fragmentos florestais urbanos, também conhecidos como áreas verdes naturais urbanizados, bosques naturais urbanizados, florestas urbanas ou parques urbanos, representam porções remanescentes de florestas nativas que sofreram modificações devido à expansão urbana (Santin, 1999; Cielo Filho; Santin, 2002; Martini; Biondi, 2015; Magalhães et al., 2017; Mexia et al., 2018). Esses remanescentes desempenham um papel crucial na conservação da biodiversidade local, constituindo valiosos vestígios da vegetação original que um dia dominou a paisagem, tanto em ambientes urbanos (Silva et al., 2019).

A existência desses fragmentos oferece uma oportunidade única para entender como a natureza pode se adaptar e coexistir em ambientes urbanizados. Além disso, destaca-se a importância da conservação desses espaços para a qualidade de vida das comunidades e para a sustentabilidade ambiental (Koelhert; Holanda, 2014). Esses fragmentos representam verdadeiros redutos de biodiversidade, abrigando uma variedade de espécies de flora e fauna que se adaptaram a esses ambientes singulares.

Além de seu valor intrínseco para a conservação da natureza, esses remanescentes desempenham um papel significativo na melhoria da qualidade do ar, na regulação térmica e no fornecimento de outros serviços ecossistêmicos essenciais para as populações urbanas (Pinto et al., 2006; Leal, 2012). A conservação e o manejo adequado desses fragmentos não apenas garantem a continuidade de espécies nativas, mas também contribuem para o bem-estar dos habitantes das cidades,

oferecendo oportunidades para a recreação, educação ambiental e conexão com a natureza (serviços culturais).

2.3 FLORESTA OMBRÓFILA MISTA

A Floresta Ombrófila Mista, também conhecida como Floresta de Araucária é um ecossistema singular e inestimável que abriga uma riqueza de espécies endêmicas e apresenta uma notável diversidade biológica (Moreira et al., 2007; Fonseca et al., 2009). A árvore predominante nesse ambiente é a majestosa *Araucaria angustifolia* (Bertol.) Kuntze, conhecida popularmente como araucária ou pinheiro-do-Paraná, uma conífera ameaçada de extinção que desempenha um papel crucial no equilíbrio do ecossistema (Soares, 1979; Tagliari et al., 2021; Tagliari et al., 2023). Estima-se que os atuais fragmentos remanescentes dessa floresta representem apenas de 2 a 4% de sua cobertura original (Guerra et al., 2002).

A araucária é uma árvore de grande porte, podendo atingir alturas impressionantes de até 50 m e apresentando diâmetros que alcançam 2,5 m, com uma longevidade que pode ultrapassar os 200 anos (Ferri, 2019). Suas raízes pivotantes e folhas adaptadas desempenham um papel fundamental na minimização da perda de água para o ambiente, uma adaptação essencial para a sobrevivência em condições climáticas adversas (Ferri, 2019).

De acordo com Budowski (1965), a araucária é uma espécie de longa vida secundária, exibindo algumas características de pioneirismo, como a capacidade de germinar sementes em áreas abertas e ensolaradas, e de colonizar campos, formando novos agrupamentos florestais (Imaguire, 1979; Gurgel Filho, 1980). No entanto, a espécie não se desenvolve bem sob sombreamento (Backes, 1983), possui sementes de curta durabilidade e com dispersão limitada devido ao peso e tamanho dos pinhões. Além disso, é uma planta dióica, dependendo da polinização pelo vento e só florescendo por volta dos 15 anos, quando alcança a maturidade (Soares, 1979; Carvalho, 1994).

A araucária é amplamente distribuída nas regiões Sul e Sudeste do Brasil. Ela pode ser encontrada em estados como Espírito Santo, Minas Gerais, Rio de Janeiro, São Paulo, Paraná, Santa Catarina e Rio Grande do Sul (Wrege et al., 2017). Além disso, a araucária também ocorre em áreas limitadas da Argentina e do Paraguai (Hueck, 1953; Brandão et al., 2019). No entanto, estudos indicam que a área de

ocorrência da araucária pode sofrer uma forte redução nas próximas décadas devido ao aumento da temperatura e à alteração do regime hídrico (Marchioro, 2020; Tagliari, 2021).

Curiosamente, o nome "Curitiba", a capital do estado do Paraná, tem suas raízes na língua Tupi e está relacionado com as araucárias. "Curitiba" deriva das palavras Tupi "kur yt yba", que significam "grandes quantidades de pinheiros, pinheiral", fazendo alusão à abundância de pinheiros (*Araucaria angustifolia*) na região antes de sua fundação (Hueck, 1953; Curitiba, 2023).

2.4 MONITORAMENTO E IDENTIFICAÇÃO DE ESPÉCIES EM FLORESTAS NATIVAS

O monitoramento e a identificação de espécies em florestas nativas são fundamentais para a conservação da biodiversidade e a gestão sustentável dos recursos florestais. A mata atlântica, por exemplo, possui mais de 17.000 espécies de plantas terrestres, e esse número cresce com o avanço da pesquisa (Brasil, 2020). No entanto, a identificação botânica de espécies florestais é um desafio enfrentado por muitos profissionais do setor.

Os Veículos Aéreos Não Tripulados (VANTs), ou drones, são amplamente utilizados em projetos de monitoramento florestal e têm se mostrado eficazes na identificação de espécies através de sensoriamento remoto. Este processo envolve a análise de imagens aéreas para identificar espécies florestais, utilizando parâmetros como fenologia da copa, incluindo floração, frutificação e variações na coloração das folhas, fatores essenciais para a identificação de espécies em diferentes ecossistemas (Dainelli et al., 2021; Jiang et al., 2023).

A técnica de sensoriamento remoto com VANTs permite a coleta de imagens sem contato físico direto entre o sensor e o objeto, gerando ortofotos georreferenciadas. Essas imagens são processadas por *softwares* especializados que auxiliam na criação de mosaicos detalhados da cobertura floresta (Thapa; Garcia e Eklundh, 2021). Tais informações são fundamentais para a conservação de florestas nativas, fornecendo dados detalhados sobre a estrutura e a saúde das florestas, bem como estoques de biomassa e carbono (Dainelli et al., 2021; Miraki et al., 2024)

A fim de auxiliar na conservação das florestas um estudo investigou a precisão da detecção de uma espécie específica utilizando dados de UAV e satélite. A

combinação de modelos de floresta aleatória treinados com dados do Sentinel-2 e UAV resultou em melhorias na classificação de espécies arbóreas, demonstrando a viabilidade de integrar dados de sensoriamento remoto para identificar espécies arbóreas específicas (Miraki et al., 2024). O uso de dados multiespectrais e de alta resolução espacial dos UAVs, junto com a robustez dos modelos de floresta aleatória proporcionou uma abordagem poderosa para a distinção de espécies com base em suas características espectrais e fenológicas.

Os VANTs também surgiram como ferramentas promissoras para complementar levantamentos terrestres e monitorar a saúde florestal. Um *pipeline* de dados padronizado foi desenvolvido para gerar dados de referência semiautomáticos, integrando dados terrestres e UAV. Utilizando CNNs para classificar espécies e condições de copa, o estudo mostrou-se eficaz para reduzir tarefas terrestres, economizando tempo e custos, e sugere uma modernização do manejo florestal para eficiência e sustentabilidade (Ecke, 2024). A padronização do *pipeline* de dados permite a integração eficiente de diversas fontes de dados, enquanto as CNNs garantem uma classificação precisa e automatizada das condições das copas das árvores.

Para estimar a biomassa acima do solo das florestas, um estudo utilizou imagens de UAV e uma rede Mask R-CNN para identificar automaticamente a copa e a altura das árvores de *Pinus sylvestris*. A inclusão de dados de altura das copas no treinamento do modelo melhorou significativamente a precisão da extração, contribuindo para pesquisas sobre sequestro de carbono e redução de custos de métodos manuais (FU et al., 2024). A rede Mask R-CNN, conhecida por sua capacidade de segmentação precisa, combinada com os dados de modelo de altura de copa permitiu a identificação detalhada das características estruturais das árvores, essencial para estimativas acuradas de biomassa.

O desenvolvimento do YOLO-DCAM, uma rede de aprendizado profundo baseada no YOLOv5, incorpora camadas de convolução deformáveis e um módulo de atenção em múltiplas escalas. Esta metodologia se mostrou eficaz para a detecção de árvores individuais em florestas plantadas complexas, utilizando imagens RGB de UAV para promover a precisão na identificação de copas de árvores (Wang et al., 2024). A combinação das camadas de convolução deformáveis permite ao modelo adaptar-se melhor às formas irregulares das copas das árvores, enquanto o módulo

de atenção em múltiplas escalas melhora a capacidade do modelo de focar em características relevantes em diferentes níveis de detalhe nas imagens.

A segmentação de árvores individuais com o uso de UAVs equipados com LiDAR foi abordada através de um algoritmo adaptativo de formato de copa que não depende do tamanho da janela, diferentemente dos métodos tradicionais. Este algoritmo foi testado em diversas condições florestais e topográficas, mostrando-se eficaz para detectar pontos de sementes e segmentar árvores individualmente em florestas densas e naturais (Yan et al., 2018; Ma et al., 2024). O algoritmo adaptativo se ajusta dinamicamente às diferentes formas e tamanhos das copas das árvores, permitindo uma segmentação mais precisa e robusta em variados contextos ambientais.

Para avaliar a qualidade e a saúde das florestas de mangue, a delimitação precisa das copas das árvores foi realizada utilizando dados de UAV-LiDAR. Foram identificadas características ótimas como o modelo de altura da copa e a variação da altura da nuvem de pontos. O uso de redes neurais convolucionais (Mask R-CNN e YOLOv8) em combinação com essas características melhorou significativamente a acurácia em comparação aos métodos tradicionais (Lu; Wang, 2024). As redes neurais convolucionais permitiram a extração de características detalhadas e a delimitação precisa das copas, essencial para o monitoramento eficaz das florestas de mangue.

Esses avanços tecnológicos têm potencial para revolucionar o monitoramento e a gestão das florestas nativas, proporcionando uma compreensão mais aprofundada e detalhada das dinâmicas florestais. A implementação de métodos baseados em UAVs, redes neurais e sensoriamento remoto multiespectral oferece uma abordagem inovadora para superar os desafios tradicionais da identificação e monitoramento de espécies, aumentando a precisão e a eficiência dos estudos florestais.

2.5 APRENDIZADO DE MÁQUINA

A Rede Neural Artificial (RNA) pode ser definida como uma estrutura complexa interligada por elementos de processamento simples (neurônios), que possuem a capacidade de realizar operações como cálculos em paralelo para processamento de dados e representação de conhecimento. Seu primeiro conceito foi introduzido em 1943 (Mcculloch; Pitts, 1943), mas ganhou popularidade algumas décadas depois

com a introdução de algoritmos de treinamento como retropropagação (*backpropagation*), que permite a realização de um treinamento posterior para aperfeiçoar os resultados do modelo. Desde que foi desenvolvida, essa técnica vem sendo amplamente utilizada e validada por diversas áreas de pesquisa que pretendem antever acontecimentos e auxiliar na tomada de decisão.

Em 1958, Frank Rosenblatt introduziu a Rede Neural Artificial Perceptron, inspirando-se nos trabalhos pioneiros de Walter Pitts e Warren Sturgis McCulloch (Rosenblatt, 1958). Este modelo é uma das primeiras abordagens em aprendizado de máquina e lida com um único neurônio, classificando os resultados de maneira linear.

Visando enfrentar desafios envolvendo problemas que não podem ser separados linearmente, uma evolução significativa ocorreu no modelo de Rosenblatt, resultando na criação da Rede Neural Artificial Multilayer Perceptron (MLP) (Gardner; Dorling, 1998). Essa nova configuração opera como uma rede *feedforward* (ou seja, uma rede onde a saída de um neurônio se conecta a outro neurônio na camada seguinte, seguindo uma direção da esquerda para a direita). A MLP é composta por um conjunto de neurônios denominados "nós". A estrutura da rede inclui uma camada de entrada, que não possui função computacional, uma ou mais camadas ocultas e, por fim, uma camada de saída. A complexidade da MLP é determinada pela quantidade de camadas ocultas e pelo número de neurônios presentes nessas camadas.

As RNAs são estruturadas em diferentes estratos, que compõem sua arquitetura. Essas camadas podem variar desde uma única camada simples, conhecida como perceptron, até redes multicamadas que consistem em uma ou mais camadas intermediárias, frequentemente referidas como "camadas ocultas". Além disso, as RNAs podem ser construídas pela combinação de várias redes com camadas simples (Venturieri; Dos Santos, 1998).

2.6 APRENDIZADO PROFUNDO (*DEEP LEARNING*)

No contexto tradicional do aprendizado de máquina, um desafio recorrente reside não tanto no treinamento da máquina, mas na engenharia de variáveis que possa facilitar o processo de aprendizado. Em áreas como o reconhecimento de imagens, isso se torna evidente nas etapas complexas de pré-processamento que a imagem deve atravessar antes de ser alimentada a um algoritmo de aprendizado de

máquina: filtros de ruído, segmentação, ajuste de contraste, detecção de contornos, entre outros. É neste cenário que as redes neurais artificiais emergem como uma solução para esse problema (Krogh, 2008).

Diferentemente do aprendizado de máquina clássico, em que se necessita criar manualmente variáveis representativas, as redes neurais têm a capacidade de aprendê-las automaticamente, o que representa uma distinção fundamental. A Aprendizagem Profunda não se limita apenas a aprender mapeamentos entre características representativas e resultados desejados. Em vez disso, as máquinas podem automaticamente aprender as próprias características representativas. Essa capacidade é o cerne das técnicas de aprendizagem profunda.

Essas técnicas se baseiam principalmente no uso de redes neurais profundas, onde cada camada oculta pode ser vista como aprendendo níveis hierárquicos de abstração. No contexto do reconhecimento de imagens, por exemplo, as camadas mais próximas à entrada aprendem a detectar traços e variações de luminosidade, enquanto camadas mais altas se especializam em combinar esses traços para formar partes de objetos. Posteriormente, um modelo linear pode utilizar essas partes para distinguir entre diferentes objetos (Lecun; Bengio; Hinton, 2015).

A aprendizagem profunda representa, assim, um avanço significativo na capacidade das máquinas de aprender e representar dados de forma automática e hierárquica, demonstrando sua relevância crescente em diversas aplicações de aprendizado de máquina.

2.7 REDES NEURAS CONVOLUCIONAIS

Uma Rede Neural Convolutiva (*ConvNet* / *Convolutional Neural Network* / *CNN*) é um poderoso algoritmo de aprendizado profundo projetado para analisar imagens de entrada, atribuir importância (pesos e vieses que podem ser ajustados durante o treinamento) a várias características e objetos presentes na imagem e, por fim, distingui-los uns dos outros. O pré-processamento necessário em uma *ConvNet* é notavelmente mais simplificado em comparação com outros algoritmos de classificação. Enquanto abordagens mais antigas exigiam que os filtros fossem projetados manualmente, as *CNNs* têm a notável capacidade de aprender esses filtros e características automaticamente durante o treinamento (Liu et al., 2022).

Em um marco histórico em 1962, Hubel e Wiesel realizaram um experimento que revelou que certos neurônios se ativam em conjunto quando expostos a linhas, curvas e bordas, demonstrando uma capacidade inicial de reconhecimento visual (Russell; Norvig, 2004). Essa descoberta fundamental serve como a base para as Redes Convolucionais, que realizam a tarefa de filtrar esses elementos visuais básicos em camadas sucessivas, transformando gradualmente essa informação em representações cada vez mais complexas de uma imagem.

Esse processo é fundamental para a capacidade das redes neurais convolucionais de identificar padrões, características e objetos em imagens, tornando-as uma ferramenta essencial em tarefas de visão computacional, como reconhecimento de objetos, detecção de objetos em tempo real e muito mais.

2.8 KERNELS CONVOLUCIONAIS

Um *kernel* é um filtro que empregamos no processamento de imagens, varrendo a imagem da esquerda para a direita e de cima para baixo, aplicando a operação de convolução. Ao final deste processo, obtemos uma imagem filtrada.

No contexto do processamento de imagens, um *kernel* de convolução é uma matriz 2D utilizada para aprimorar ou destacar características específicas em imagens. Também conhecido como matriz de convolução, um kernel é geralmente uma matriz quadrada de tamanho $M \times N$, onde M e N são números ímpares (por exemplo, 3×3 , 5×5 , 7×7 , etc.).

Os *kernels* de convolução 2D 3×3 são ferramentas poderosas que permitem realizar operações matemáticas em cada píxel de uma imagem, resultando no efeito desejado, como desfoque ou aumento de nitidez (Mairal et al., 2014). Existem dois motivos significativos para isso:

- **Redução de Ruído:** O desfoque é frequentemente utilizado para atenuar certos tipos de ruído presentes em uma imagem, tornando-a mais suave e livre de imperfeições. Esse processo é comumente referido como suavização, pois ajuda a tornar a imagem mais agradável visualmente, removendo irregularidades e pequenas variações que podem ser interpretadas como ruído.
- **Destaque de Elementos:** Em algumas situações, desfocar intencionalmente partes específicas de uma imagem pode ser uma técnica valiosa. Por exemplo, em dispositivos móveis com o modo 'Retrato', essa abordagem é utilizada para

destacar o objeto principal, desfocando o fundo. Isso cria um efeito estético atraente que concentra a atenção do espectador no objeto em primeiro plano.

2.9 OPERAÇÕES DE CONVOLUÇÃO EM REDES NEURAI CONVOLUCIONAIS

As operações de convolução desempenham um papel fundamental nas redes neurais convolucionais, funcionando como filtros que exploram regiões menores da imagem, deslizando-se por toda a entrada para capturar características distintivas. Para uma compreensão mais detalhada, consideremos uma imagem de dimensões $32 \times 32 \times 3$. Aqui, " 32×32 " refere-se à largura e altura da imagem em pixels, e "3" refere-se aos três canais de cor (vermelho, verde e azul) da imagem. Suponhamos um filtro que abrange uma área de 5×5 pixels na imagem, movendo-se com um passo de 2 pixels (conhecido como "*stride*").

Ao aplicar esse filtro à imagem, ele percorrerá cada um dos canais de cor, resultando em um "mapa de características" ou "mapa de ativação" de dimensões $28 \times 28 \times 1$ ao final do processo. A profundidade desse mapa de ativação é determinada pela quantidade de filtros aplicados durante a convolução. À medida que avançamos em camadas de convolução mais profundas, detalhes cada vez mais refinados são identificados e representados no mapa de ativação resultante.

É importante destacar que o filtro, também conhecido como *kernel*, é inicializado com pesos aleatórios e esses pesos são ajustados durante o processo de treinamento por retropropagação, à medida que a rede aprende com novos exemplos. A região da entrada onde o filtro é aplicado é chamada de "campo receptivo" e desempenha um papel crucial na captura de padrões específicos na imagem. Essas operações de convolução são essenciais para o sucesso das *CNNs* em tarefas de visão computacional com um impacto significativo na capacidade da rede de identificar e extrair características relevantes.

2.10 FUNÇÕES DE ATIVAÇÃO EM REDES NEURAI CONVOLUCIONAIS

As funções de ativação desempenham um papel essencial ao introduzir não-linearidades no sistema, permitindo que a rede aprenda uma ampla variedade de características e relações complexas nos dados. Existem várias funções de ativação disponíveis, como sigmoid, tanh e softmax (Geng et al., 2019). No entanto, para redes

neurais convolucionais, a função de ativação ReLU (*Rectified Linear Unit*) é amplamente recomendada devido à sua eficiência computacional e sua capacidade de manter níveis de precisão comparáveis aos de outras funções (Agarap, 2018).

A função ReLU tem a notável característica de zerar todos os valores negativos na saída da camada anterior. Isso introduz uma não-linearidade positiva na rede, permitindo que ela capture relações complexas e atividades discriminativas. A simplicidade computacional da ReLU a torna uma escolha vantajosa para o treinamento de redes convolucionais, pois acelera o processo de aprendizado sem comprometer significativamente a qualidade das previsões. Portanto, a função de ativação ReLU é uma escolha sólida para aprimorar a capacidade das redes neurais convolucionais em extrair informações úteis dos dados de entrada.

2.11 YOLO - UMA EVOLUÇÃO NA DETECÇÃO DE OBJETOS

A detecção de objetos desempenha um papel fundamental em diversas aplicações de visão computacional, desde a segurança de veículos autônomos até a análise de imagens médicas. O desenvolvimento contínuo de algoritmos e arquiteturas de detecção tem permitido avanços significativos na precisão e eficiência desse campo. Nesse contexto, a série YOLO de redes neurais convolucionais tem se destacado como uma das abordagens mais influentes (Lin, Jijing; Chen Xiao, 2023).

A jornada YOLO começou com o YOLOv1, apresentado por Joseph Redmon em 2016. Este modelo revolucionário introduziu o conceito de detecção de objetos em tempo real, permitindo que uma única rede neural fosse capaz de prever a presença e as localizações de objetos em uma imagem em uma única inferência. Apesar de sua inovação, o YOLOv1 apresentou desafios na detecção precisa de objetos pequenos e próximos, bem como em casos de sobreposição (Redmon et al., 2016).

O YOLOv2, também conhecido como YOLO9000, surgiu em 2017 e trouxe melhorias significativas. Ele introduziu a ideia de ancoragem (*anchor boxes*) para melhorar a detecção de objetos em diferentes escalas e aspectos. Além disso, o YOLOv2 expandiu a capacidade de detecção para inúmeras classes (mais de 9.000), tornando-o um dos modelos mais abrangentes da época.

Em 2018, o YOLOv3 foi lançado, aprimorando ainda mais a precisão da detecção. Ele adotou um *backbone Darknet-53* mais profundo e um total de 106 camadas. Além disso, introduziu três diferentes escalas de detecção em diferentes

níveis da rede, resultando em melhorias significativas na detecção de objetos em várias escalas e posições (Lun et al., 2023).

O YOLOv4, lançado em 2020, foi um marco em termos de velocidade e precisão na detecção de objetos. Com uma série de otimizações e um design mais eficiente, o YOLOv4 superou as versões anteriores. Ele também introduziu a arquitetura CSPDarknet53, melhorando a eficiência computacional.

Em resposta ao YOLOv4, o YOLOv5 foi lançado em junho de 2020, com foco em melhorias de velocidade e precisão. Embora também utilize a arquitetura CSPDarknet53, o YOLOv5 introduziu melhorias adicionais e técnicas como *mosaic data augmentation* e *auto learning bounding box anchors*, que aumentaram a eficiência e mantiveram uma alta precisão. Além disso, o YOLOv5 apresentou uma implementação mais leve e eficaz, adequada para diversas aplicações em tempo real.

O YOLOv6, lançado em 2022, superou a YOLOv5 em termos de precisão e velocidade de detecção. Ele foi desenvolvido com um foco especial em aplicações industriais, sendo capaz de superar até mesmo versões mais avançadas quando testado em cenários industriais desafiadores.

O YOLOv7, também lançado em 2022, superou todos os modelos anteriores em velocidade e precisão na detecção de objetos. Utilizando *hardware* mais simples e permitindo treinamento em pequenos conjuntos de dados sem pesos pré-treinados, ele se baseou nas arquiteturas da YOLOv4, *Scaled YOLOv4* e YOLOR.

A mais recente adição à família YOLO, o YOLOv8, foi lançada no início de 2023, sendo projetado para ser rápido, preciso e fácil de usar. Além de sua eficiência, o YOLOv8 é altamente flexível, suportando vários formatos de exportação e sendo adequado para treinamento em grandes conjuntos de dados. Ele oferece total suporte para rodar tanto em CPU (*Central Processing Unit*, ou Unidade Central de Processamento) quanto em GPU (*Graphics Processing Unit*, ou Unidade de Processamento Gráfico), entre outras melhorias.

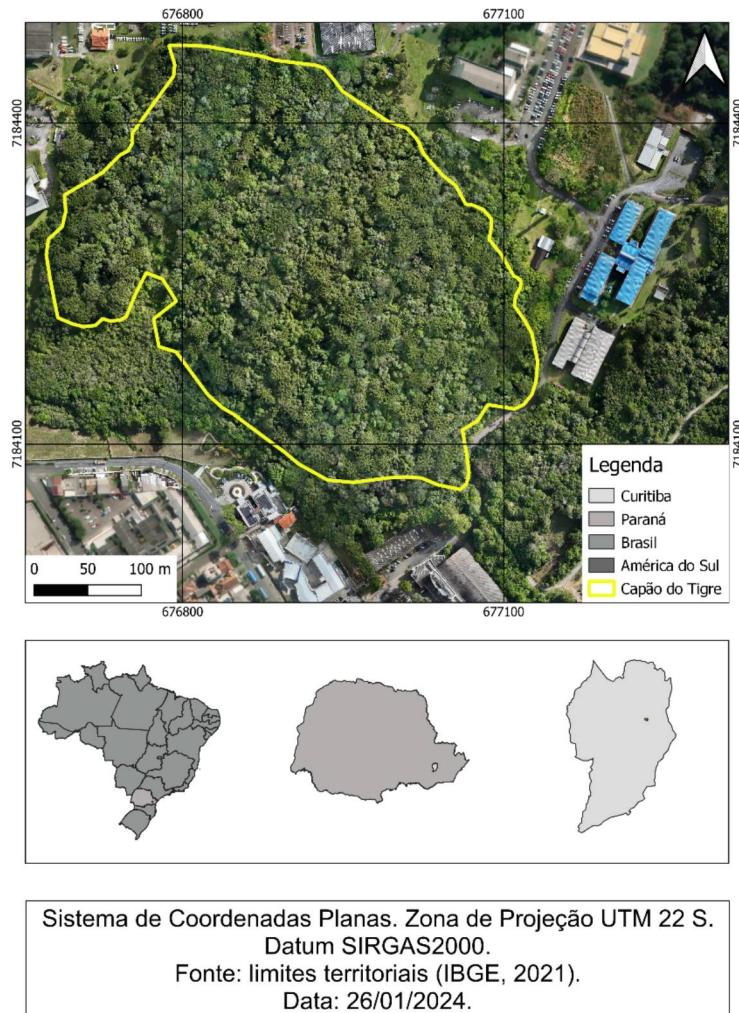
3 METODOLOGIA

3.1 ÁREA DE ESTUDO

Este estudo foi realizado em um remanescente de Floresta Ombrófila Mista localizado nos limites urbanos do município de Curitiba, estado do Paraná, Brasil, com coordenadas aproximadas de $-25^{\circ}26'50''$ - $25^{\circ}27'33''$ S e $-49^{\circ}14'16''$ - $49^{\circ}14'33''$ O e uma altitude de 900 metros acima do nível do mar. A área total é estimada em 15,24 hectares, dos quais 12,96 hectares correspondem à Floresta Ombrófila Mista Montana, enquanto 2,28 hectares são ocupados por vegetação em sucessão inicial, com predominância de bambus (*Merostachys* spp.). A Figura 1 mostra a localização da área de estudo.

O clima local é classificado como Cfb conforme a classificação de Köppen, sendo subtropical úmido mesotérmico, caracterizado por verões frescos, invernos com geadas frequentes e sem estação seca. As temperaturas médias anuais durante os meses quentes e frios são abaixo de 22°C e 18°C , respectivamente, com uma temperatura média anual de 17°C . Quanto à umidade relativa e precipitação média anual, são registrados valores de aproximadamente 85% e de 1.300 a 1.500 mm, respectivamente, com um índice hídrico variando de 60 a 100 mm, sem ocorrência de deficiência hídrica ao longo do ano (Maack, 1981).

FIGURA 1 - LOCALIZAÇÃO DA ÁREA DE ESTUDO EM UM FRAGMENTO DE FLORESTA OMBRÓFILA MISTA, CURITIBA, PARANÁ, BRASIL



FONTE: O AUTOR (2024).


3.2 OBTENÇÃO DOS DADOS

Os dados foram coletados por meio de imagens aéreas capturadas com um UAV DJI Mavic 3, que possui as seguintes especificações técnicas: velocidade de até 21 m/s, resolução de imagem de 20 MP, lentes com FOV (*Field Of View*) de 84° (equivalente a 24 mm) f/2.8 a f/11, gerando imagens de 5280 x 3956 pixels, com um peso de 899 g (incluindo bateria e hélices) e precisão de foco de 1 metro vertical e horizontal, respectivamente. O controle remoto do UAV opera nas frequências de 5.725-5.850 GHz. As imagens do UAV consistem em bandas do espectro eletromagnético visível, operando no sistema RGB (*Red, Green e Blue*) para composição de cores. A coleta de dados foi realizada em condições climáticas

favoráveis, com voo próximo ao meio-dia, para minimizar sombras devido ao ângulo solar, a altitude do voo realizado foi de 80 m.

O processamento foi realizado utilizando o *software* OpenDroneMap (WebODM) para gerar ortomosaicos georreferenciados. Os ortomosaicos foram então divididos em seções menores usando o *software* QGIS, versão 3.18, como mostrado na Figura 2. O corte no ortomosaico foi necessário devido ao seu tamanho, uma vez que a plataforma usada posteriormente para identificar os indivíduos tem limitações quanto ao número de píxeis para processamento. Assim, o tamanho dos polígonos foi determinado em aproximadamente 100 m x 100 m. Outra abordagem adotada no estudo foi evitar cortar as copas das árvores, para impedir que fossem separadas em polígonos distintos. Portanto, os polígonos foram ajustados para contorná-las, minimizando possíveis problemas nas etapas subsequentes de análise.

FIGURA 2 - DIVISÃO DO ORTOMOSAICO DA ÁREA DE ESTUDO EM FRAGMENTOS MENORES NO QGIS PARA PROCESSAMENTO E TREINAMENTO DO MODELO YOLOV7 NO ROBOFLOW, EM UM FRAGMENTO DE FLORESTA OMBRÓFILA MISTA, CURITIBA, PR



FONTE: O AUTOR (2024).

As imagens foram processadas para treinar o modelo YOLOv7 usando a plataforma Roboflow (Dwyer et al., 2022), que oferece recursos para a criação de modelos personalizados de visão computacional. Na plataforma, foi realizado o treinamento do modelo, que incluiu a criação de caixas delimitadoras para a identificação de indivíduos de *A. angustifolia* usando o modelo YOLOv7, bem como a atribuição de rótulos a categorias específicas.

O treinamento e o teste do modelo YOLOv7 usados para detectar as árvores foram realizados utilizando a ferramenta AutoML (*Automated Machine Learning*) do Roboflow Train. Essa ferramenta AutoML permitiu não apenas o treinamento eficiente do modelo, mas também sua implementação para a detecção das árvores de *A. angustifolia* (objeto personalizado) no conjunto de dados.

Para treinar o modelo YOLOv7 no Google Colaboratory, os pacotes essenciais foram instalados, incluindo o Roboflow. Os dados do Roboflow foram acessados e importados da plataforma para análise. O método YOLOv7 foi utilizado para identificar as imagens, e os resultados foram armazenados em planilhas para posterior análise. Este procedimento envolveu a configuração do ambiente, a integração com o Roboflow e a aplicação do modelo YOLOv7, garantindo a eficácia do processo de identificação.

3.3 TREINAMENTO DO MODELO

A fim de realizar o treinamento do modelo na plataforma Roboflow, as imagens obtidas durante o levantamento de campo foram carregadas. Foram criados 3.261 rótulos de araucária, referindo-se às árvores presentes em 300 imagens, selecionadas de um total de 848 imagens que cobrem a área mapeada. Esses rótulos foram distribuídos da seguinte forma: 2.252 para o conjunto de treinamento, 687 para validação e 322 para o conjunto de teste, conforme ilustrado na Figura 3. O modelo foi treinado ao longo de aproximadamente 160 épocas, sendo cada época uma passagem completa dos dados de treinamento pelo modelo YOLOv7.

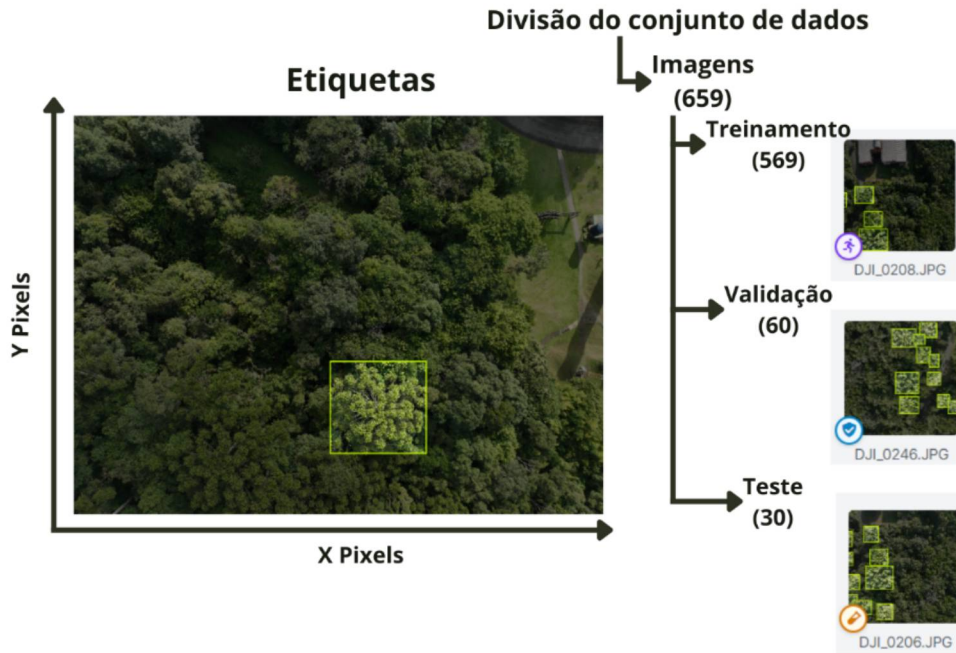
A *Box Loss* indica quão bem o modelo YOLOv7 consegue localizar o centro e a caixa delimitadora da *A. angustifolia* no processo de classificação. A *Class Loss* refere-se à precisão da classificação do modelo YOLOv7 ao prever as classes das araucárias. O *Object Loss* representa a probabilidade de que a *A. angustifolia* esteja em uma região de interesse proposta

Além disso, as métricas de desempenho de precisão, recall, mAP50 e mAP50-95 do modelo YOLOv7 são apresentadas, sendo essas as métricas mais importantes para avaliar o desempenho do modelo (Figura 7). As curvas de *Box Loss*, *Class Loss* e *Object Loss* mostraram uma tendência semelhante durante o estágio de treinamento, indicando uma convergência eficiente do modelo. Espera-se que as curvas diminuam até atingirem um ponto de estagnação (Casas et al., 2023).

Durante o pré-processamento, as imagens foram transformadas para otimizar o tempo de treinamento. Nessa etapa, aplicamos os seguintes procedimentos: orientação automática das imagens e redimensionamento para 640 x 640 pixels. A orientação automática ignorou os dados EXIF (Formato de Arquivo de Imagem Intercambiável), garantindo uma visualização consistente, independentemente da orientação original fornecida por esses metadados. Os dados EXIF geralmente indicam a orientação específica da imagem. O redimensionamento ajustou as dimensões das imagens, preservando a proporcionalidade das anotações. Embora o processo tenha gerado imagens quadradas e levemente distorcidas, é importante destacar que nenhum dado relevante da imagem original foi perdido durante esse ajuste.

Na etapa seguinte, aumentamos o número de imagens para melhorar o desempenho do modelo. Isso foi alcançado aplicando rotações de 90° e 180° no sentido anti-horário e horário às imagens existentes. Essa abordagem tem o potencial de melhorar a capacidade do modelo de generalização, resultando em um desempenho mais eficaz ao lidar com imagens previamente não vistas. Durante esse processo, os incrementos são encadeados sequencialmente com randomização nas configurações e valores, sendo aplicados a cada imagem expandida. Quaisquer duplicatas identificadas durante esse procedimento são filtradas da versão final criada. Dessa forma, o número de imagens no modelo aumentou de 300 para 659, representando uma melhoria significativa no desempenho do modelo. A Figura 3 detalha o procedimento de rotulagem, treinamento, validação e teste.

FIGURA 3 - PROCEDIMENTO DE ROTULAÇÃO DAS IMAGENS, TREINAMENTO, VALIDAÇÃO E TESTE DO MODELO YOLOV7 PARA DETECÇÃO DE *Araucaria angustifolia* EM FRAGMENTOS DE FLORESTA OMBRÓFILA MISTA, CURITIBA, PR



FONTE: O AUTOR (2024).

3.4 GEORREFERENCIAMENTO DAS IMAGENS

Após classificar os ortomosaicos usando o modelo YOLOv7, os resultados da classificação foram gerados na forma de caixas delimitadoras. Essas caixas delimitadoras são polígonos que cercam as copas das árvores de *A. angustifolia* identificadas pelo modelo YOLOv7, mas sem um sistema de coordenadas. Para lidar com essa situação, os píxeis da imagem foram convertidos para coordenadas UTM usando o ortomosaico georreferenciado. Para realizar essa transformação, as coordenadas das caixas delimitadoras foram convertidas em coordenadas geoespaciais (UTM) por meio de operações de conversão usando a biblioteca osgeo em Python (Miara, 2021).

3.5 DESCRIÇÃO DOS DADOS DE CAMPO E COMPARAÇÃO COM O MODELO

O banco de dados usado para comparação com os dados de classificação do modelo YOLOv7 provém de um inventário florestal realizado em 2021, contendo informações sobre 12.836 indivíduos, dos quais 342 representam *A. angustifolia*. Por sua vez, foi realizada uma filtragem específica para essa espécie, permitindo a extração das coordenadas das respectivas árvores e os Diâmetros da Altura do Peito (DAP) a altura de 1,3 m do solo. Essas coordenadas podem ser associadas às coordenadas do centroide das caixas delimitadoras obtidas a partir da classificação das imagens com os indivíduos de *A. angustifolia* identificados no inventário florestal.

Sendo que o levantamento aéreo com UAV captou imagens exclusivamente do dossel superior da floresta, as árvores no estrato inferior não foram amostradas. Como resultado, o número de indivíduos detectados no treinamento foi menor do que o registrado no inventário. Para ajustar essa discrepância, um comando Python foi implementado para integrar os dados do inventário com os dados de geoprocessamento, considerando a menor distância entre as coordenadas de ambos os conjuntos.

3.6 MÉTRICAS DE DESEMPENHO DO MODELO

As métricas de desempenho do modelo utilizadas e fornecidas pela plataforma Roboflow foi precisão, recall, mAP (*Mean Average Precision*), matriz de confusão e pontuação F1. As definições de cada uma das métricas utilizadas são apresentadas abaixo. Também apresentamos algumas métricas adicionais específicas do modelo YOLOv7 fornecidas pelo Roboflow, como Box Loss, Class Loss, e Object Loss.

O mAP pode ser descrito como uma métrica que avalia o desempenho de modelos de detecção de objetos. O mAP engloba precisão e recall em uma única medida, proporcionando uma visão abrangente da eficácia do modelo. As anotações mAP50 e mAP50-95 indicam os intervalos de confiança associados à métrica. O mAP50 refere-se à precisão média considerando apenas detecções com uma sobreposição mínima de 50% entre a caixa delimitadora prevista e a caixa delimitadora de referência. O mAP50-95 expande essa análise para intervalos de sobreposição de 50% a 95%.

A precisão é uma métrica que avalia a qualidade das previsões positivas feitas por um modelo de classificação. É calculada como a razão entre o número de verdadeiros positivos (VP) e a soma dos verdadeiros positivos e falsos positivos (FP). A precisão mede a proporção de instâncias classificadas como positivas pelo modelo que são positivas. Uma alta precisão indica que o modelo é eficaz em evitar a classificação errada de instâncias negativas como positivas. A precisão é dada pela Equação 1.

$$Precisão = \frac{Verdadeiro\ Positivo\ (VP)}{Verdadeiro\ Positivo\ (VP) + Falso\ Positivo\ (FP)} \quad (1)$$

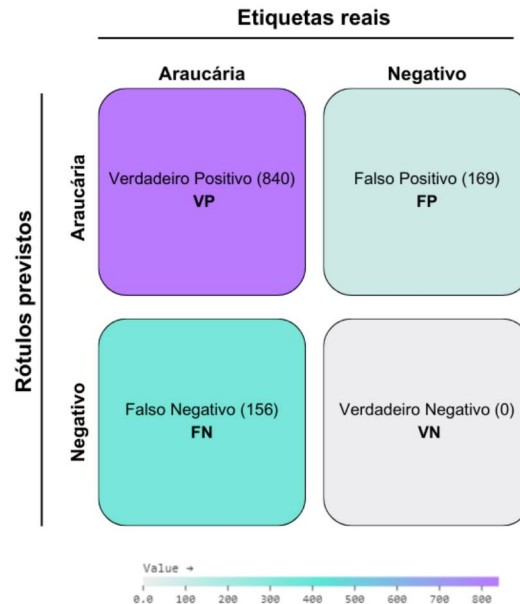
Recall é uma métrica que avalia a capacidade do modelo de capturar corretamente todas as instâncias positivas. É calculada como a razão entre o número de verdadeiros positivos (VP) e a soma dos verdadeiros positivos e falsos negativos (FN). Recall mede a proporção de instâncias positivas que foram corretamente identificadas pelo modelo em relação ao número total de instâncias positivas no conjunto de dados. Um recall alto indica que o modelo pode identificar a maioria das instâncias positivas. O recall é dado pela Equação 2.

$$Recall = \frac{Verdadeiro\ Positivo\ (VP)}{Verdadeiro\ Positivo\ (VP) + Falso\ Negativo\ (FN)} \quad (2)$$

Ambas as métricas são importantes, mas podem ser contraditórias entre si. Aumentar a precisão muitas vezes reduz o recall e vice-versa. Portanto, ao avaliar o desempenho de um modelo, é crucial considerar ambas as métricas. A matriz de confusão (Figura 4) fornece quatro informações cruciais sobre o desempenho do classificador. Verdadeiro Positivo (VP) ocorre quando uma imagem é corretamente atribuída à sua classe correspondente. Falso Positivo (FP) ocorre quando uma imagem é erroneamente identificada como contendo algo que não está realmente presente na imagem. Verdadeiro Negativo (VN) representa uma imagem corretamente identificada como não pertencente a uma classe específica. Por fim, o Falso Negativo (FN) refere-se a uma imagem classificada erroneamente como não pertencente a uma classe específica, quando, na verdade, pertence a essa classe. No entanto, no caso

de detecção de objetos, isso não é levado em consideração. Com base na matriz de confusão, é possível obter informações essenciais para calcular a precisão e o recall.

FIGURA 4 - MATRIZ DE CONFUSÃO DO MODELO YOLOV7



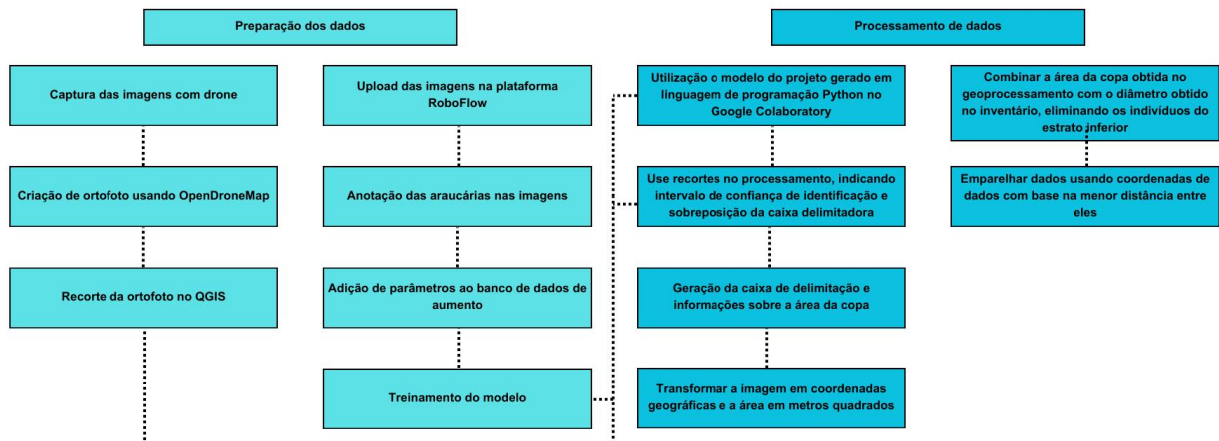
FONTE: O AUTOR (2024).

O F1 score é uma métrica que combina as medidas de precisão e recall em um único valor, proporcionando uma visão equilibrada do desempenho de um modelo de classificação. Ele é especialmente útil em situações em que é importante considerar tanto os falsos positivos quanto os falsos negativos. O F1 varia de 0 a 1. Uma pontuação de 1 indica o melhor desempenho possível, indicando um equilíbrio ideal entre precisão e recall. O F1 score é dado pela Equação 3:

$$F1 = 2 * \frac{Precisão * Recall}{Precisão + Recall} \quad (3)$$

O procedimento metodológico é ilustrado na Figura 5, abrangendo desde a obtenção dos dados reais até a avaliação do desempenho do modelo. Isso inclui o voo do UAV, o processamento dos ortomosaicos, o treinamento do modelo YOLOv7 e a análise das métricas de desempenho.

FIGURA 5 - FLUXOGRAMA DA METODOLOGIA



FONTE: O AUTOR (2024).

3.7 MODELAGEM DO DAP DAS ÁRVORES DE *A. angustifolia* POR MEIO DA ÁREA DA COPA OBTIDA PELO YOLOV7

Com base nas áreas das copas das *Araucaria angustifolia* obtidas por meio de sobrevoos com drone, implementamos a criação de modelos de regressão linear. Esses modelos visam avaliar as associações entre a área da copa (m^2) e o diâmetro à altura do peito (d). O objetivo é desenvolver uma equação de predição do DAP que possa ser aplicada a outros conjuntos de dados. As equações elaboradas estão representadas na Tabela 1:

TABELA 1 - MODELOS ESTATÍSTICOS DE REGRESSÃO AJUSTADOS PARA A ESTIMATIVA DO DAP (DIÂMETRO À ALTURA DO PEITO) DE ÁRVORES DE *Araucaria angustifolia* A PARTIR DA ÁREA DE COPA EM FRAGMENTOS DE FLORESTA OMBRÓFILA MISTA, CURITIBA, PR.

Denominação	Modelo
Linear simples	$d = \beta_0 + \beta_1 m + \varepsilon_i$
Logarítmico	$\ln(d) = \beta_0 + \beta_1 \ln(m) + \varepsilon_i$
Parabólico	$d = \beta_0 + \beta_1 m + \beta_2 m^2 + \varepsilon_i$
Inverso	$\frac{1}{d} = \beta_0 + \beta_1 \left(\frac{1}{m}\right) + \varepsilon_i$

FONTE: O autor (2024).

LEGENDA: d = DAP (cm); m = área da copa (m^2); \ln = logaritmo neperiano; β_0 , β_1 e β_2 = coeficientes de regressão e, ε_i = erro associado.

Nos modelos logarítmicos, a transformação antilogarítmica pode introduzir erros sistemáticos. Portanto, é necessário utilizar um fator de correção para obter parâmetros estatísticos que permitam a comparação entre equações logarítmicas e não logarítmicas. A re-transformação logarítmica é realizada utilizando o fator de correção de Meyer, dado por:

$$Meyer = e^{0,5(S_{yx})^2} \quad (4)$$

Onde:

- e é a base do logaritmo natural;
- S_{yx} é o erro padrão da estimativa.

Segundo Machado et al. (2002), o erro padrão da estimativa (S_{yx}) mede a dispersão média entre os valores observados e estimados ao longo da linha de regressão. Além disso, para avaliar a qualidade do ajuste de um modelo de regressão, utilizamos o coeficiente de determinação (R^2), que expressa a proporção da variabilidade total da variável dependente explicada pela variável independente. No entanto, o R^2 simples pode ser otimista quando há múltiplos preditores no modelo, pois ele tende a aumentar com o número de variáveis, independentemente de estas serem relevantes ou não.

Para corrigir essa tendência e proporcionar uma medida mais realista da qualidade do ajuste, utilizamos o coeficiente de determinação ajustado ($R^2_{ajustado}$). Este coeficiente penaliza o acréscimo de variáveis que não contribuem significativamente para o modelo, ajustando-se pelo número de preditores. Portanto, após a correção da discrepância logarítmica, os parâmetros estatísticos foram recalculados utilizando as expressões para o erro padrão da estimativa e o coeficiente de determinação ajustado:

$$S_{yx_{recalculado}} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n - p}} \quad (5)$$

e

$$R^2_{ajustado} = 1 - \left(\frac{SQ_{res}}{SQ_t} \right) \cdot \left(\frac{n-1}{n-p} \right) \quad (6)$$

Onde:

- y_i é o diâmetro observado (cm);
- \hat{y}_i é o diâmetro estimado (cm);
- SQ_{res} é a soma dos quadrados dos resíduos;
- SQ_{total} é a soma total dos quadrados;
- n é o número de observações
- p é o número e coeficientes do modelo.

As análises exploratórias das variáveis trabalhadas devem seguir alguns pressupostos fundamentais da regressão linear, incluindo linearidade dos resíduos, homocedasticidade, normalidade e independência residual. Para verificar esses pressupostos, utilizamos testes estatísticos no RStudio.

A análise desses pressupostos pode ser realizada por meio da análise gráfica dos modelos ajustados. Essas análises gráficas permitem avaliar a linearidade dos resíduos e outras características importantes, como homocedasticidade, normalidade dos resíduos, e a presença de *outliers* ou pontos influentes.

O gráfico de resíduos studentizados vs. valores estimados permitem verificar as suposições de linearidade, homocedasticidade e a presença de possíveis *outliers*. Neste gráfico os resíduos padronizados são plotados contra os valores ajustados. Se a linha azul suavizada estiver próxima da linha zero, isso indica que não há uma tendência clara nos resíduos, sugerindo que a relação linear entre as variáveis independentes e dependentes foi adequadamente modelada. Além disso, a dispersão dos pontos ao longo da linha ajustada deve ser aproximadamente constante por toda a distribuição, sem um padrão evidente de aumento ou diminuição da variância, o que sugere que a suposição de homocedasticidade é razoavelmente atendida. Os limites estipulados de 2 e -2 ajudam a identificar possíveis *outliers*.

O gráfico Quantil-Quantil é utilizado para verificar a normalidade dos resíduos. Os pontos neste gráfico devem se alinhar na linha reta diagonal, indicando que os resíduos seguem uma distribuição normal.

Além das análises gráficas, utilizamos o teste de Shapiro-Wilk para avaliar a normalidade dos resíduos, o teste de Breusch-Pagan para verificar a homocedasticidade, e o teste de Durbin-Watson para examinar a independência residual.

O teste de Shapiro-Wilk é amplamente reconhecido por sua eficácia em pequenos conjuntos de dados. Este teste avalia a hipótese nula de que a amostra segue uma distribuição normal. Um valor de p superior a 0,05 indica que não podemos rejeitar a hipótese nula, sugerindo que os resíduos são normalmente distribuídos.

O teste de Breusch-Pagan, testa a hipótese nula de homocedasticidade (variância constante dos erros). Um valor de p superior a 0,05 indica que não há evidências suficientes para rejeitar a hipótese de homocedasticidade.

O teste de Durbin-Watson é utilizado para detectar a presença de autocorrelação nos resíduos de um modelo de regressão. A autocorrelação ocorre quando os resíduos não são independentes entre si, o que pode invalidar as inferências estatísticas do modelo.

Este teste avalia a hipótese nula de que não há autocorrelação entre os resíduos (correlação zero). O valor do teste de Durbin-Watson varia entre 0 e 4, onde:

- Valores próximos a 2 indicam ausência de autocorrelação;
- Valores próximos a 0 sugerem autocorrelação positiva;
- Valores próximos a 4 indicam autocorrelação negativa.

As correções aplicadas aos modelos, especialmente o uso do fator de correção de Meyer para transformações logarítmicas, foram essenciais para garantir a validade dos parâmetros estatísticos. Essas medidas permitiram um ajuste mais preciso dos modelos e proporcionaram uma base sólida para interpretações e conclusões subsequentes. Com base nesses ajustes, podemos afirmar que os modelos ajustados apresentam uma representação mais fiel das relações entre as variáveis estudadas, sendo crucial para a precisão das inferências feitas a partir dos dados.

Além das métricas mencionadas, outro critério importante utilizado na seleção de modelos é o Critério de Informação de Akaike (AIC). O AIC é uma medida da qualidade relativa de um modelo estatístico para um determinado conjunto de dados, equilibrando a qualidade do ajuste com a complexidade do modelo. O modelo com o menor valor de AIC é geralmente preferido, pois ele indica um bom equilíbrio entre o ajuste do modelo e a complexidade. Ao considerar o AIC na seleção de modelos,

podemos evitar o sobreajuste e escolher um modelo que generalize melhor para novos dados.

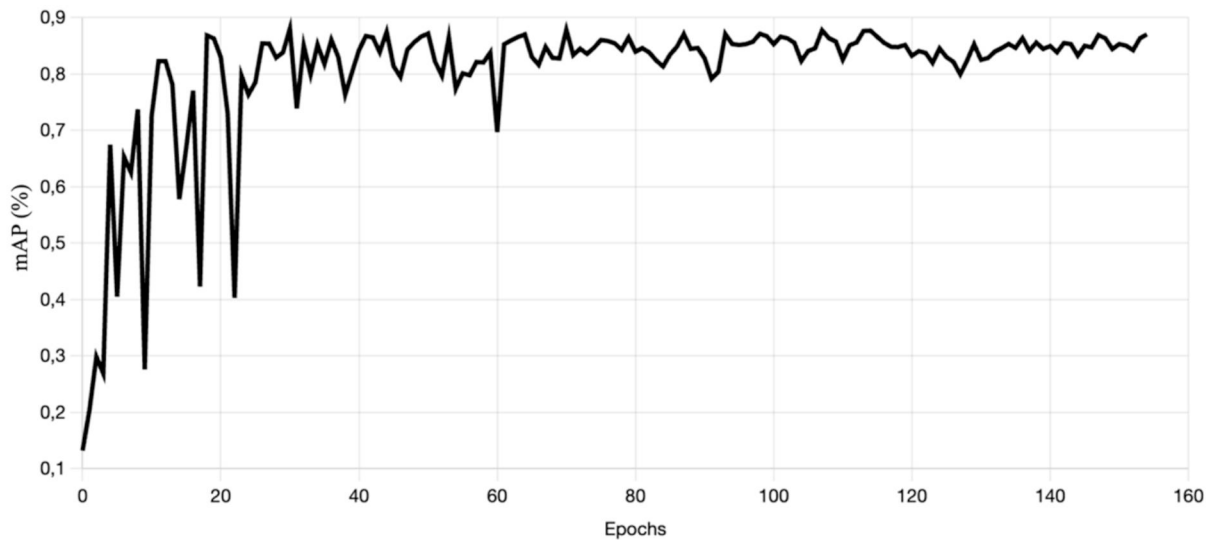
No entanto, é importante notar que os modelos logarítmico e parabólico requerem que a fórmula do AIC seja ajustada devido às transformações das variáveis. Essas transformações podem alterar a distribuição dos erros, o número de parâmetros efetivos do modelo e a função de verossimilhança. Por exemplo, a transformação logarítmica muda a escala dos dados e, conseqüentemente, a função de verossimilhança, o que deve ser refletido no cálculo do AIC. Ajustar a fórmula do AIC para esses modelos transformados é essencial para garantir uma comparação justa e precisa entre os diferentes modelos, levando em conta as novas condições impostas pelas transformações.

4 RESULTADOS

4.1 DESEMPENHO DO MODELO

O processo de treinamento foi concluído em cerca de 160 épocas. Como pode ser visto na Figura 6, o mAP não melhorou a partir da época 60. O treinamento do modelo YOLOv7 levou aproximadamente 24 horas para ser concluído. Durante a etapa de treinamento, o modelo alcançou uma precisão de 79,3%, recall de 86,8% e mAP de 87%. Essas métricas fornecem informações sobre o desempenho do modelo na detecção de araucárias nas imagens.


FIGURA 6 - DESEMPENHO DO MODELO YOLOV7 EM RELAÇÃO À MÉTRICA MAP DURANTE OS PERÍODOS DE TREINAMENTO



FONTE: O AUTOR (2024).

A Figura 7 ilustra os resultados de diferentes curvas de desempenho para o modelo YOLOv7 na identificação de *A. angustifolia* nas etapas de treinamento e validação. Com um mAP de 87%, o modelo apresentou uma baixa taxa de falsos negativos e falsos positivos, indicando precisão e recall em suas previsões. Essa pontuação sugere que o modelo possui uma capacidade robusta de identificar corretamente objetos de interesse, minimizando casos de não detecção e detecção incorreta (Kuznetsova, 2021; Shi, 2021).

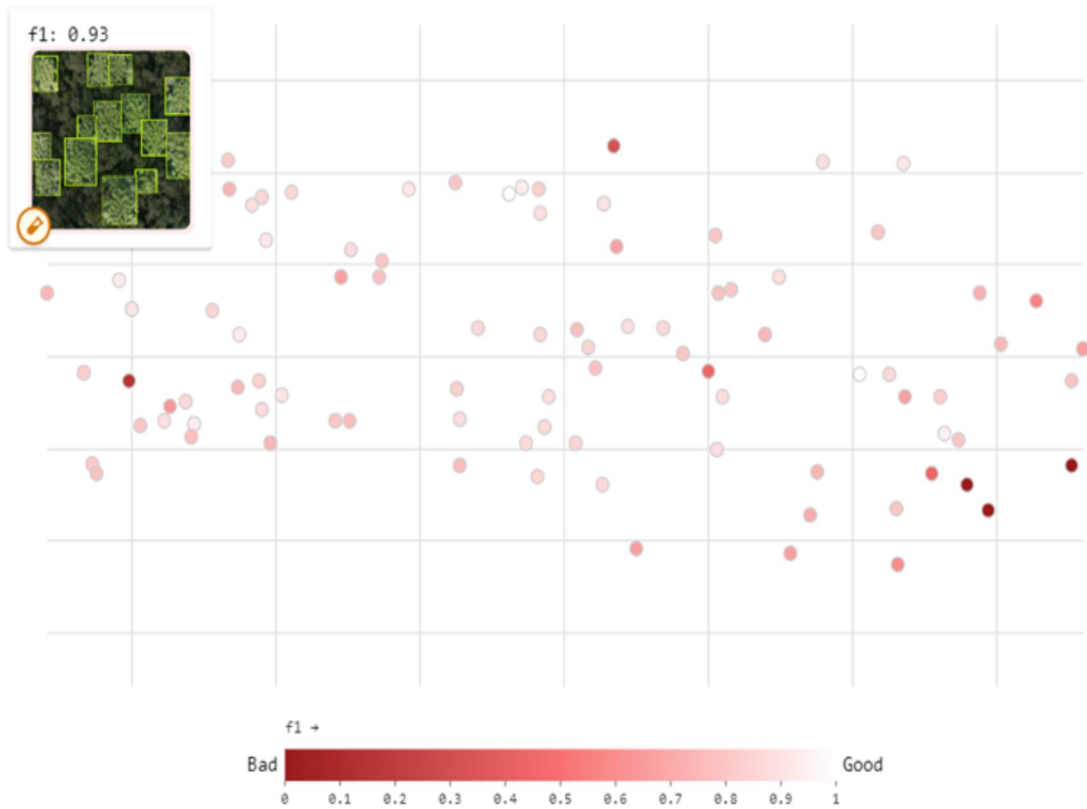
FIGURA 7 - CURVAS DE DESEMPENHO DO MODELO YOLOV7 DURANTE AS ETAPAS DE TREINAMENTO E VALIDAÇÃO



FONTE: O AUTOR (2024).

A Figura 8 mostra um gráfico de dispersão representando os F1 scores para cada imagem no modelo YOLOv7. Cada ponto no gráfico corresponde a uma imagem do teste e validação do modelo, com imagens semanticamente semelhantes (características similares) agrupadas próximas umas das outras. A coloração dos pontos reflete os F1 scores associados a cada imagem. Ao analisar os F1 scores, observou-se que cerca de 91,01% das imagens alcançaram uma pontuação acima de 60%, enquanto apenas 8,99% ficaram abaixo desse valor. A pontuação média do F1 score durante o treinamento foi de 77,16%.

Essa métrica fornece uma compreensão clara do desempenho relativo das imagens, destacando aquelas que mostraram concordância significativa entre os rótulos verdadeiros e as previsões do modelo. Além disso, essa métrica facilita a identificação de padrões ou características específicas que podem influenciar o desempenho do modelo em diferentes tipos de imagens. Essa análise oferece percepções valiosas para melhorar a eficácia do modelo YOLOv7 em outras localizações na detecção de *A. angustifolia*.


FIGURA 8 - PONTUAÇÃO F1 DO MODELO YOLOV7 PARA DETECÇÃO DE *A. angustifolia*

FONTE: O AUTOR (2024).

A mínima discrepância refere-se à diferença entre o ponto central da caixa delimitadora gerada pelo modelo YOLOv7 e a coordenada real identificada no inventário florestal de *A. angustifolia*. O maior erro mínimo encontrado foi de cerca de 5 metros entre o ponto real e o estimado pelo modelo YOLOv7. Em média, o erro foi de $1,86 \pm 1,18$ metros. Os dados obtidos no inventário florestal também revelam a área da copa (m^2) e o diâmetro à altura do peito (cm).

A representação gráfica da área da copa, bem como as estatísticas descritivas (Figura 9), é mostrada na Figura 10. A área média da copa foi de $205,52 \pm 69,64 m^2$, variando de $52,81 m^2$ a $427,36 m^2$. O DAP é apresentado em uma variedade de cores na Figura 10-A. O DAP médio da *A. angustifolia* foi de $65,20 \pm 11,42$ cm, variando de 34,47 cm a 102,81 cm.

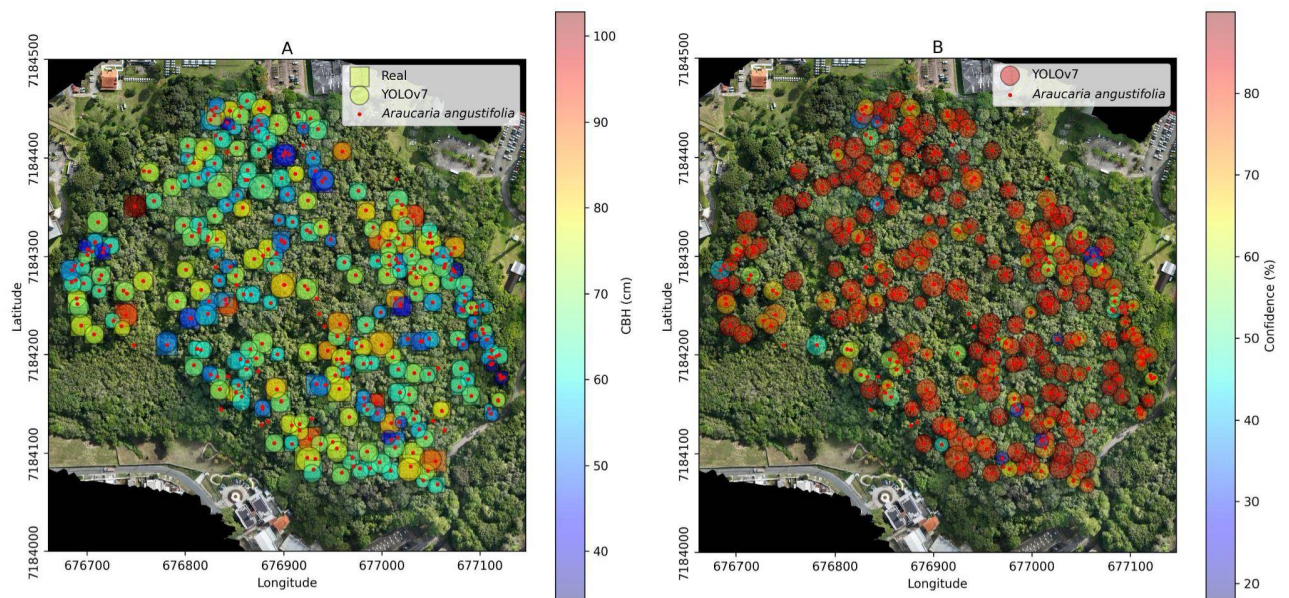
FIGURA 9 - ESTATÍSTICAS DESCRITIVAS PARA ERRO MÍNIMO, ÁREA DA COPA E DAP



FONTE: O AUTOR (2024).

A comparação final entre as árvores de *A. angustifolia* identificadas no inventário florestal e aquelas classificadas pelo modelo YOLOv7 é mostrada na Figura 10. Os pontos vermelhos indicam a posição real das árvores. Os quadrados na Figura 10-A representam a posição real das árvores com variação no tamanho da copa. Em contraste, os círculos indicam a identificação de araucárias pelo modelo YOLOv7, incluindo a variação no tamanho da copa.

FIGURA 10 – RESULTADOS DA CLASSIFICAÇÃO DO MODELO YOLOV7 NA IDENTIFICAÇÃO DE ÁRVORES DE *Araucaria angustifolia* EM UMA FLORESTA URBANA EM CURITIBA, PARANÁ, BRASIL



FONTE: O AUTOR (2024).

A Figura 10-B mostra em cores a confiança de classificação do modelo YOLOv7 para identificar as árvores de *A. angustifolia*. O resultado obtido da classificação indica uma predominância de confiança, como pode ser observado na maioria das classificações em vermelho. A confiança média de classificação do modelo YOLOv7 foi de $76,18 \pm 12,88\%$, sendo 80,81% a classificação típica para a mediana.

A classificação do modelo YOLOv7 mostrou-se satisfatória para a identificação de indivíduos de *A. angustifolia* em uma floresta urbana. A generalização do modelo pode contribuir para a gestão pública na conservação e monitoramento de espécies ameaçadas e seu manejo sustentável (Sühs et al., 2018; Orellana et al., 2021; Finger et al., 2023).

4.2 AVALIAÇÃO E COMPARAÇÃO DOS MODELOS DE REGRESSÃO

Durante o desenvolvimento do modelo de regressão linear para prever o DAP com base na área da copa (m^2), foram testadas diferentes equações para identificar a melhor abordagem (Tabela 2). Todos os modelos testados apresentaram valores de Durbin-Watson próximos de 2, indicando ausência de autocorrelação entre os resíduos das variáveis utilizadas.

TABELA 2 - MODELOS DE REGRESSÃO AJUSTADOS PARA A PREDIÇÃO DO DAP DE *Araucaria angustifolia* COM BASE NA ÁREA DA COPA, EM FRAGMENTOS DE FLORESTA OMBRÓFILA MISTA, CURITIBA, PR

Denominação	β_0	β_1	β_2	$S_{yx}\%$	R^2_{aj}	Shapiro-Wilk p-value	Breusch-Pagan p-value	Akaike (AIC)
Linear simples	46,026*	0,100*		10,983	0,471	0,262	$1,136 \cdot 10^{-4}$	1592,279
Logarítmico	2,496*	0,321*		10,734	0,495	0,603	0,205	1581,591
Parabólico	32,914*	0,226*	$-2,714 \cdot 10^{-4}$ *	10,658	0,502	0,274	0,014	1575,238
Inverso	0,011*	0,883*		10,813	0,487	0,010	0,400	1591,944

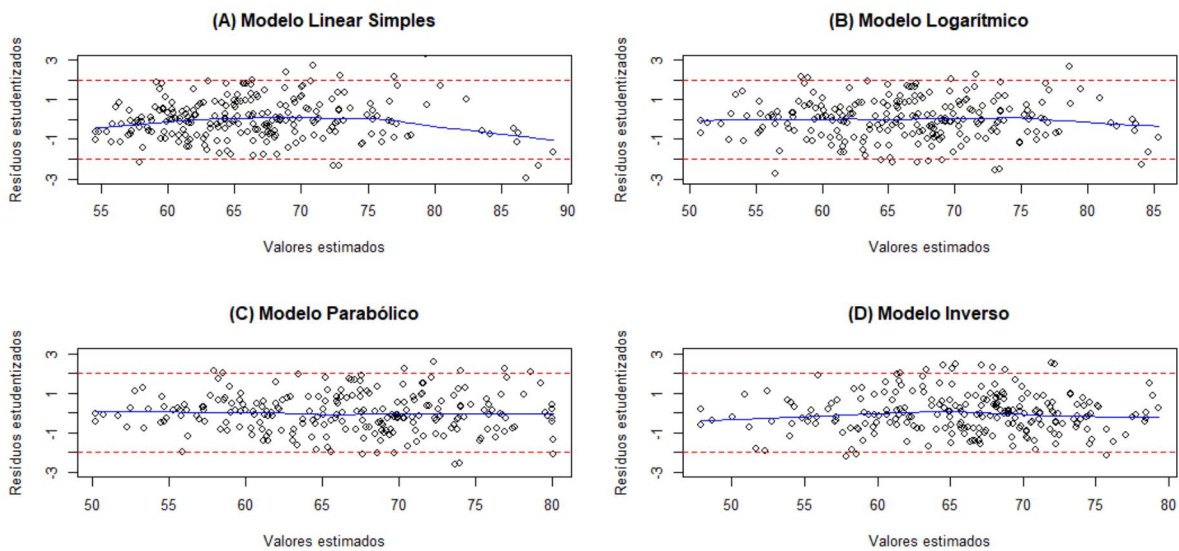
FONTE: O autor (2024).

LEGENDA: β_0 , β_1 e β_2 = coeficientes de regressão; $S_{yx}\%$ = erro padrão percentual; R^2_{aj} = coeficiente de determinação ajustado e, * = significância de 5% pelo teste t.

Após a realização dos testes, verificou-se que apenas o modelo logarítmico respeitou todas as hipóteses da regressão linear. As transformações logarítmicas

foram eficazes na linearização da relação entre as variáveis e na correção de problemas de heterocedasticidade e normalidade dos resíduos. Este modelo proporcionou um ajuste adequado e garantiu a validade dos resultados, resultando em uma análise robusta e confiável.

FIGURA 11 – GRÁFICOS DOS RESÍDUOS ESTUDENTIZADOS EM RELAÇÃO AOS VALORES ESTIMADOS DOS MODELOS DE REGRESSÃO PARA A PREDIÇÃO DO DAP DE *Araucaria angustifolia* EM FRAGMENTOS DE FLORESTA OMBRÓFILA MISTA, CURITIBA, PR



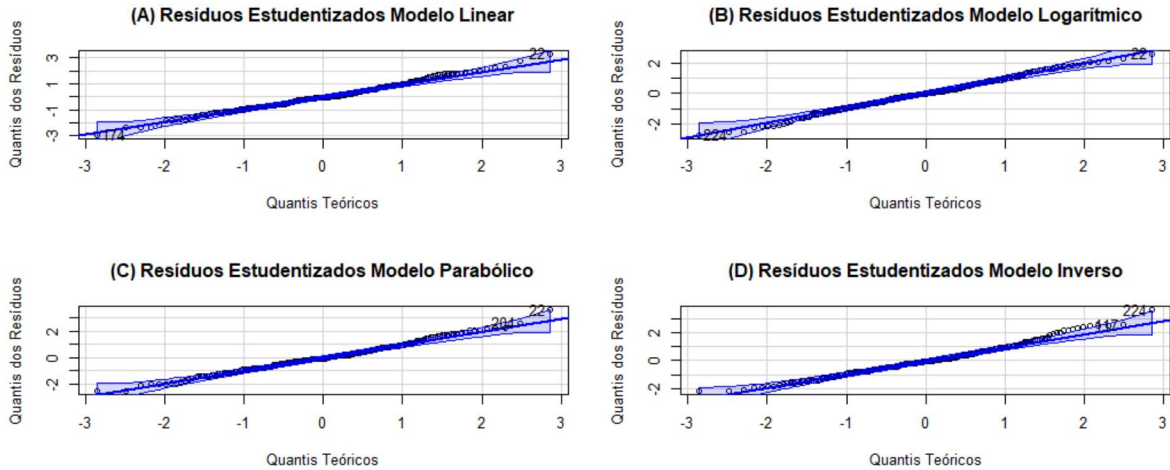
FONTE: O AUTOR (2024).

A Figura 11 permite verificar que a suposição de linearidade foi bem atendida nos modelos ajustados, exceto na Figura 11-A, que apresentou maior dispersão em torno do eixo central. Na Figura 11-A, a dispersão dos resíduos mostra uma tendência de aumento de variância, enquanto as Figuras 11-B, C e D demonstram uma dispersão constante ao longo de toda a distribuição. Esta análise é confirmada na Tabela 2 pelo teste de Breusch-Pagan. No entanto, o modelo parabólico apresentou um valor de 0,014, que é menor que o nível de significância de 0,05 do teste. Isso indica que há evidências de heterocedasticidade no modelo parabólico, com uma chance de 1,4% de cometer um erro ao concluir que há heterocedasticidade. Os limites de 2 e -2 indicados pelas linhas tracejadas sugerem que os pontos externos dessa escala podem ser possíveis *outliers*.

A Figura 12 apresenta a avaliação de normalidade dos resíduos dos modelos ajustados. Observa-se que apenas a Figura 12-D apresentou desvio de alguns pontos da faixa de normalidade. Na Tabela 2, ao aplicar o teste de Shapiro-Wilk, verificamos

que somente o modelo inverso apresentou valores abaixo do limite de 0,05, sendo 0,01. Isso indica que há apenas uma probabilidade de 1% de que os resultados observados ocorram se a hipótese nula for verdadeira.

FIGURA 12 – GRÁFICOS QUANTIL-QUANTIL (Q-Q) PARA AVALIAÇÃO DA NORMALIDADE DOS RESÍDUOS DOS MODELOS DE REGRESSÃO NA PREDIÇÃO DO DAP DE *Araucaria angustifolia* EM FRAGMENTOS DE FLORESTA OMBRÓFILA MISTA, CURITIBA, PR



FONTE: O AUTOR (2024).

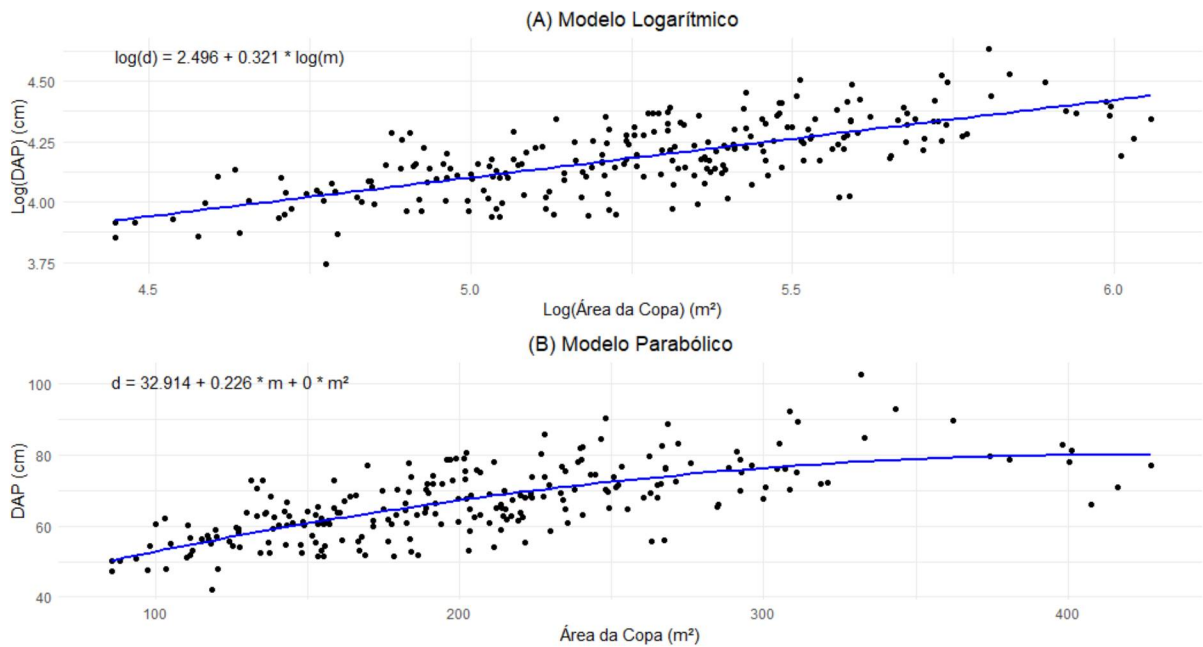
Contudo, após a adequação dos modelos propostos, observamos que os modelos parabólico e logarítmico apresentaram valores próximos tanto para a precisão ($S_{yx}\%$) quanto para o coeficiente de determinação ajustado (R^2_{aj}). No entanto, o modelo logarítmico demonstrou uma melhor adequação no teste de Breusch-Pagan, apresentando um valor superior ao nível de significância do teste estatístico. Isso indica que não podemos rejeitar a hipótese nula, sugerindo que o modelo não apresenta heterocedasticidade.

O modelo parabólico apresentou os melhores resultados para o coeficiente de determinação, precisão e teste de AIC, indicando ser o melhor modelo. No entanto, ele apresentou um valor p menor que 0,05 no teste de heterocedasticidade de Breusch-Pagan, o que pode ser justificado pela subamostragem dos dados para copas maiores que 300 m², como indicado na Figura 13-B.

Os gráficos de diagnóstico, juntamente com os resultados dos testes de Shapiro-Wilk e Breusch-Pagan, indicam que as suposições da regressão linear foram adequadamente atendidas no modelo logarítmico. As análises confirmam a linearidade, homocedasticidade, normalidade dos resíduos e independência residual.

Dessa forma, podemos concluir que o modelo ajustado é robusto e que as inferências feitas a partir dele são confiáveis (Figura 13-A).

FIGURA 13 – MODELOS DE REGRESSÃO LOGARÍTMICA E PARABÓLICA PARA A RELAÇÃO ENTRE O DAP E A ÁREA DA COPA DE *Araucaria angustifolia* EM FRAGMENTOS DE FLORESTA OMBRÓFILA MISTA, CURITIBA, PR



FONTE: O AUTOR (2024).

5 DISCUSSÃO

O estudo se baseia nos avanços das técnicas de visão computacional, particularmente a utilização do YOLOv7, para detectar e monitorar espécies de árvores, com foco específico na *Araucaria angustifolia* em um ambiente de floresta urbana. O desempenho do modelo foi avaliado usando várias métricas, demonstrando sua eficácia e confiabilidade na identificação de árvores-alvo em ecossistemas urbanos.

Este trabalho expande significativamente as aplicações da visão computacional, especialmente no contexto do YOLO, ao identificar uma árvore de importância crítica, a espécie *A. angustifolia*, que consta em listas de espécies ameaçadas. A abordagem adotada, inspirada nos avanços e *insights* fornecidos por estudos anteriores, destaca-se como uma valiosa contribuição para a conservação e monitoramento de espécies em perigo.

Comparando os resultados com estudos anteriores que utilizaram o YOLO para detecção de espécies de árvores, observou-se desempenho comparável ou superior. Prasvita et al. (2023) alcançaram valores de mAP50 e mAP95 de 85,1% e 45,7%, respectivamente, na detecção de palmeiras usando o YOLOv5. Em contraste, o modelo atingiu um mAP de 87%, indicando níveis de precisão semelhantes. Da mesma forma, Singh et al. (2023) alcançaram uma pontuação F1 de 81% na detecção de caules de mandioca com o YOLOv4, enquanto o modelo alcançou uma pontuação F1 de 87%. Essas comparações destacam a robustez e a eficácia da abordagem na identificação de espécies de árvores.

Além disso, a análise das pontuações F1 revelou que 91,01% das imagens alcançaram uma pontuação acima de 60%, com uma pontuação F1 média de 77,16%. Isso sugere uma forte concordância entre os rótulos verdadeiros e os resultados previstos para a maioria das imagens, indicando a confiabilidade do modelo.

Além da precisão da localização, o modelo exibiu um desempenho satisfatório em termos de desvio mínimo, com um erro médio de $1,86 \pm 1,18$ m entre as coordenadas previstas e reais das árvores. Esse nível de precisão é crucial para aplicações que requerem informações espaciais precisas, como inventário e manejo florestal.

Além disso, o estudo contribui para o crescente corpo de pesquisas que demonstram o potencial das técnicas de visão computacional no monitoramento

ecológico e nos esforços de conservação. Ao fornecer métodos precisos e eficientes para identificar espécies de árvores ameaçadas, como a *Araucaria angustifolia*, essa abordagem tem potencial para a conservação da biodiversidade e promover práticas sustentáveis de manejo florestal.

Os resultados obtidos estão alinhados com estudos anteriores que utilizaram o YOLO para detecção de espécies de árvores. Jemaa et al. (2023) alcançaram uma pontuação F1 de 86,24% para detecção de macieiras e uma precisão geral de 97,52% para avaliar a saúde das árvores. Da mesma forma, Abeyrathna et al. (2023) obtiveram valores de mAP50 de 84%, 86%, 90,5% e 77,5% para diferentes algoritmos YOLO na contagem de maçãs. Esses resultados coletivos destacam a versatilidade e a aplicabilidade do YOLO em tarefas de detecção de árvores em diversos ambientes ecológicos.

Em resumo, o estudo demonstra a eficácia do YOLOv7 na identificação de árvores *Araucaria angustifolia* em um ambiente de floresta urbana. O desempenho robusto do modelo, evidenciado por várias métricas, destaca seu potencial para apoiar pesquisas ecológicas, iniciativas de conservação e práticas sustentáveis de manejo florestal.

Com base nos modelos ajustados, podemos destacar que o modelo treinado pelo YOLOv7 proporciona uma base de dados robusta e adequada para a construção de modelos de regressão. A aplicação de técnicas avançadas de visão computacional, como o YOLOv7, facilita a identificação e medição de árvores, especificamente a *A. angustifolia*, em fragmentos florestais urbanos. Este método não apenas reduz significativamente o custo e o tempo necessários para a coleta de dados em campo, como também diminui a dependência de pessoal qualificado.

A capacidade de estimar os diâmetros das árvores com precisão estatística, com base nas áreas de copa, representa uma grande vantagem. Esta precisão abre possibilidades para a redução de custos operacionais associados aos inventários florestais convencionais, permitindo a obtenção de dados essenciais de maneira mais eficiente e menos onerosa.

Além disso, a precisão do modelo selecionado permite sua aplicação na estimativa de diversos atributos florestais, como a distribuição dos diâmetros da população de araucária, além dos estoques de volume, biomassa e carbono. Esta versatilidade torna os modelos treinados ferramentas valiosas para o manejo sustentável e a conservação das florestas urbanas.

É importante ressaltar que os modelos desenvolvidos (YOLOv7 e regressão) têm potencial para serem utilizados em outros remanescentes florestais. A aplicação bem-sucedida desses modelos em diferentes contextos pode contribuir significativamente para a gestão e conservação de diversas espécies florestais, ampliando os benefícios observados neste estudo.

Para futuras pesquisas, propomos a aplicação desta abordagem para a identificação e contagem de outras espécies florestais. Explorar novas abordagens para a redução de erro de identificação também é uma área promissora, assim como a investigação de outras variáveis que podem influenciar a acurácia dos modelos. Tais estudos poderiam ampliar ainda mais a eficácia e a aplicabilidade das técnicas de visão computacional e aprendizado de máquina na conservação e gestão florestal.

6 CONCLUSÃO

Este estudo desenvolveu uma metodologia para a identificação e contagem de indivíduos de *Araucaria angustifolia* em fragmentos urbanos de Floresta Ombrófila Mista, utilizando imagens aéreas obtidas por VANTs e a estrutura de rede neural YOLOv7. Os resultados demonstraram que a aplicação desta tecnologia avançada não apenas superou os desafios tradicionais da identificação de árvores em áreas urbanas, mas também proporcionou uma solução eficiente e precisa.

Primeiramente, as análises de desempenho do modelo YOLOv7 revelaram métricas satisfatórias, com destaque para a precisão e o F1 score, que confirmaram a eficácia do modelo durante as etapas de treinamento e validação. Em segundo lugar, a comparação entre as coordenadas previstas pelo modelo e as coordenadas reais do inventário florestal evidenciou uma discrepância mínima, reforçando a confiabilidade do YOLOv7 na detecção da *A. angustifolia*.

Além disso, o desenvolvimento de modelos de regressão linear permitiu avaliar a associação entre a área da copa e o diâmetro a 1,3 m das árvores. O modelo logarítmico se destacou, respeitando as suposições de linearidade, homocedasticidade e normalidade dos resíduos. Contudo, a análise também apontou para a necessidade de considerar o modelo parabólico, que apresentou melhores resultados estatísticos, como o coeficiente de determinação e o AIC. A geração de uma equação de predição confiável para o DAP é um avanço significativo, facilitando a estimativa da estrutura da população e contribuindo para o manejo sustentável e a conservação da espécie.

REFERÊNCIAS

- ABEYRATHNA, RM Rasika D. et al. Recognition and Counting of Apples in a Dynamic State Using a 3D Camera and Deep Learning Algorithms for Robotic Harvesting Systems. **Sensors**, v. 23, n. 8, p. 3810, 2023.
- AGARAP, A. F. Deep learning using rectified linear units (relu). **arXiv preprint arXiv:1803.08375**, 2018.
- ALBUQUERQUE, Rafael Walter et al. Mapping key indicators of forest restoration in the amazon using a low-cost drone and artificial intelligence. **Remote Sensing**, v. 14, n. 4, p. 830, 2022.
- ALEIXO, A. L. P. et al. Mudanças climáticas e a biodiversidade dos biomas brasileiros: passado, presente e futuro. 2010.
- BACKES, A.; NILSON, A. D. *Araucaria angustifolia* (Bert.) O. Kuntze, o pinheiro brasileiro. **IHERINGIA. Série Botânica**, 1983.
- BRASIL, Flora. em construção. 2017. **Jardim Botânico do Rio de Janeiro**, 2020.
- BRASIL. Ministério do Meio Ambiente. Proteção e recuperação da Floresta com Araucárias: governo propõe novas áreas protegidas para Paraná e Santa Catarina. DF, 2005. Disponível em: <<https://www.gov.br/mma/pt-br/noticias/governo-propoe-novas-areas-protegidas-para-parana-e-santa-catarina>>. Acesso em: 15 set. 2023.
- BUDOWSKI, Gerardo. Distribution of tropical American rainforest species in the light of successional processes. Turrialba (Costa Rica) v. 15 (1) p. 40-42, 1965.
- CAO, Lianjun; ZHENG, Xinyu; FANG, Luming. The semantic segmentation of standing tree images based on the Yolo V7 deep learning algorithm. **Electronics**, v. 12, n. 4, p. 929, 2023.
- CARVALHO, Paulo Ernani Ramalho et al. Espécies florestais brasileiras: recomendações silviculturais, potencialidades e uso da madeira. 1994.
- CASAS, Gianmarco Goycochea et al. Automatic detection and counting of stacked eucalypt timber using the YOLOv8 model. **Forests**, v. 14, n. 12, p. 2369, 2023.
- CASTELLA, P. R.; BRITZ, R. M.; MIKICH, S. B. Áreas prioritárias de Floresta com Araucária para conservação no Estado do Paraná. In: **Curitiba, Anais do IV Congresso Brasileiro de Unidades de Conservação**, p. 1677-1486, 2004.
- CHASSOT, Tatiane et al. Modelos de crescimento em diâmetro de árvores individuais de *Araucaria angustifolia* (Bertol.) Kuntze em Floresta Ombrófila Mista. **Ciência Florestal**, v. 21, n. 2, p. 303-313, 2011.

CHEN, Youliang et al. An object detection method for bayberry trees based on an improved YOLO algorithm. **International journal of digital earth**, v. 16, n. 1, p. 781-805, 2023.

CIELO FILHO, Roque; SANTIN, Dionete A. Estudo florístico e fitossociológico de um fragmento florestal urbano: Bosque dos Alemães, Campinas, SP. **Brazilian Journal of Botany**, v. 25, p. 291-301, 2002.

CI-BRASIL (CONSERVATION INTERNATIONAL DO BRASIL). Avaliação e ações prioritárias para a conservação da biodiversidade da mata atlântica e campos sulinos. Fundação SOS Mata Atlântica, Fundação Biodiversitas, IPÊ, SMA-SP & SEMAD-MG. 2000.

CUNHA, ERNANDES M. DA et al. Combining ALS and UAV to derive the height of *Araucaria angustifolia* in the Brazilian Atlantic Rain Forest. **Anais da Academia Brasileira de Ciências**, v. 95, n. 1, p. e20201503, 2023.

CURITIBA. História - Fundação e Nome da Cidade. Disponível em: <(https://www.curitiba.pr.gov.br/conteudo/historia-fundacao-e-nome-da-cidade/207#:~:text=Curitiba%20%C3%A9%20uma%20palavra%20de,o%20pinheiro%2Ddo%2DParan%C3%A1.)>. Acesso em 14 de setembro de 2023.

DA, A. CONSERVAÇÃO DA BIODIVERSIDADE. Avaliação e ações prioritárias para a conservação da biodiversidade da Mata Atlântica e Campos Sulinos. **Secretaria de Biodiversidade e Florestas (SBF), Ministério do Meio Ambiente (MMA). Brasília, 2000.**

DAINELLI, Riccardo et al. Recent advances in unmanned aerial vehicle forest remote sensing — A systematic review. Part I: A general framework. **Forests**, v. 12, n. 3, p. 327, 2021.

DANNER, Moeses Andriago; ZANETTE, Flávio; RIBEIRO, Juliana Zanetti. O cultivo da araucária para produção de pinhões como ferramenta para a conservação. **Pesquisa Florestal Brasileira**, v. 32, n. 72, p. 441-441, 2012.

DÍAZ-DELGADO, Ricardo et al. Enhancement of ecological field experimental research by means of UAV multispectral sensing. **Drones**, v. 3, n. 1, p. 7, 2019.

DWYER, B. et al. Roboflow (version 1.0)[software]. URL: <https://roboflow.com>. **computer vision**, 2022.

ECKE, Simon et al. UAV-based forest health monitoring: A systematic review. **Remote Sensing**, v. 14, n. 13, p. 3205, 2022.

ECKE, Simon et al. Towards operational UAV-based forest health monitoring: Species identification and crown condition assessment by means of deep learning. **Computers and Electronics in Agriculture**, v. 219, p. 108785, 2024.

EIRA, M. T. S. et al. Efeito do teor de água sobre a germinação de sementes de *Araucaria angustifolia* (Bert.) O. Ktze.-Araucariaceae. **Revista brasileira de sementes**, v. 16, n. 1, p. 71-75, 1994.

FARJON, A. et al. *Araucaria angustifolia*. **IUCN-International Union for Conservation of Nature and Natural Resources**, 2011.

FEDRIZZI, Joice Cristina. Análise da chuva polínica no Parque Nacional das Araucárias–Santa Catarina, Brasil. 2018.

FERRI Karlos Gil. *Araucaria angustifolia*: Botânica, Evolução e Dispersão da Espécie sob o Viés da História Ambiental Global. in *EcoDebate*, 2019.

FINGER, César Augusto Guimarães et al. Simulating sustainable forest management practices using crown attributes: Insights for *Araucaria angustifolia* trees in southern Brazil. **Forests**, v. 14, n. 7, p. 1285, 2023.

FONSECA, Carlos R. et al. Towards an ecologically-sustainable forestry in the Atlantic Forest. **Biological Conservation**, v. 142, n. 6, p. 1209-1219, 2009.

FU, Hancong et al. Automatic detection tree crown and height using Mask R-CNN based on unmanned aerial vehicles images for biomass mapping. **Forest Ecology and Management**, v. 555, p. 121712, 2024.

GALTON, Francis. Regression towards mediocrity in hereditary stature. **The Journal of the Anthropological Institute of Great Britain and Ireland**, v. 15, p. 246-263, 1886.

GARDNER, Matt W.; DORLING, S. R. Artificial neural networks (the multilayer perceptron) - a review of applications in the atmospheric sciences. **Atmospheric environment**, v. 32, n. 14-15, p. 2627-2636, 1998.

GENG, Xue et al. Hardware-aware softmax approximation for deep neural networks. In: **Computer Vision–ACCV 2018: 14th Asian Conference on Computer Vision, Perth, Australia, December 2–6, 2018, Revised Selected Papers, Part IV 14**. Springer International Publishing, p. 107-122, 2019.

GUERRA, Miguel Pedro et al. Exploração, manejo e conservação da araucária (*Araucaria angustifolia*). **Sustentável Mata Atlântica: a exploração de seus recursos florestais**, v. 1, p. 85-101, 2002.

GUTERRES, T. T. S. C. Uso de imagens aéreas obtidas por VANT em inventário florestal em uma floresta urbana no município de Belém, Pará, Brasil (Trabalho de Conclusão de Curso). Universidade Federal Rural da Amazônia, Belém, 2023.

GURGEL FILHO, O. do A. Silvica da *Araucaria angustifolia* (Bert) O. KUNTZE. In: IUFRO MEETING ON FORESTRY PROBLEMS OF THE GENUS ARAUCARIA. Curitiba. Forestry problems of the genus *Araucaria*. Curitiba: **FUPEF**, p. 29-68, 1980.

JIANG, Meichen et al. Seeing Trees from Drones: The Role of Leaf Phenology Transition in Mapping Species Distribution in Species-Rich Montane Forests. **Forests**, v. 14, n. 5, p. 908, 2023.

HADDAD, Nick M. et al. Fragmentação de Habitat e seu Impacto Duradouro nos Ecossistemas da Terra. **Science Advances**, v. 1, n. 2, p. 8-17, 2015.

HAMRAZ, Hamid et al. Deep learning for conifer/deciduous classification of airborne LiDAR 3D point clouds representing individual trees. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 158, p. 219-230, 2019.

HANI E., Um et al. Automatic Tree Counting from Satellite Imagery Using YOLO V5, SSD and UNET Models: A case study of a campus in Islamabad, Pakistan. In: **2023 3rd International Conference on Artificial Intelligence (ICAI)**. IEEE, p. 88-94, 2023.

HANSKI, Ilkka. Habitat loss, the dynamics of biodiversity, and a perspective on conservation. **Ambio**, v. 40, n. 3, p. 248-255, 2011.

HUECK, Kurt. Distribuição e habitat natural do Pinheiro do Paraná (*Araucaria angustifolia*). **Boletim da Faculdade de Filosofia, Ciências e Letras, Universidade de São Paulo. Botânica**, p. 3-24, 1953.

IMAGUIRE, N. Condições ambientais para a *Araucaria angustifolia* Bert. O. Ktze. **Dusenya, Curitiba**, v. 11, n. 3, p. 121-127, 1979.

JEMAA, Hela et al. Uav-based computer vision system for orchard apple tree detection and health assessment. **Remote Sensing**, v. 15, n. 14, p. 3558, 2023.

KLEIN, Roberto M. O aspecto dinâmico do pinheiro brasileiro. **Sellowia**, v. 12, n. 12, p. 17-44, 1960.

KNAUER, Uwe et al. Tree species classification based on hybrid ensembles of a convolutional neural network (CNN) and random forest classifiers. **Remote Sensing**, v. 11, n. 23, p. 2788, 2019.

KOELHERT, S.; DE HOLANDA FORMIGONI, M. Preservação da Mata Atlântica na Comunidade de São Luís, Santa Marida de Jetibá, ES. 2014.

KROGH, Anders. What are artificial neural networks?. **Nature biotechnology**, v. 26, n. 2, p. 195-197, 2008.

KUZNETSOVA, Anna A. Statistical precision-recall curves for object detection algorithms performance measurement. **Cyber-Physical Systems: Modelling and Intelligent Control**, p. 335-348, 2021.

LEAL, Luciana. A influência da vegetação no clima urbano da cidade de Curitiba-PR. 2012.

LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep learning. **nature**, v. 521, n. 7553, p. 436-444, 2015.

LIN, Jijing; CHEN, Xiao. Application of digital design technology in the design of intelligent agricultural machinery and equipment. **Applied Mathematics and Nonlinear Sciences**, v. 9, n. 1, 2024.

LINDENMAYER, David B.; FISCHER, Joern. **Habitat fragmentation and landscape change: an ecological and conservation synthesis**. Island Press, 2013.

LIU, Zhuang et al. A convnet for the 2020s. In: **Proceedings of the IEEE/CVF conference on computer vision and pattern recognition**. p. 11976-11986, 2022.

MA, Kaisen et al. Performance and sensitivity of individual tree segmentation methods for UAV-LiDAR in multiple forest types. **Remote Sensing**, v. 14, n. 2, p. 298, 2022.

MAACK, Reinhard. Geografia física do Estado do Paraná. **(No Title)**, 1968.

MAACK, Reinhard. Notas complementares à apresentação preliminar do mapa fitogeográfico do Estado do Paraná (Brasil). **Arquivos do Museu Paranaense**, v. 7, p. 351-361, 1949.

MAGALHÃES, Luís Mauro S. et al. Arborização e florestas urbanas-terminologia adotada para a cobertura arbórea das cidades brasileiras. **Série técnica Floresta e Ambiente**, p. 23-26, 2017.

MAIRAL, Julien et al. Convolutional kernel networks. **Advances in neural information processing systems**, v. 27, 2014.

MAMALIS, Marios et al. Deep learning for detecting verticillium fungus in olive trees: Using yolo in uav imagery. **Algorithms**, v. 16, n. 7, p. 343, 2023.

MARCHIORO, Cesar A.; SANTOS, Karine L.; SIMINSKI, Alexandre. Present and future of the critically endangered *Araucaria angustifolia* due to climate change and habitat loss. **Forestry: An International Journal of Forest Research**, v. 93, n. 3, p. 401-410, 2020.

MARTINI, Angeline; BIONDI, Daniela. Microclima e conforto térmico de um fragmento de floresta urbana em Curitiba, PR. **Floresta e Ambiente**, v. 22, n. 2, p. 182-193, 2015.

MCCULLOCH, Warren S.; PITTS, Walter. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, v. 5, p. 115-133, 1943.

MEDEIROS, João; SAVI, Maurício; DE BRITO, Bernardo Ferreira Alves. Seleção de áreas para criação de Unidades de Conservação na Floresta Ombrófila Mista. **Biotemas**, v. 18, n. 2, p. 33-50, 2005.

MEIO AMBIENTE, MMA-Ministro. Lista Oficial das Espécies da Flora Brasileira Ameaçadas de Extinção. **Instrução Normativa**, n. 06, 2008.

MEXIA, Teresa et al. Ecosystem services: Urban parks under a magnifying glass. **Environmental research**, v. 160, p. 469-478, 2018.

MIARA, I. (2021). "A dummy placeholder for the GDAL package." Disponível em: <https://pypi.org/project/osgeo/>>. Acesso em 13 de maio de 2024.

MIRAKI, Mojdeh et al. Coupling UAV and satellite data for tree species identification to map the distribution of Caspian poplar. **Landscape Ecology**, v. 39, n. 2, p. 30, 2024.

MOREIRA, Milene et al. Biodiversity and distribution of arbuscular mycorrhizal fungi in *Araucaria angustifolia* forest. **Scientia agricola**, v. 64, p. 393-399, 2007.

MOU, Chao et al. A novel efficient wildlife detecting method with lightweight deployment on UAVs based on YOLOv7. **IET Image Processing**, v. 18, n. 5, p. 1296-1314, 2024.

MULLANEY, Jennifer; LUCKE, Terry; TRUEMAN, Stephen J. A review of benefits and challenges in growing street trees in paved urban environments. **Landscape and urban planning**, v. 134, p. 157-166, 2015.

MYERS, Norman et al. Biodiversity hotspots for conservation priorities. **Nature**, v. 403, n. 6772, p. 853-858, 2000.

ORELLANA, Enrique et al. Predicting the dynamics of a native *Araucaria* forest using a distance-independent individual tree-growth model. **Forest Ecosystems**, v. 3, p. 1-11, 2016.

PALUDO, Rafael; COSTABEBER, José Antônio. Sistemas agroflorestais como estratégia de desenvolvimento rural em diferentes biomas brasileiros. **Revista Brasileira de Agroecologia**, v. 7, n. 2, p. 63-76, 2012.

PARDINI, Renata et al. Beyond the fragmentation threshold hypothesis: regime shifts in biodiversity across fragmented landscapes. **PloS one**, v. 5, n. 10, p. e13666, 2010.

PEARSON, Karl. Contributions to the mathematical theory of evolution. **Philosophical Transactions of the Royal Society of London. A**, v. 185, p. 71-110, 1894.

PINTO, Luiz Paulo et al. Mata Atlântica Brasileira: os desafios para conservação da biodiversidade de um hotspot mundial. **Biologia da conservação: essências. São Carlos: RiMa**, p. 91-118, 2006.

PRASVITA, Desta Sandya; ARYMURTHY, Aniat Murni; CHAHYATI, Dina. Deep Learning Model for Automatic Detection of Oil Palm Trees in Indonesia with YOLO-V5. In: **Proceedings of the 8th International Conference on Sustainable Information Engineering and Technology**. p. 39-44, 2023.

PUTRA, Yoga Cahya; WIJAYANTO, Arie Wahyu. Automatic detection and counting of oil palm trees using remote sensing and object-based deep learning. **Remote Sensing Applications: Society and Environment**, v. 29, p. 100914, 2023.

RANTA, Pertti et al. The fragmented Atlantic rain forest of Brazil: size, shape and distribution of forest fragments. **Biodiversity & Conservation**, v. 7, p. 385-403, 1998.

REDMON, J. You only look once: Unified, real-time object detection. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. 2016.

RIBEIRO, Milton Cezar et al. The Brazilian Atlantic Forest: How much is left, and how is the remaining forest distributed? Implications for conservation. **Biological conservation**, v. 142, n. 6, p. 1141-1153, 2009.

ROSENBLATT, Frank. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, v. 65, n. 6, p. 386, 1958.

RUSSELL, Stuart J.; NORVIG, Peter. **Inteligência artificial**. Elsevier, 2004.

SAAD, Felipe et al. Detectability of the Critically Endangered *Araucaria angustifolia* Tree Using Worldview-2 Images, Google Earth Engine and UAV-LiDAR. **Land**, v. 10, n. 12, p. 1316, 2021.

SANTIN, Dionete Aparecida. **A vegetação remanescente do município de Campinas (SP): mapeamento, caracterização fisionômica e florística, visando a conservação**. Tese de Doutorado – Universidade Estadual de Campinas (UNICAMP), São Paulo, 1999.

SANTOS, Anderson Aparecido dos et al. Assessment of CNN-based methods for individual tree detection on images captured by RGB cameras attached to UAVs. **Sensors**, v. 19, n. 16, p. 3595, 2019.

SCHEEREN, Luciano Weber et al. Crescimento em altura de *Araucaria angustifolia* (Bert.) O. Ktze. Em três sítios naturais, na região de Canela-RS. **Ciência Florestal**, v. 9, n. 2, p. 23-40, 1999.

SHI, Zihong. Object detection models and research directions. In: **2021 IEEE International Conference on Consumer Electronics and Computer Engineering (ICCECE)**. IEEE, p. 546-550, 2021.

SILVA, Alessandra Leite da et al. Classificação de fragmentos florestais urbanos com base em métricas da paisagem. **Ciência Florestal**, v. 29, n. 3, p. 1254-1269, 2019.

SILVA, Cesar Aparecido et al. Diagnóstico da restinga de Pontal do Paraná, litoral paranaense, através da utilização de drones. **Revista Técnico-Científica**, n. 14, 2018.

SOARES, Ronaldo Viana. Considerações sobre a regeneração natural da *Araucaria angustifolia*. **Floresta**, v. 10, n. 2, 1979.

SUN, Chenxin et al. Individual tree crown segmentation and crown width extraction from a heightmap derived from aerial laser scanning data using a deep learning framework. **Frontiers in plant science**, v. 13, p. 914974, 2022.

TAGLIARI, Mario M. et al. Disrupting a socio-ecological system: could traditional ecological knowledge be the key to preserving the Araucaria Forest in Brazil under climate change?. **Climatic Change**, v. 176, n. 2, p. 2, 2023.

TAGLIARI, Mario M. et al. Relict populations of *Araucaria angustifolia* will be isolated, poorly protected, and unconnected under climate and land-use change in Brazil. **Biodiversity and Conservation**, v. 30, n. 12, p. 3665-3684, 2021.

THAPA, Shangharsha; GARCIA MILLAN, Virginia E.; EKLUNDH, Lars. Assessing forest phenology: a multi-scale comparison of near-surface (UAV, spectral reflectance sensor, phenocam) and satellite (MODIS, sentinel-2) remote sensing. **Remote Sensing**, v. 13, n. 8, p. 1597, 2021.

VENTURIERI, Adriano; DOS SANTOS, João Roberto. Técnicas de classificação de imagens para análise de cobertura vegetal. 1998.

LUN, Zhao et al. Skip-YOLO: Domestic garbage detection using deep learning method in complex multi-scenes. **International Journal of Computational Intelligence Systems**, v. 16, n. 1, p. 139, 2023.

WAGNER, Fabien H. et al. Regional mapping and spatial distribution analysis of canopy palms in an amazon forest using deep learning and VHR images. **Remote Sensing**, v. 12, n. 14, p. 2225, 2020.

WANG, Jiamin et al. Individual rubber tree segmentation based on ground-based LiDAR data and faster R-CNN of deep learning. **Forests**, v. 10, n. 9, p. 793, 2019.

WANG, Jiansen et al. Tree-Level Chinese Fir Detection Using UAV RGB Imagery and YOLO-DCAM. **Remote Sensing**, v. 16, n. 2, p. 335, 2024.

WEISBERG, Sanford. Applied linear regression. John Wiley & Sons, 2005.

WREGGE, Marcos Silveira et al. Distribuição natural e habitat da araucária frente às mudanças climáticas globais. 2017.

WU, Kunjie et al. An improved YOLO model for detecting trees suffering from pine wilt disease at different stages of infection. **Remote Sensing Letters**, v. 14, n. 2, p. 114-123, 2023.

WU, Jintao et al. Extracting apple tree crown information from remote imagery using deep learning. **Computers and electronics in agriculture**, v. 174, p. 105504, 2020.

YAN, Wanqian et al. An automated hierarchical approach for three-dimensional segmentation of single trees using UAV LiDAR data. **Remote Sensing**, v. 10, n. 12, p. 1999, 2018.