

UNIVERSIDADE FEDERAL DO ACRE
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA FLORESTAL

**RECONHECIMENTO DE COPAS DE CASTANHA DO BRASIL
UTILIZANDO CNN DO YOLO NA AMAZÔNIA SUL-OCIDENTAL**

ERICA KEROLAINE MENDONÇA DOS SANTOS

DISSERTAÇÃO DE MESTRADO

RIO BRANCO-AC, BRASIL
DEZEMBRO DE 2024

UNIVERSIDADE FEDERAL DO ACRE
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA FLORESTAL

**RECONHECIMENTO DE COPAS DE CASTANHA DO BRASIL
UTILIZANDO CNN DO YOLO NA AMAZÔNIA SUL-OCIDENTAL**

ERICA KEROLAINE MENDONÇA DOS SANTOS

Dissertação apresentada ao Programa de Pós-Graduação em Ciência Florestal da Universidade Federal do Acre, como requisito parcial à obtenção do título de Mestre.

Orientador: Prof. Dr. Evandro Orfanó Figueiredo

Coorientador: Me. Mauro Alessandro Karasinski

RIO BRANCO-AC, BRASIL

DEZEMBRO DE 2024



UNIVERSIDADE FEDERAL DO ACRE
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
CENTRO DE CIÊNCIAS BIOLÓGICAS E DA NATUREZA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA FLORESTAL - PPGCIFLOR



ATA DE SESSÃO PÚBLICA DE DEFESA DE DISSERTAÇÃO DE ÉRICA KEROLAINE MENDONÇA DOS SANTOS, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO, STRICTO SENSU, EM CIÊNCIA FLORESTAL, DA UNIVERSIDADE FEDERAL DO ACRE.

Às nove horas do dia vinte de dezembro de 2024, realizou-se, de forma presencial, a Sessão Pública de Defesa de Dissertação, intitulada: "**RECONHECIMENTO DE COPAS DE CASTANHA DO BRASIL UTILIZANDO CNN DO YOLO NA AMAZÔNIA SUL-OCIDENTAL**", de autoria do (a) mestrando(a) **Érica Kerolaine Mendonça dos Santos**, discente do Programa de Pós-graduação em Ciência Florestal, da Universidade Federal do Acre - UFAC, em nível de Mestrado. Na ocasião, a Banca Examinadora esteve constituída pelos (as) membros (as): **Prof. Dr. Evandro Orfanó Figueiredo (Presidente – orientador/ CIFLOR/UFAC/Embrapa Acre)**; **Prof. Dr. Evandro José Linhares Ferreira (Membro Interno Professor CIFLOR/UFAC/INPA)**; **Prof. Dr. Hudson Franklin Pessoa Veras (Membro externo, Professor IFAC)**. Logo após a exposição oral, houve arguição pelos Examinadores e, ao final da arguição, reaberta a sessão pública, o (a) discente foi considerado (a) **APROVADA** pela Banca Examinadora. E, ao término, foi lavrada a presente Ata, que será assinada pelos avaliadores.

Documento assinado digitalmente



EVANDRO ORFANO FIGUEIREDO
Data: 03/01/2025 13:21:33-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Evandro Orfanó Figueiredo
(Presidente – orientador/ CIFLOR/UFAC/Embrapa Acre)

Documento assinado digitalmente



EVANDRO JOSE LINHARES FERREIRA
Data: 03/01/2025 13:31:52-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Evandro Jose Linhares Ferreira
(Professor Membro Interno Professor CIFLOR - INPA)

Documento assinado digitalmente



HUDSON FRANKLIN PESSOA VERAS
Data: 03/01/2025 19:14:48-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Hudson Franklin Pessoa Veras
(Professor Membro Externo - IFAC)

Ficha catalográfica elaborada pela Biblioteca Central da UFAC

S237r Santos, Erica Kerolaine Mendonça dos, 1994-
Reconhecimento de copas de Castanha do Brasil utilizando CNN do Yolo na
Amazônia Sul-Occidental / Erica Kerolaine Mendonça dos Santos; Orientador:
Prof. Dr. Evandro Orfanó Figueiredo; Coorientador: Mauro Alexandre Karasinski
– 2024.
72 f.: il.; 30 cm.

Dissertação apresentada ao Programa de Pós-Graduação em Ciência
Florestal da Universidade Federal do Acre, requisito para obtenção do título de
Mestre.

Inclui anexos.

1. Inventário automatizado. 2. Detecção de árvores. 3. Deep learning e
PFNM. 4. Castanha do Brasil – Estudo. I. Figueiredo, Evandro Orfanó
(orientador). II. Karasinsk, Mauro Alexandre (coorientador). III. Título.

CDD: 634.575

Bibliotecário: Marcelino G. M. Monteiro CRB-11º/258.

AGRADECIMENTOS

Agradeço primeiramente aos céus, por me permitirem chegar até aqui, superando os desafios e alcançando este marco tão significativo. Ao meu filho Benício Gael que, apesar da pouca idade, me apoiou incondicionalmente, fornecendo carinho e afeto em todas as fases desta jornada. Agradeço também à minha querida amiga Jaquelyne Lins, que me ofereceu apoio pessoal em todos os momentos, com sua amizade leal e seu carinho, o presente que o mestrado me trouxe em forma de amizade!

Ao Fundo JBS para a Amazônia, por viabilizar e financiar a coleta de dados, sem qual este trabalho não seria possível. À equipe Geoflora, por todo o suporte na coleta e no processamento dos dados, com especial agradecimento a Caio Alexandre, pela realização dos voos para a captura das ortoimagens, e a Mauro Karasinski, por me ensinar a processar os dados e por sua valiosa coorientação durante o processo de escrita.

Agradeço de forma especial ao meu orientador, Doutor Evandro Orfanó Figueiredo, cuja orientação foi essencial para o sucesso deste trabalho. Sua dedicação incansável, sua sabedoria e seu compromisso com a excelência acadêmica foram fontes de constante inspiração. Sempre me guiou com paciência e rigor, desafiando-me a buscar a inovação e a excelência em cada etapa. A oportunidade de aprender com um profissional tão íntegro e competente foi, sem dúvida, uma das experiências mais enriquecedoras da minha vida acadêmica.

“Das árvores mais lindas, a mais
exuberante e resiliente, a majestosa,
castanheira...”

(Erica Mendonça)

SUMÁRIO

1 Introdução.....	11
2 Revisão de Literatura.....	13
2.1 Comunidades Extrativistas e Gestão da Produção de PFNMS.....	13
2.2 A Castanha do Brasil (<i>Bertholletia excelsa</i>)	15
2.3 Aeronaves Remotamente Pilotadas e Fotogrametria.....	16
2.4 Aprendizado de Máquina Aplicado à Ciência Florestal.....	18
2.4.1 Aprendizado Profundo.....	19
2.4.1.1 Redes Neurais Convolucionais	20
2.5 You Only Look Once (YOLO).....	22
3 Metodologia.....	24
3.1 Abrangência do estudo	24
3.2 Fluxo de trabalho para geração do conjunto de dados.....	27
3.3 Treinamento do algoritmo YOLOv7x	29
3.4 Treinamento do modelo.....	32
3.5 Estatística aplicada à análise dos dados.....	33
4 Resultados.....	38
4.1 Desempenho do modelo	38
5 Discussão	44
5.1 Desempenho do modelo	44
5.2 Orientar para a gestão	49
Considerações Finais	53
Reconhecimentos.....	65
Material Suplementar	65
Apêndices	65
Anexos.....	66

Reconhecimento de Copas de Castanha do Brasil Utilizando CNN do YOLO na Amazônia Sul-Occidental

Erica Kerolaine Mendonça dos Santos^a, Evandro Orfanó Figueiredo^b, Mauro Alessandro Karasinski^c

^aPrograma de Pós-Graduação em Ciência Florestal, Universidade Federal do Acre (UFAC), BR 364, km 4, Distrito Industrial, CEP 69920-900, Rio Branco, Acre, Brasil

^bEmpresa Brasileira de Pesquisa Agropecuária - Embrapa- Acre, Rodovia BR-364, Km 14, Rio Branco - AC, CEP 69900-970

^cBIOFIX Research Center, Federal University of Parana, Curitiba – PR, CEP 80210-170, Brazil

Resumo

A castanha-da-Amazônia (*Bertholletia excelsa* Bonpl.) é um valioso produto florestal não madeireiro (PFNM) da região amazônica, que enfrenta desafios no manejo sustentável, necessitando equilibrar a maximização da produtividade com a sua conservação. O objetivo do estudo é avaliar o método de mapeamento de árvores de castanheira em florestas nativas na Amazônia, utilizando ortoimagens obtidas por drones (UAS) e o algoritmo YOLO v7x. Para a formação do *dataset* de treinamento, foram coletadas imagens aéreas em diferentes sítios que geraram ortoimagens de florestas com inventário, além da apropriação de coordenadas geográficas em campo de todas as árvores do experimento. Em seguida, ortoimagens, as copas foram identificadas, recortadas e anotadas, permitindo o treinamento dos algoritmos em *Pytorch*. O modelo foi treinado em duas bases de dados distintas: a primeira com classe única (castanheiras) e outra com múltiplas classes (22 espécies arbóreas). As métricas de desempenho, como precisão, *recall* e *F1-score*, mostraram resultados mais robustos no treinamento com múltiplas classes, indicando maior capacidade de generalização e precisão na detecção, especialmente para árvores com maior área de projeção de copa (APC). O algoritmo treinado com múltiplas classes alcançou uma precisão de treinamento 92% e de teste de 80% para a castanheira, com baixo índice de confusões, enquanto o treinamento para a classe única obteve uma precisão de 96% de treinamento e 17% em teste, apresentando um número elevado de copas confundidas. O uso de técnicas de visão computacional para a detecção de copas a partir de ortoimagem se revela uma ferramenta poderosa no auxílio ao planejamento florestal e ao manejo sustentável da castanheira.

Palavras-chave: Inventário automatizado, Detecção de árvores, *Deep learning* e PFNM.

Abstract:

The Brazil nut tree (*Bertholletia excelsa* Bonpl.) is a valuable non-timber forest product (NTFP) from the Amazon region, facing challenges in sustainable management that require balancing productivity maximization with conservation. The objective of this study is to evaluate a method for mapping Brazil nut trees in native Amazonian forests using orthoimages obtained by drones (UAS) and the YOLO v7x algorithm. For the training dataset, aerial images were collected at different sites, generating orthoimages of forests with inventory data, along with the collection of geographic coordinates of all trees in the field experiment. Subsequently, tree crowns were identified, cropped, and annotated in the orthoimages, enabling the training of algorithms in Pytorch. The model was trained on two distinct datasets: one with a single class (Brazil nut trees) and another with multiple classes (22 tree species). Performance metrics such as precision, recall, and F1-score showed more robust results in the training with multiple classes, indicating greater generalization capacity and detection accuracy, especially for trees with larger crown projection areas (CPA). The algorithm trained with multiple classes achieved a training precision of 92% and a test precision of 80% for Brazil nut trees, with a low rate of confusion, while the single-class training achieved a training precision of 96% and a test precision of 17%, showing a high number of misidentified crowns. The use of computer vision techniques for crown detection from orthoimages proves to be a powerful tool in aiding forest planning and the sustainable management of Brazil nut trees.

Keywords: Automated inventory, Tree detection, Deep learning, NTFP.

Resumo gráfico




Figura 1- Resumo gráfico do estudo.

Introdução

As cadeias produtivas dos produtos florestais não madeireiros (PFNMs) são atividades de desenvolvimento sustentável, com produção que auxilia na manutenção dos serviços ecossistêmicos das florestas e a bioeconomia local (Sacande e Parfondry, 2018; Araújo *et al.*, 2024). O uso desses recursos como fonte de renda é expressivo em comunidades tradicionais e território de povos nativos na Amazônia (Araújo *et al.*, 2024).

Entre os PFNMs, a Castanha do Brasil produzida em árvores de *Bertholletia excelsa* Bonpl. merece destaque pela grande contribuição econômica na cesta de produtos do extrativismo na Amazônia (Batista *et al.*, 2019).

Entretanto, a maximização do nível anual de produção de frutos e a manutenção da sustentabilidade ecológica da árvore são grandes desafios para a comercialização (Kainer, Wadt e Staudhammer, 2007). Uma alternativa para subsidiar a sustentabilidade da cadeia produtiva é a expansão da área de extração na floresta para a coleta dos frutos bem como a organização das atividades econômicas via cooperativismo (Silva, *et al.*, 2019; Fibich *et al.*, 2016; Staudhammer, Kainer, Wadt e Cunha, 2021).

A floresta amazônica possui extensas áreas de floresta nativa com ocorrência de árvores de *B. excelsa* apresentando grande potencial para aumento da produtividade de frutos. Entretanto, sua ocorrência nas florestas é variável a depender da tipologia florestal e da influência ancestral humana na área, sendo que o uso de metodologias tradicionais de mapeamento de árvores como transectos influencia na detecção das árvores (Wadt, Kainer e Silva, 2005; Munaretti, Wadt e Papa, 2016; Silva, *et al.*, 2019; Wadt *et al.*, 2023). Neste caso, o real potencial produtivo de frutos de *B. excelsa* pode ser desconhecido por comunidades extrativistas e demais *stakeholders* (Ferreira *et al.*, 2021).

Neste caso, percebe-se um modelo, desenvolvido a partir de uma rede neural artificial, e treinado no contexto de inteligência artificial com aprendizado profundo de máquina, de forma a criar um sistema adaptativo por meio do qual as máquinas aprendem com os erros, aprimorando-se continuamente (Izbicki e Mendonça, 2020, p.162; Huang, *et al.*, 2023; Kipli, Zen e Chin, 2023).

Existem inúmeros algoritmos de aprendizado profundo de máquina, dentre eles o Yolo (You Only Look Once). O YOLO é uma família de algoritmos que utiliza as redes neurais convolucionais para a detecção de objetos, avançado em termos de velocidade e precisão quando comparado a outros algoritmos similares (Ji, Ling, Han, 2023). O YOLO versão 7X (YOLOv7X) apresenta uma arquitetura mais profunda e robusta, incorporando camadas adicionais e estratégias avançadas de treinamento, permitindo inferências mais precisas, especialmente para objetos menores ou em cenários com alta densidade de informações (Wang, Bochkovskiy e Liao, 2023) como as áreas florestais.

Portanto, considerando as características de estudos específicos ao mapeamento em grandes áreas florestais, a importância de *B. excelsa* na bacia amazônica, o intuito de apoiar comunidades extrativistas na gestão e no manejo sustentável da espécie e a grande capacidade de detecção de objetos do YOLOv7X, este estudo objetivou treinar um algoritmo para torná-lo capaz de detectar indivíduos de castanheiras a partir da análise de ortoimagens obtidas por Sistemas de Aeronaves Não Tripuladas (UAS) e aprendizado profundo de máquina.

Especificamente buscou-se responder: i) é possível detectar árvores de *B. excelsa* a partir de ortoimagens analisadas por algoritmos de redes neurais convolucionais de maneira precisa? ii) de que maneira a aplicação do inventário automatizado pode auxiliar na melhoria da gestão na cadeia produtiva de *B. excelsa*?

2 Revisão de Literatura

2.1 Comunidades Extrativistas e Gestão da Produção de PFNMS

Os produtos florestais não madeireiros são alternativas econômicas viáveis para auxiliar nas estratégias de conservação da floresta amazônica, podendo ser óleos, resinas, sementes, folhas, fibras, exsudados, entre outros (Gonçalves *et al.*, 2021). Esses produtos são alternativas para diminuir os impactos negativos ocasionados nas florestas da Amazônia com as atividades relacionadas à conversão do uso do solo de florestas nativas (Wadt, Kainer e Gomes-Silva, 2005; Gonçalves *et al.*, 2021).

Os produtos florestais não madeireiros (PFNM) auxiliam na melhoria da renda dos extrativistas e na garantia de recursos para as próximas gerações, conferindo à atividade o *status* de sustentável ecologicamente correta e economicamente viável (Wadt, Kainer e Gomes-Silva, 2005 e Gonçalves *et al.*, 2021). Cada produto possui características específicas, com calendários de coleta e metodologia de exploração diferentes, bem como custos e comercialização (Giatti *et al.*, 2021 e Santos, Figueiredo e Figueiredo, 2020).

Giatti *et al.*, 2021, ao estudarem uma comunidade extrativista localizada em uma reserva de desenvolvimento sustentável na Amazônia, evidenciaram que; o preço recebido da comercialização dos PFNMs não apresenta política de preço mínimo, o que prejudica a comercialização dos mesmos, bem como, não há organização nos processos sociais para a coleta e a venda por parte da comunidade, frente à demanda crescente dos produtos oferecidos por eles, logo, falta-lhes ; gestão organizacional.

As comunidades extrativistas podem escolher o arranjo de organização social e comercial que melhor se adeque às suas necessidades, dentre estas há associações, cooperativas e outros instrumentos que permitem; organizar-se enquanto comunidade, bem como produtora de produtos e serviços florestais, sejam estes madeireiros ou não.

A cooperativa é um instrumento de grande importância para os extrativistas, uma vez que, através da mesma, a comunidade (via associação) consegue melhores condições para a comercialização dentro da cadeia produtiva em que está inserida, agregando a renda e diminuindo a incidência de atravessadores, bem como, podem obter acesso e assistência técnica e extensão rural (Silva *et al.*, 2019 e Giatti *et al.*, 2021).

Através da cooperativa é possível realizar a compra diretamente do produtor, já que, normalmente, o produtor também é cooperado, portanto ele é cliente e membro, gerando assim mais benefícios para ambos (cooperativa e cooperado) Essa modalidade de organização possibilita ainda realizar rastreabilidade da matéria-prima, fortalecendo elos da cadeia produtiva. Por meio das cooperativas, os cooperados têm acessos a capacitações e assistência técnica, o que auxilia na melhoria da gestão da cadeia produtiva através da organização social e proporciona aos mesmos melhor entendimento acerca dos benefícios, econômicos e sociais, que as atividades extrativistas desempenham (Silva *et al.*, 2019 e Gonçalves, 2021).

Quando a gestão é organizada, torna-se eficiente, permitindo assim, que as associações extrativistas consigam desenvolver sua logística de maneira a diminuir os impactos negativos no piso florestal, realizando suas atividades de coleta de maneira mais racional e programada, evitando retrabalho, garantindo confiabilidade ao processo. Quando bem gerida, a atividade extrativista se consolida e permite destaque dentro da cadeia produtiva à qual pertence. Processos de gestão eficientes facilitam a acreditação e consequentemente o acesso a selos de qualidade que permitem maior destaque internacional comunidade produtora (Silva *et al.*, 2019). Uma gestão que leve em consideração os aspectos inerentes à espécie, como: crescimento, mortalidade, dispersão, tipologia florestal, que realiza monitoramentos contínuos ajustados à a coleta ecológica e sustentável, permite

melhoria no monitoramento da produtividade florestal ao longo dos anos (Wadt, Kainer, Gomes-Silva, 2005).

2.2 A Castanha do Brasil (*Bertholletia excelsa*)

Trata-se de uma espécie arbórea pertencente à família botânica *Lecythidaceae*, secundária tardia, conhecida vernaculamente como “castanha-do-brasil ou Castanha do Brasil” e encontrada em florestas não inundáveis no Brasil, com distribuição natural em todos os estados da região norte e no estado de Mato Grosso, com domínio fitogeográfico Amazônia (Catenacci, *et al.*, 2023).

As árvores renovam suas folhas próximo ao início do período chuvoso, dispersando seus frutos no período de novembro a março (Santos, Figueiredo e Figueiredo, 2020). Os frutos são dispersos por roedores, sendo que, alguns são enterrados e eventualmente esquecidos, auxiliando no processo de germinação da espécie (Wadt, *et al.*, 2018).

Há evidências significativas da relação entre dispersão e ação antrópica de *B. excelsa* (Wadt, *et al.*, 2018), o que consequentemente influencia no padrão de distribuição espacial da espécie. Os estudos de Batista *et al.*, (2019) relatam que, de acordo com o tipo de floresta, haverá diferentes associações espaciais para a espécie, “havendo assim necessidade da adoção de diferentes estratégias de manejo e conservação para as espécies arbóreas em relação ao tipo de floresta”.

A *B. excelsa* é um dos principais PFNMs da América do Sul, sua extração é basicamente realizada em florestas naturais, sua comercialização é expressiva, tanto em nível nacional quanto para exportação (Ferreira, *et al.*, 2021). Atualmente um dos maiores desafios relacionados à cadeia produtiva é a relação entre maximização da produtividade e sustentabilidade ecológica da árvore (Batista, *et al.*, 2021). Um ponto chave que pode auxiliar no aumento da produtividade é a elaboração de metodologias que mapeiam de maneira eficiente extensas áreas de floresta com vistas a identificar indivíduos produtivos

(Batista, *et al.*, 2021) não mapeados por comunidades através das metodologias tradicionais (transectos).

2.3 Aeronaves Remotamente Pilotadas e Fotogrametria

A Agência Nacional de Aviação Civil, classifica as aeronaves remotamente pilotadas (Unmanned Aircraft System – UAS do inglês), como sendo aquelas destinadas a usos experimentais, institucionais ou comerciais. Existem inúmeras marcas e modelos que podem ser utilizados no ambiente institucional para a promoção da ciência.

O uso de UAS é uma parte importante para a realização de levantamentos florestais modernos, bem como se tornaram aeronaves que estão ganhando mais autonomia de voo com a evolução dos modelos, facilitando assim os processos de coleta de dados (Kukkonen *et al.*, 2021). Para escolher a marca e o modelo que melhor se adeque às necessidades do estudo, faz-se necessário conhecer as vantagens e limitações que cada categoria tem, para assim, de acordo com os objetivos do trabalho, realizar uma escolha mais adequada de aeronave.

Dentre os inúmeros modelos têm-se os Mavic 2 e 3Pro. A UAS possui tecnologia de prevenção à colisão frontal e traseira; utiliza o sistema de posicionamento global e o sistema global de navegação por satélite (GNSS), Mavic 2 com GPS e GLONASS e Mavic 3 com GPS, Galileo e BeiDou (DJI, 2023). “O Mavic usa o sistema de satélite duplo para ajudar com precisão voando e retorno para casa, prevenção de obstáculos, pontos de passagem, pontos de interesse e muito mais” (Vellemu *et al.*, 2021). Esses fatores são importantes para evitar acidentes durante a realização dos voos, processos de decolagem e aterrissagem (DJI, 2023 e Vellemu *et al.*, 2021).

O estudo de Vellemu *et al.* (2021), evidenciou que, comparado a outros modelos, o Mavic 2 Pro, demonstrou mais agilidade nos processos de coleta, bem como seu sistema de prevenção de obstáculos auxiliou no impedimento de um acidente de trabalho durante as

operações de voo, demonstrando ser um equipamento adequado para coletas na área ambiental.

O processo de automação nas atividades relacionadas ao ambiente florestal, permite maior agilidade na coleta de dados, fornecendo informações de alta qualidade quando bem planejadas e executadas, auxiliando assim na tomada de decisões. Para a utilização de aeronaves remotamente pilotadas, necessita-se realizar a regularização da aeronave e o plano de voo, considerando-se que essa atividade envolve: regularização da radiofrequência, registro da aeronave e registro e autorização da missão de voo (Figueiredo *et al.*, 2020).

Para a realização do projeto do plano de voo é necessário identificar a localização da área de interesse, fazer os cálculos dos parâmetros fotogramétricos e escolher o aplicativo de voo. Após essas etapas, é realizada a execução das missões de voo do projeto. Deve-se coletar *ground control points*, em caso de intempéries e perda de equipamento (Figueiredo *et al.*, 2020). Após completadas as atividades de voo, será necessário processar os dados coletados.

O processamento das imagens aéreas obtidas por aeronaves remotamente pilotadas, deve ser efetuado via *software* para fotogrametria digital, levando-se em conta que existem vários no mercado disponíveis para uso (Figueiredo *et al.*, 2020). Os algoritmos de fotogrametria permitem a extração de características que não variam em função à rotação da imagem; dessa forma, para que seja possível o processamento adequado, as imagens devem ser de alta qualidade e sem efeito de rolamento do pixel (Figueiredo *et al.*, 2020). “O processamento fotogramétrico avançado que permite a realização do processamento da ortoimagem tem a finalidade de facilitar a localização geográfica das árvores dominantes e codominantes e vetorizar a área de cada copa individualmente” (Figueiredo *et al.*, 2020).

Para obter atributos de árvores necessários, deve-se realizar processamento analítico adicional à nuvem de pontos a um custo razoável (tempo de processamento) para grandes

áreas (Zhang *et al.*, 2023). Através da utilização da ortoimagem é possível realizar fotointerpretação de árvores individuais utilizando-se a classificação orientada a objetos - GEOBIA ou por algoritmos de aprendizado profundo de máquina (Figueiredo *et al.*, 2020).

2.4 Aprendizado de Máquina Aplicado à Ciência Florestal

A inteligência artificial é uma área multidisciplinar; em sua essência pode ser definida como a capacidade de os sistemas tomarem decisões de forma independente, precisa e apoiada em dados digitais (Guido, 2016). A inteligência artificial é composta por subáreas, dentre elas a de aprendizado de máquina e aprendizado profundo.

O aprendizado de máquina (*machine learning*) é uma área de pesquisa relacionada à estatística e à ciência da computação—é responsável basicamente por tomar decisões a partir de regras pré-estabelecidas e codificadas. Através deste há automação, que possibilita a elaboração de modelos analíticos; o sistema aprende com os dados, identifica padrões e realiza decisões, a interferência humana no processo é mínima (SAS, 2023).

Segundo o Instituto SAS (2023), para tornar possível a criação de bons sistemas de aprendizado de máquina, é necessário ter boa capacidade de *data preparation*, algoritmos básicos e avançados, processos automatizados e iterativos, escalabilidade e modelagem conjunta. “No aprendizado de máquina o alvo é denominado rótulo; uma variável em estatística é chamada de recurso e uma transformação estatística é chamada de criação de recurso em *machine learning*”.

O aprendizado de máquina possui três tipologias, o supervisionado, não supervisionado e o por reforço. O aprendizado supervisionado utiliza preditores, que são os dados de entrada com vistas a prever os dados de saída, os quais podem ser tanto qualitativos relativos à problema de classificação ou quantitativos quando há problema de previsão (Morettin 2022, p. 401). O aprendizado não supervisionado considera que todas as variáveis possuem natureza similar, não havendo distinção entre variável preditora e resposta

(Morettin 2022, p. 652). A aprendizagem por reforço é utilizada para objetivos específicos, aplicados a tarefas de constante aprendizagem e para decisões em tempo real utilizando *feedback* de informações para corrigir erros e ajustar o comportamento do modelo ao mesmo tempo que desempenha a tarefa (Karasinski, 2021). Inúmeros estudos na área florestal utilizam tanto a primeira quanto a segunda tipologia de aprendizado para a produção de dados científicos no Brasil.

Silva *et al.*, (2023) realizaram modelagem e detecção de árvores invasoras com o uso de UAS e aprendizado de máquina em floresta subtropical. Rubí *et al.*, (2023) utilizaram o aprendizado profundo para realizar estudo comportamental acerca de incêndios. Diniz *et al.*, (2021) combinaram o aprendizado profundo com dados espaciais para prever geadas em áreas de florestas plantadas. Caffaratti *et al.*, (2021) testaram diferentes algoritmos de aprendizado profundo para detectar florestas. Os estudos evidenciam que as diferentes arquiteturas de aprendizado serão adequadas para análises em ciência florestal.

2.4.1 Aprendizado Profundo

O aprendizado de máquina utiliza algoritmos para organizar dados, reconhecer padrões e produzir informações úteis para uma determinada área do conhecimento. A aprendizagem profunda é uma parte do aprendizado de máquina que utiliza algoritmos de alto nível, reproduz uma estrutura de neurônios artificiais similar ao orgânico e aprende com os dados, entende conceitos de hierarquia e é basicamente a evolução do aprendizado de máquina (Izbicki e Mendonça, 2020; Karasinski, 2021).

O aprendizado profundo tem sido utilizado em todo o globo e demonstra melhor desempenho quando comparado a outras metodologias da análise de dados; recentemente, *perceptron* multicamadas (MLPs), redes neurais artificiais (RNAs), redes neurais convolucionais (CNNs), redes neurais de aprendizagem profunda (DLNNs) (Saha *et al.*,

2023) têm sido empregados em inúmeras áreas do conhecimento, inclusive na ciência florestal. Segundo o Instituto SAS o aprendizado profundo (*deep learning*):

Combina avanços no poder computacional e tipos especiais de redes neurais para aprender padrões complicados em grandes quantidades de dados. Técnicas de *deep learning* são o que há de mais avançado hoje para identificar objetos em imagens e palavras em sons. Os pesquisadores estão tentando aplicar esses sucessos no reconhecimento de padrões em tarefas mais complexas, como na tradução automática de idiomas, diagnósticos médicos e diversos outros problemas sociais e corporativos.

O aprendizado profundo é capaz de analisar e aprender com os dados, por isso na agronomia é aplicado para inúmeras tarefas, dentre elas distinguir entre diferentes vegetações (Kipli, *et al.*, 2023); já-na ciência florestal foi utilizado para identificar e classificar espécies de *Arecaceae* em áreas de floresta na Amazônia brasileira (Ferreira *et al.*, 2020).

2.4.1.1 Redes Neurais Convolucionais

As RNAs processam dados similares à metodologia utilizada por rede neural orgânica (cérebro humano), diferindo-se, portanto, dos computadores convencionais; o sistema de processamento complexo e inúmeras vezes não linear; realiza organizações profundas através de neurônios artificiais; sua estrutura básica é formada por um *perceptron* (uma camada simples e um classificador linear binário) e quando se tem mais de uma camada denomina-se rede neural convolucional (Izbicki e Mendonça, 2020, p.162). Graficamente uma rede neural simples é composta por camada de entrada, camada oculta e camada de saída,—e na primeira encontram-se os dados fornecidos por programador, ou seja, as covariáveis do banco de dados, na segunda são realizados os processos não lineares nos neurônios artificiais e a terceira é o resultado (Izbicki e Mendonça, 2020, p.162).

A rede neural convolucional (CNN) é uma das formas mais proeminentes de redes neurais clássicas para realizar a detecção de objetos e a manutenção de informações correlacionadas aos dados abrangentes (Huang, *et al.*, 2023). As CNNS possuem expressiva capacidade de extração de informações, são compostas principalmente por camadas de

convolução e camadas de agrupamentos; quando as camadas são repetidamente aplicadas, é possível diminuir a quantidade de dados de entradas, bem como recursos úteis serão mais bem produzidos gradualmente (Huang, *et al.*, 2023).

Segundo os estudos de Huang *et al.*, (2023) as CNNs incluem três tipologias de camadas, as convolucionais, as de agrupamento e aquelas totalmente conectadas. As camadas convolucionais aprendem com as feições de entrada; as de agrupamentos podem alcançar invariância de deslocamento e resolução dos mapas de feições, o que normalmente ocorre entre duas camadas convolucionais; quando há uma, duas ou mais camadas trabalhando inter-relacionadas com vistas a executar raciocínio de alto nível, têm-se camadas totalmente conectadas; e a última camada da CNN é denominada camada de saída.

Ao utilizar CNNs há inúmeras abordagens a serem consideradas, as mais comuns são; segmentação semântica, segmentação de instância e detecção de objetos. A utilização de uma abordagem ou outra dependerá do objetivo da pesquisa a ser desenvolvida, considerando-se que, no presente projeto de pesquisa, optou-se por utilizar a detecção de objetos (alvos).

A segmentação semântica realiza a classificação pixel a pixel em uma imagem de acordo com conjuntos de classe e estudos na área da ciência florestal demonstram (>80%) alta taxa de classificação (Veras *et al.*, 2022). A segmentação de instâncias detecta cada objeto individual entre objetos semelhantes.

A detecção de objeto primeiramente realiza a etapa de aprender o que é o objeto para depois classificá-lo, sendo subdividida em duas categorias: a primeira é *region proposals* em que o algoritmo encontra regiões da imagem onde haverá o objeto; e a segunda, o *classification-based methods*, é o processo agnóstico de localizar o objeto dentro da imagem, com base no aprendizado das características individuais do alvo; ao se utilizar a segunda categoria é possível o uso do *You Only Look Once (YOLO)* (Macarini, 2021).

2.5 You Only Look Once (YOLO)

A detecção de objetos é um constituinte de grande importância para a visão computacional, podendo ser aplicada para a realização de interações entre textos e objetos ou para rastreá-los (Ji *et al.*, 2023), e, em vista disso, o presente estudo visa a utilização do segundo (rastrear objetos). A utilização do YOLO é crescente entre os cientistas, podendo ser observada sua utilização em diferentes áreas do conhecimento. O Yolo é uma família de algoritmos que procura solucionar problemas de regressão para objetos (Ji *et al.*, 2023).

O algoritmo YOLO é um sistema de detecção de objetos de última geração que utiliza uma série de algoritmos de detecção de objetos em tempo real desenvolvido por Joseph Redmon em 2015. O algoritmo utiliza as redes neurais convolucionais para a detecção de objetos em passada única (Rios, 2022) prevendo a probabilidade de existirem objetos desejados e a sua classificação (Redmon, 2016).

Quando comparado a outros algoritmos similares, em geral, o YOLO apresenta maior velocidade de detecção e classificação, bem como precisão. Entretanto, para pequenos objetos com resolução limitada da imagem, o mesmo apresenta alta taxa de detecção de erros devido às limitações como: poucas expressivas características, o que pode aumentar a taxa de erros de detecção (Ji, *et al.*, 2023).

Há um grande número de recursos através do YOLO capazes de melhorar a precisão da CNN para pequenos objetos, desde que suas características sejam bem delimitadas. Devido às melhorias da estrutura no algoritmo, a versão quatro do mesmo possui melhores resultados quando comparada às versões anteriores e a outras arquiteturas (Bochkvskiy *et al.*, 2020).

Em sua versão 7 (YOLOv7), o mesmo introduz várias inovações para aprimorar a eficiência e a precisão dos detectores em tempo real. Algumas das principais melhorias incluem: *trainable bag-of-freebies*, modelos escalonáveis, reparametrização planejada,

atribuição de rótulos *coarse-to-fine* e eficiência computacional (Wang, Bochkovskiy, Liao, 2022).

O *trainable bag-of-freebies*, refere-se às técnicas otimizadas para o processo de treinamento que aumentam a precisão sem impactar os custos de inferência. Os modelos escalonáveis estão relacionados ao uso de "*extended efficient layer aggregation networks* (E-ELAN)", que melhora o aprendizado de recursos ao ajustar a cardinalidade e o uso de convoluções em grupo. A reparametrização planejada está relacionada às estratégias específicas para substituir módulos na arquitetura, otimizando a propagação de gradientes. A atribuição de rótulos *coarse-to-fine* é um método de geração de rótulos que equilibra a precisão e o *recall* para diferentes camadas de saída. E a eficiência computacional reduz significativamente o número de parâmetros e operações sem sacrificar a precisão computacional (Wang, Bochkovskiy, Liao, 2022).

O YOLOv7x é uma variante escalonada do YOLOv7, que visa atender demandas de detecção mais exigentes. Ele utiliza uma maior profundidade e largura nos blocos computacionais, alcançando melhores desempenhos em termos de precisão de detecção. A arquitetura otimizada mantém um bom equilíbrio entre velocidade de inferência e eficiência de cálculo, com um aumento notável na precisão geral, especialmente em tarefas computacionais mais complexas (Wang, Bochkovskiy, Liao, 2022). Comparado com seus antecessores e concorrentes (Wang, Bochkovskiy, Liao, 2022).

Portanto, o YOLOv7 solidifica sua posição como um marco na evolução de detectores de objetos, oferecendo uma solução poderosa para cenários em que precisão e eficiência são cruciais. Este trabalho pavimenta o caminho para futuras pesquisas, destacando áreas de otimização arquitetural e treinamento eficaz como pilares para inovações na visão computacional.

3 Metodologia

3.1 Abrangência do estudo

O estudo foi conduzido em 18 áreas de floresta nativa variando de 191 a 339 ha totalizando 18.023,20 ha sobrevoados e abrangendo os estados do Acre, Amazonas e Rondônia (Figura 1). Em cada área, a localização geográfica das árvores de *B. excelsa* foi obtida com receptores do Sistema Global de Navegação por Satélite (GNSS), provenientes dos dados do inventário florestal.




Figura 2- Mapa de localização das áreas de estudo - base de dados Geoflora (Geotecnologias aplicadas à automação florestal e espacialização dos estoques de carbono em uso nativo e modificado da terra na Amazônia Ocidental – Anexo 01) (2024), em A – As áreas de estudo localizadas nos estados do Acre, Amazonas e Rondônia; em B – Área de teste na Embrapa-Acre; em C – Detalhe das copas com identificação do nome vernacular.

A localização das áreas de estudo e a tipologia florestal são apresentadas no Quadro

1. Cada sítio possui uma população finita de *B. excelsa*, cuja copa da árvore é a unidade amostral.

Quadro 1: Número de copas de árvores de *B. excelsa* (n) utilizadas no treinamento do algoritmo YOLOv7X.

Sítio	Estado	Município	n	Tipologia Florestal	PMFS
01	Acre	Rio Branco	746	FOD+FAB	Não
02	Acre	Bujari	134	FOAP	Não
03	Acre	Porto Acre	11	FOAB	Sim
04	Acre	Porto Acre	14	FOAB	Sim
05	Acre	Rio Branco	8	FOAB	Sim
06	Acre	Rio Branco	46	FOD+FOAB	Não
07	Acre	Rio Branco	169	FOD	Sim
08	Acre	Rio Branco	145	FOD	Não
09	Acre	Senador Guimard	410	FOD+FOAB	Sim
10	Acre	Rio Branco	22	FOD	Não
11	Acre	Rio Branco	82	FOD	Não
12	Acre	Xapuri	800	FOD+FOAB	Sim
13	Acre	Plácido de Castro	16	FOATBB	Não
14	Amazonas	Lábrea	77	FOD	Sim
15	Rondônia	Espigão do Oeste	14	FOD	Sim
16	Rondônia	Candeias do Jamari	1	FOD	Sim
17	Rondônia	Jaquirana	136	FOD	Sim
18	Rondônia	Jaquirana	172	FOAAP+FOD	Não
Somatório			3003		

Em que: FOD = Floresta Ombrófila Densa, FOAB = Floresta Ombrófila Aberta com Bambu, FOAP = Floresta Ombrófila Aberta com Palmeiras, FOAAP = Floresta Ombrófila Aberta Aluvial com Palmeiras, FOATBB = Floresta Ombrófila Aberta das Terras Baixas com Bambu e PMFS = Plano de Manejo Florestal Sustentável, n = número de copas no sítio. Fonte: Geoflora (2024).

Além de *B. excelsa*, outras 21 espécies foram consideradas para permitir a avaliação do desempenho do algoritmo na detecção: *Apuleia leiocarpa* (Vogel) J. F. Macbr – garapeira; *Brosimum alicastrum* Sw – Manite; *Parkia pendula* (Willd.) Benth. ex Walp – bajião; *Copaifera multijuga* Hayne – copaíba; *Cedrela odorata* L. – cedro; *Ceiba pentandra* (L.) Gaertn – samaúma branca; *Ceiba samauma* (Mart. & Zucc.) K. Schum. – samaúma preta; *Ceiba speciosa* (A. St.-Hil.) Ravenna – samaúma rosa;

Castilla Ulei Warb - caucho; *Dipteryx odorata* (Aubl.) Willd – cumaru-ferro; *Enterolobium schomburgkii* (Benth.) Benth- orelha de macaco; *Hymenaea parvifolia* Huber - jutaí; *Manilkara huberi* (Ducke) Standl. - maçaranduba; *Parkia nitida* Miq. - faveira; *Tachigali melanocarpa* (Ducke) van der Werff – taxi preto; *Tachigali myrmecophila* (Ducke) Ducke) - vermelho. As mesmas são pertencentes ao banco de dados do projeto Geoflora (Geotecnologias aplicadas à automação florestal e espacialização dos estoques de carbono em uso nativo e modificado da terra na Amazônia Ocidental).

3.2 Fluxo de trabalho para geração do conjunto de dados:

Em cada área de floresta, um sobrevoo foi realizado por uma aeronave não tripulada^s (do inglês, *Unmanned Aircraft Systems* - UAS) modelo Mavic 2 e 3 Enterprise com uma câmera acoplada posicionada em ângulo de nadir (ângulo de 90° perpendicular ao solo) para a obtenção de imagens (Figueiredo e Figueiredo, 2018). Todos os voos realizados foram autorizados no Sistema para solicitação de acesso ao Espaço Aéreo Brasileiro por Aeronaves Não Tripuladas – SARPAS emitida por Departamento de controle do Espaço Aéreo – DECEA (ANAC, 2024).

Cada sobrevoo foi realizado a 120 metros de altura com velocidade de cruzeiro (36km/h ou 10m/s), intervalo de captura de fotos de 3 segundos com sobreposição lateral e longitudinal média entre fotos de 80% e distância entre linhas de 45m em GSD (*ground sampling distance*) de 4 cm (Figueiredo e Figueiredo, 2018).

Logo, para a elaboração das ortoimagens, aplicamos o algoritmo SIFT (*Scale-invariant feature transform*) disponível no *software Pix4D* (*software* de mapeamento de fotogrametria terrestre e de drones) (Pix4D, 2024) e realizamos o processo fotogramétrico utilizando a composição de cor verdadeira (RGB). Posteriormente, extraímos as copas individuais (ITCs) das árvores de *B. excelsa* para o processo de demarcação ou rotulagem.

Sobre cada ortoimagem foi realizada a identificação de árvores de *B. excelsa* a partir da avaliação da copa com o apoio das coordenadas geográficas de cada árvore obtidas previamente no inventário florestal 100%.

Para cada copa identificada foram realizados a demarcação e o recorte de polígonos (*Bounding Box* ou caixa delimitadora) com o uso do *software Qgis* versão *Firenze* (3.28, 2022), o que gerou um total de 3003 polígonos com imagens de *B. excelsa* com tamanho padrão 1024 x 1024 *pixels*, que foram analisadas posteriormente no *software Make Sense* - GPLv3 (ferramenta de código aberto e gratuita, executável em navegador *web*) para a geração de arquivo em formato compatível com a rede neural do YOLOv7X (Skalski, 2019).

A partir da análise da caixa delimitadora extraíram-se cinco variáveis: coordenadas (b_x, b_y) do centro da caixa delimitadora, a largura w e a altura h da caixa delimitadora e o nome da classe conforme mostrado na Figura 3.




Figura 3- Variáveis componentes de uma caixa delimitadora. - (b_x, b_y) = coordenadas X e Y correspondente ao centro da caixa delimitadora, w representa a largura e h a altura.

3.3 Treinamento do algoritmo YOLOv7x

O treinamento do algoritmo foi realizado em duas fases denominadas de Cenário I e Cenário II. No Cenário I o algoritmo foi submetido à avaliação das 3.003 imagens de copas das árvores de *B. excelsa* e no Cenário II considerou-se um segundo conjunto de dados contendo imagens de copas de 11.000 árvores distribuídas em 22 espécies com o objetivo de diminuir a incidência de falsos positivos durante o processo de treinamento do modelo. Os Falsos positivos (FP) referem-se ao número de amostras de classificação incorreta no modelo (Zhu *et al.*, 2022).

O cenário II foi introduzido no estudo devido à divergência observada entre as métricas de treinamento e teste no cenário I. Isso ocorreu porque o modelo confundiu espécies com características texturais e de copa semelhantes às da castanheira, classificando-as incorretamente como sendo da mesma espécie. Como resultado, houve aumento significativo nas identificações errôneas. Para corrigir essa falha, foi implementado o cenário II, a fim de melhorar a precisão do modelo.

Para o processo de treinamento do modelo utilizamos a Rede Neural Convolutacional YOLOv7x, que realiza detecção e classificação de objetos. O YOLOv7x possui quatro partes básicas (*Input*, *Backbone*, *Neck* e *Head*) (Bhagabati, Sarma e Bora, 2024). O *Input* refere-se aos dados de entrada fornecidos ao modelo, sendo a base sobre a qual o aprendizado foi realizado. O *Backbone* atua como a estrutura principal da rede neural, sendo responsável pela extração de características discriminativas das imagens de entrada, como bordas, texturas e formas, que são fundamentais para o processo de reconhecimento (Cao *et al.*, 2023; Bhagabati, Sarma e Bora, 2024).

O *Neck*, por sua vez, adiciona camadas e mecanismos que permitem a generalização das características extraídas, aprimorando a capacidade de modelar objetos em diferentes escalas. Ele facilita a transferência de informações entre camadas de baixo e alto nível,

contribuindo para uma representação mais robusta e eficaz das imagens durante o processo de treinamento e inferência (Bhagabati, Sarma e Bora, 2024).

A *Head* é a etapa final do processo de detecção, responsável por gerar os resultados de saída, incluindo as probabilidades de classe, as pontuações de confiança (ou objetividade) e as caixas delimitadoras associadas aos objetos detectados. Durante essa fase, é aplicada a técnica de *Non-Maximum Suppression* (NMS) (Hosang *et al.*, 2017) para filtrar e eliminar caixas redundantes ou sobrepostas, mantendo apenas a caixa delimitadora com a maior pontuação de confiança para cada objeto. Essa abordagem garante que a saída da rede seja precisa, minimizando falsas detecções e aprimorando a qualidade da previsão final da imagem.

A pontuação de confiança reflete o nível de certeza do modelo em relação a uma previsão específica, variando de 0% a 100%. Valores mais altos indicam maior probabilidade de que a detecção seja correta. Com a aplicação de NMS, o modelo é capaz de fornecer resultados mais confiáveis, otimizando a detecção de objetos e assegurando a clareza e a precisão nas previsões.

O treinamento do modelo foi realizado no *Jupyter Notebook* (aplicativo web de código aberto que possibilita a criação e o compartilhamento de documentos interativos com código semelhante.), utilizando o YOLOv7X, realizado por meio de aprendizado de transferência (Zhuang *et al.*, 2020), fazendo uso dos pesos pré-treinados do conjunto de dados MS-COCO (Lin *et al.*, 2014). As imagens originais foram redimensionadas para 640x640 pixels na entrada do treinamento, conforme recomendações da arquitetura do YOLO. Ambos os cenários foram treinados com lote de tamanho 16 para 300 épocas de treinamento (uma única passagem de todo o conjunto de dados de treinamento no modelo de *machine learning* durante o processo de treinamento) em estrutura *PyTorch* (Paszke *et al.*,

2019). Ao redimensionar a imagem facilitamos o treinamento à custa da perda de alguns detalhes da imagem.

O aumento de dados (uso de dados sintéticos) foi incorporado ao treinamento com foco em configurações específicas, otimizando a robustez do modelo. Os ajustes incluíram um máximo de 4 âncoras delimitadoras e modificações nos valores de matiz, saturação e valor (HSV), definidos como: HSV_h (matiz) de 0,015, HSV_s (saturação) de 0,7 e HSV_v (brilho) de 0,4. Além disso, foram aplicadas mudanças de tradução de 0,2 e variação de escala de 0,5 para aumentar a diversidade do conjunto de dados.

O treinamento foi realizado em uma *workstation* de alta performance, equipada com um processador AMD *Ryzen Threadripper* 5964 WX, contendo 24 núcleos e 48 *threads*, 256 GB de memória RAM e uma GPU NVIDIA GeForce RTX 4090 com 24 GB de memória dedicada, garantindo eficiência computacional e redução do tempo de processamento.

Os conjuntos de dados nos cenários I e II foram subdivididos e organizados aleatoriamente em dois grupos (separadamente): conjunto de treinamento (80%) e conjunto de validação (20%). O conjunto de treinamento contém imagens utilizadas para o aprendizado do modelo, enquanto o conjunto de validação é composto por imagens empregadas para avaliar o desempenho do experimento. Este último fornece uma avaliação imparcial do modelo durante o ajuste dos pesos, garantindo a padronização e a robustez do processo de aprendizado.

Utilizamos validação cruzada *k-fold* (Anthony e Holden, 1998) para mitigar possíveis vieses no treinamento, uma vez que métodos de *Deep Learning* são particularmente sensíveis à variabilidade dos dados. Dependendo da distribuição dos dados de treino e validação, o modelo pode apresentar variações no erro de generalização. Esse processo, no entanto, resultou em um aumento do custo computacional e do tempo de

treinamento do modelo YOLOv7x, exigindo em média 6 e 17 horas para cada *k-fold* nos cenários I e II, respectivamente.

Após o treinamento e a validação, realizamos testes com dados inéditos para comprovar a eficácia do modelo em ambos os cenários. Essa etapa é essencial para verificar se o modelo realmente funciona, demonstrando sua capacidade de generalização além dos dados utilizados nas etapas anteriores.

3.4 Treinamento do modelo

Treinamos o YOLOv7x com dois cenários diferentes com validação cruzada, (I) modelo de classe única com 5 *k-fold*; (II) modelo com 22 classes com 5 *k-fold*, em que cada classe representa uma espécie de árvore. A fim de obter uma avaliação objetiva e confiável do desempenho de um modelo de detecção, foi realizada uma validação cruzada com cinco replicações. Cada ciclo envolveu partições aleatórias do conjunto de dados, seguido por treinamento e avaliação do modelo com diferentes subconjuntos aleatórios. A precisão média nas cinco replicações foi usada como métrica de desempenho, reduzindo a influência de partições específicas e garantindo resultados mais robustos e imparciais.

Para o treinamento utilizamos o *script* desenvolvido por Wang, Bochkovskiy e Liao (2023) com adaptações; imagem de entrada de 640x640 *pixels* e *threshold* de 0,1 para seleção do melhor índice pós-processamento. O *threshold* é o “limite”, valor determinado de máximo e mínimo, do desempenho.

O YOLOv7x possui 122 camadas, sendo 01 de entrada, responsável por pré-processamento (tamanho e normalização da imagem); o *backbone* com 59 camadas extraíndo feições principais da imagem em diferentes escalas.; *Neck* com 59 camadas fundindo feições de diferentes escalas, conectando o *backbone* ao *head*.; e *Head* com 03

camadas gerando as caixas delimitadoras, probabilidades de classe e pontuações de confiança (WongKinYiu, 2022).

A atualização da taxa de aprendizagem, responsável por definir a velocidade com que os pesos da rede são ajustados em direção ao ponto ótimo, foi ajustada de forma específica para essa função. Inicialmente, utilizou-se uma taxa de aprendizagem de 0,01, com um *warmup* equivalente a 3 épocas. Após esse período, a atualização passou a ser controlada por uma função cosseno. O treinamento foi realizado ao longo de 300 épocas, utilizando um *lote* de 16 imagens. Essa abordagem permitiu reduzir o tempo total do processo de treinamento e melhorar a capacidade de generalização do modelo, tornando-o mais eficaz para diferentes cenários.

3.5 Estatística aplicada à análise dos dados

Para avaliar o desempenho do modelo utilizamos algumas métricas de avaliação, precisão média, interseção sobre a união, avaliação da precisão, *recall*, limiar de confiança e validação cruzada para verificar a confiabilidade do algoritmo treinado (Bonfanti-Gris *et al.*, 2024).

Utilizamos a interseção sobre a união (IoU) para medir a similaridade entre caixa delimitadora prevista e caixa delimitadora de verdade fundamental (resultado em relação ao mundo real), também conhecida como índice de *Jaccard* (Figura 4 e Equação 1). O valor resultante desta equação varia entre 0 e 1, assim quanto maior a proximidade de 1 melhor a previsão e pode ser calculada com base na Equação 1.

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




Figura 4 - Exemplo de detecção para copa de castanheira. A caixa delimitadora prevista foi desenhada em laranja e a do dado fundamental em azul.

Para as demais métricas utilizamos termos referentes à aprendizagem e a previsões. O Verdadeiro Positivo (TP) representa as detecções corretas realizadas pelo modelo durante o treinamento, o número de *B. excelsa* corretamente identificadas. O Falso Positivo (FP) refere-se a previsões incorretas realizadas pelo modelo, como identificar erroneamente a presença de uma de *B. excelsa* em uma localização onde ela não existe. O Falso Negativo (FN) corresponde aos casos em que o modelo falhou em identificar de *B. excelsa* presentes, ou seja, as detecções positivas que não foram realizadas (Bhagabati, Sarma e Bora, 2024).

Para determinar os TPs, utiliza-se normalmente um limite mínimo de *Intersection over Union* (IoU), que estabelece a precisão espacial mínima necessária para considerar uma previsão como correta. Neste caso, foi adotado um limite de IoU de 0,2 (20%), assegurando que, para ser considerada válida, a previsão precisa ter no mínimo 20% de sobreposição entre a caixa delimitadora prevista pelo modelo e a real.

As métricas de Precisão e *Recall* foram utilizadas para avaliar a capacidade do modelo em detectar corretamente as caixas delimitadoras associadas a uma determinada espécie. A precisão (Equação 2) foi calculada através da razão entre o número de caixas corretamente detectadas da espécie e o número de caixas que foram previstas pelo detector como daquela espécie (Bhagabati, Sarma e Bora, 2024). Em que, TP refere-se a verdadeiro positivo, FP a falso positivo e FN falso negativo;

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

O *Recall* (Equação 3) determina a probabilidade de que as caixas delimitadoras para *B. excelsa* sejam detectadas corretamente (Wang *et al.*, 2025).

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

Ao utilizar ambas as métricas é improvável que um detector de objetos produza valores elevados para ambos para classe de objeto em todos os momentos, principalmente por causa de uma compensação entre as duas métricas, dependendo do limiar de confiança. Cada caixa delimitadora prevista é associada a um limite de confiança, variando de 0 a 1, que indica a probabilidade de a classe de *B. excelsa* estar presente na caixa. Um limite de alta confiança torna o modelo mais seletivo, reduzindo falsos positivos e aumentando a precisão, mas também aumentando os falsos negativos, o que reduz o *recall*. Por outro lado, limites mais baixos aumentam o *recall* ao identificar mais exemplos positivos, mas à custa de uma redução na precisão.

Definimos o limite de confiança igual a 0,25 devido à compensação entre as duas métricas, pois, elas dependem do limiar de confiança (0-baixa e 1-alta precisão).

O *F1-score* (Equação 4) é utilizado para avaliar a capacidade de generalização do modelo, ou seja, sua eficácia em manter um bom desempenho ao ser testado em um conjunto

de dados não previamente observado. Essa métrica combina Precisão e *Recall*, fornecendo uma medida equilibrada da performance do modelo em cenários reais.

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

Para calcular mAP@0.5 realizamos o cálculo da precisão média (AP) (Equação 5), em que para cada classe, calcula-se a precisão média ao longo da curva precisão-*recall*. O cálculo é feito pela média das precisões para cada ponto de *recall* (geralmente usando interpolação ou uma média simples). O mAP@0.5 (Equação 6) é a média da precisão média (AP) para todas as classes, considerando que a interseção sobre união (IoU) entre a caixa predita e a caixa real deve ser ao menos 0.5 para ser considerada uma detecção válida. Em mAp significa o valor médio de precisão de todas as classes, em que i denota uma classe específica. C significa o número total de classes, e AP_j é a precisão média para a classe j .

$$AP = \frac{1}{N} \sum_{i=1}^N Precisão(i) \quad (5)$$

$$mAp@0.5 = \frac{1}{C} \sum_{j=1}^C AP_j \quad (6)$$

Assim, o mAP@0.5 fornece uma métrica de desempenho que avalia tanto a precisão das detecções quanto a sua capacidade de localizar corretamente os objetos com um limiar de IoU de 0.5.

Realizamos a validação cruzada para ambos os cenários. Após realizados o treinamento do modelo e a comparação entre os cenários I e II, fizemos o teste do modelo, com ortoimagem não utilizada durante o treinamento. A contagem de verdade de campo de *B. excelsa* no ambiente de teste foi de 128 árvores em 168 ha, obtida a partir de voo realizado em março de 2024. Antes do teste, o limiar de confiança de 0,25 foi selecionado para ambos

os cenários do modelo para reduzir a ocorrência de falsos positivos e o tamanho da imagem foi padronizado para 1536×1536 pixels. Em seguida, procedemos com a análise dos resultados utilizando o QGIS, a fim de identificar e avaliar os falsos positivos e falsos negativos.

Analizamos a influência do tamanho da caixa delimitadora na predição o modelo (cenário II) e, para isso, utilizamos a fórmula de Sturges (1926) (Equação 7), para definir a quantidade ideal para o conjunto de dados, em que, k é o número de classes (ou intervalos), e n o número de observações ou dados.

$$k = 1 + \log_2 (n) \quad (7)$$

A ideia por trás dessa fórmula é que o número de classes k deve ser proporcional ao logaritmo do número de dados n . Sturges assumiu que os dados seguem uma distribuição normal e que a fórmula funciona bem em muitas situações, mas pode não ser ideal para todos os tipos de dados ou distribuições.

4 Resultados

4.1 Desempenho do modelo

O algoritmo treinado apenas com as imagens das copas de castanheiras (Cenário I) apresentou maior precisão comparado à situação em que o modelo é submetido à detecção de imagens de 21 espécies além das copas de castanheira (Tabela 1).

O *recall* no Cenário I foi ligeiramente superior, mas ambos os cenários exibiram resultados bastante elevados, indicando que o modelo conseguiu identificar corretamente a maioria das instâncias positivas em ambas as situações. Em relação ao *mAP@.5*, o desempenho foi consistente entre os dois cenários, reforçando a boa capacidade preditiva do modelo em termos gerais. Por fim, o *F1-score*, que combina precisão e *recall*, foi ligeiramente superior no Cenário I.

Tabela 1 – Média dos 5 *folds* por meio de validação cruzada (k=5) para os cenários I e II.

Cenário	Classe	Precisão (P)	Recall (R)	mAP@.5	F1-score
I	<i>B. excelsa</i>	0,94	0,95	0,97	0,94
	<i>B. excelsa</i>	0,92	0,95	0,97	0,93
	<i>spp1</i>	0,77	0,80	0,82	0,79
	<i>spp2</i>	0,76	0,88	0,90	0,81
	<i>spp3</i>	0,95	0,94	0,96	0,94
	<i>spp4</i>	0,91	0,83	0,89	0,86
	<i>spp5</i>	0,81	0,92	0,92	0,86
	<i>spp6</i>	0,81	0,67	0,81	0,73
	<i>spp7</i>	0,83	0,88	0,91	0,86
	<i>spp8</i>	0,68	0,69	0,72	0,69
II	<i>spp9</i>	0,83	0,82	0,88	0,83
	<i>spp10</i>	0,84	0,86	0,91	0,85
	<i>spp11</i>	0,86	0,87	0,91	0,86
	<i>spp12</i>	0,73	0,60	0,72	0,66
	<i>spp13</i>	0,83	0,38	0,70	0,49
	<i>spp14</i>	0,76	0,82	0,84	0,78
	<i>spp15</i>	0,63	0,81	0,72	0,71
	<i>spp16</i>	0,96	0,23	0,38	0,28
	<i>spp17</i>	0,88	0,73	0,85	0,80
	<i>spp18</i>	0,91	0,73	0,87	0,80
	<i>spp19</i>	0,90	0,88	0,94	0,88
	<i>spp20</i>	0,89	0,83	0,89	0,85

<i>spp21</i>	0,92	0,93	0,97	0,92
--------------	------	------	------	------

O Cenário II é muito eficiente para algumas espécies como *B. excelsa* apresentando métricas consistentemente altas (próximas a 0,9), indicando um bom desempenho do modelo. A alta precisão (Figura 5) combinada com um *recall* mais baixo em algumas espécies indica que o Cenário II tende a ser conservador na classificação, priorizando evitar falsos positivos, mas às vezes ignorando verdadeiros positivos. A maioria das espécies apresenta mAP@.5 acima de 0,8, indicando uma boa capacidade do modelo em diferenciar as espécies no geral.




Figura 5- Matrix de confusão para o Cenário II do melhor *fold* do treinamento, em que; *Background FP* = Classes de espécies que o modelo confundiu com o plano de fundo; *Background FN*= Número de árvores não detectadas pelo modelo.

A Figura 5 mostra que 96% das copas de árvores de castanheira em campo (verdade fundamental) foram corretamente detectadas como castanheira pelo algoritmo (valor da diagonal referente à interseção entre a predição e a verdade fundamental). No que se refere aos falsos positivos (FP), os valores fora da diagonal na linha da castanheira representam as espécies que foram incorretamente classificadas como castanheira, *spp1* tem um valor de 0,01 e o *background* FN tem um valor de 0,03. Esses números indicam que um pequeno percentual de outras classes foi erroneamente identificado como castanheira. Os falsos negativos (FN), valores fora da diagonal na coluna da castanheira, indicam exemplos de castanheira que foram classificados incorretamente como outras classes, o *background* FP na coluna da castanheira tem um valor de 0,17. Isso significa que 17% das castanheiras foram classificadas como "fundo".

A Tabela 2 apresenta as métricas de desempenho para os Cenários I e II que incluem Verdadeiros Positivos (TP), Falsos Positivos (FP), Falsos Negativos (FN), Precisão, *Recall*, *F1-Score* e IoU em ambiente de teste.

Tabela 2 - Avaliação e comparação dos cenários I e II para Yolov7x.

Cenário	TP	FP	FN	Precisão	<i>Recall</i>	<i>F1 score</i>	IoU (%)
I	101	465	35	0,17	0,74	0,28	16,8
II	99	24	29	0,8	0,77	0,78	65,13

No Cenário I, dos 168 indivíduos de *B. excelsa* o modelo detectou 101 corretamente, enquanto que, no Cenário II, esse número foi ligeiramente menor (99). Em contrapartida, no que se refere aos falsos positivos, o Cenário I apresentou 465 FPs, o que é consideravelmente alto, indicando um número elevado de detecções incorretas, enquanto no Cenário II os FPs foram drasticamente reduzidos para 24, o que evidencia que o modelo teve uma taxa de erro muito menor, refletindo uma melhoria significativa na precisão das detecções. No que se

refere aos falsos negativos, houve redução modesta entre os Cenários I e II, refletindo um leve aumento na capacidade do modelo de detectar todos os objetos.

Ao comparar os Cenários, o *recall* foi ligeiramente superior no Cenário II, o que sugere uma leve melhoria na capacidade do modelo de detectar objetos.

Ao analisar o *F1-score*, medida balanceada do desempenho do modelo, os resultados demonstram para o Cenário I, baixo desempenho global do modelo, principalmente devido à baixa precisão. No Cenário II, o *F1-Score* teve aumento de 50%, indicando uma melhoria significativa na combinação entre precisão e *recall*.

A IoU fornece avaliação da qualidade das detecções espaciais. No Cenário I, o IoU foi de 16,80%, um valor relativamente baixo, sugerindo que as caixas delimitadoras preditas estavam em desacordo com as caixas reais na maioria das detecções. No Cenário II, o IoU aumentou para 65,13%, um valor consideravelmente mais alto, indicando que as caixas delimitadoras preditas estavam mais alinhadas com as reais, refletindo uma melhoria na qualidade espacial das detecções.

Para o Cenário II, à medida que o *confidence threshold* aumenta (Figura 6), há uma tendência de queda nas métricas *Recall*, *F1-score* e IoU, enquanto a Precisão se mantém mais estável, evidenciando que o *confidence-threshold* mais adequado é o de 0,25 mantendo assim melhor compensação entre as métricas de desempenho do modelo. Isso ocorre porque em *confidence-threshold* mais elevados, o modelo se torna mais seletivo, afetando principalmente o *recall*, pois a quantidade de falsos positivos tende a aumentar.




Figura 6 - Impacto do *confidence-threshold* nas Métricas de Desempenho para o Cenário II.

Ao analisar os Falsos Positivos (FPs), identificamos copas de árvores semelhantes às da castanheira em diferentes fases fenológicas (Figura 7), com características texturais similares. Além disso, ao analisar a caixa delimitadora e influência na predição do modelo em que, quanto maior a caixa delimitadora, maior a área de copa de castanheira, notamos (Tabela 5 e Figura 8) que a Classe 6 (436 - 508 m²) se destaca, com 100% de TP, o que indica que todos os indivíduos dessa classe foram classificados corretamente como positivos. Esse desempenho é um indicativo de que o modelo foi extremamente preciso ao identificar os elementos dessa faixa de área, sem cometer nenhum erro de falso positivo (FP). Além disso, a Classe 5 (363 - 435 m²) apresenta um desempenho notável, com 90,91% de TP.




Figura 7 - Análise de detecções de castanheira, a) castanheiras corretamente previstas (TP), b) incorretamente previstas (FP) e c) não previstas (FN). Reserva Florestal da Embrapa Acre, Rio Branco, Acre, 2024.

Tabela 3 – Efeito do tamanho da caixa delimitadora na predição do modelo YoloV7x para *B. excelsa* no eCenário II.

Índice	Classe (m²)	TP	FP	TP(%)	FP(%)
1	71- 143	12	5	70,59	29,41
2	144-216	19	5	79,17	20,83
3	217-289	25	7	78,13	21,88
4	290-362	22	3	88,00	12,00
5	363-435	10	1	90,91	9,09
6	436-508	3	0	100,00	0,00
7	509-581	7	1	87,50	12,50
8	582-654	1	2	33,33	66,67
Somatório		99	24		




Figura 8- Comportamento da detecção de árvores de *B. excelsa* pelo Yolov7x em área de teste para o Cenário II.

A Classe 3 (217 - 289 m²), com 25 verdadeiros positivos (TP), apresenta a maior quantidade de indivíduos corretamente classificados, o que a torna a classe mais significativa em termos de volume de acertos. Embora sua taxa de TP (%) (78,13%) seja inferior à de outras classes, a quantidade absoluta de acertos a torna uma classe relevante para o modelo, especialmente em termos de contribuição para o somatório total de TP. A Classe 2 (144 - 216 m²) também se destaca em termos de quantidade de indivíduos classificados corretamente, com 19 verdadeiros positivos (TP), embora sua taxa de acerto (79,17%) seja ligeiramente menor que a da Classe 3.

5 Discussão

5.1 Desempenho do modelo

No Cenário I, em que se considerou apenas uma classe de dados, o modelo apresentou desempenho limitado em ambiente de teste com precisão de 17%, indicando

problemas de generalização. Esse resultado reflete a memorização de padrões específicos dos dados de treinamento, em vez de características generalizáveis, como a estrutura da copa e as variações sazonais. Neste sentido, Li *et al.*, (2024) aprimoraram o YOLOv7, reduzindo detecções perdidas por oclusões e falsos positivos, melhorando significativamente o mAP@0.5 e a precisão. De forma complementar, Ferreira *et al.*, (2021), ao utilizar WorldView-3 com DeepLabv3+, alcançaram 93,87% de precisão, mas com maior custo computacional e com mais etapas de pré-processamento. Esses estudos destacam diferentes abordagens para aprimorar a generalização e a eficiência em tarefas de detecção.

No Cenário II, adicionamos espécies com copas similares a *B. excelsa*, o que elevou o desempenho do modelo, atingindo precisão (0,92), *recall* (0,95), mAP@0.5 (0,97) e *F1-score* (0,93). Esses resultados evidenciam que a diversificação de dados melhora a robustez do modelo, conforme também demonstrado por Dang *et al.*, (2023), que usaram um conjunto multiclasse de 5.648 imagens com 12 classes, ampliando a capacidade de generalização. A inclusão de dados diversificados mostrou-se eficaz na diferenciação de características estruturais e texturais, reduzindo falsos positivos e aprimorando a classificação em novos dados. Esses achados reforçam a importância da diversificação de dados e do refinamento arquitetural para melhorar o desempenho em sistemas complexos de detecção e classificação.

Os estudos de Veras *et al.*, (2022) demonstraram a eficácia de uma abordagem baseada na ResNet-18 e na DeepLabv3+ para classificação de espécies de árvores a partir de imagens multi-estação. Enquanto o Cenário II no presente estudo utilizou espécies de copa similar para melhorar a robustez, Veras *et al.*, (2022) destacam que a composição multi-estação é uma estratégia complementar que reduz significativamente as taxas de classificação incorreta ao capturar características discriminativas das espécies, especialmente em estações com folhagem distinta. Por exemplo, enquanto o modelo proposto no presente estudo

mostrou robustez ao diferenciar *B. excelsa* de espécies com copas similares, Veras *et al.* relataram como características sazonais, por exemplo, a queda de folhas, influenciam a precisão. Assim, integrar dados multi-estação com a estratégia de diversificação de espécies pode oferecer um potencial adicional para reduzir falsos positivos e melhorar a classificação em cenários com variabilidade sazonal. Além disso, a abordagem de Veras *et al.*, (2022) confirma que o aprendizado automático é capaz de identificar padrões sazonais únicos, alinhando-se aos resultados positivos obtidos no presente estudo com estratégias de aumento de dados e modelos aprimorados, como os de Dang *et al.*, (2023) e Li *et al.*, (2024)

Com base nos resultados do Cenário II e na Figura 6, podemos observar que o *confidence threshold* de 0,25 se mostrou ideal para equilibrar as métricas de desempenho do modelo, apresentando valores robustos para *Recall*, *F1-score* e *IoU*. Isso reflete uma abordagem menos seletiva, favorecendo a detecção de objetos com maior cobertura, reduzindo falsos negativos.

Comparando com Ostovar *et al.*, (2018), que propuseram abordagens de limiares variáveis e por aprendizado por reforço para otimizar a segmentação em diferentes cenários, o comportamento observado no Cenário II demonstra a relevância de um limiar bem ajustado. Estudos como Zhang *et al.*, (2023) reforçam que a seleção do limiar adequado depende do objetivo do modelo. No caso deste trabalho, o limiar de 0,25 oferece o melhor compromisso entre métricas críticas, favorecendo uma solução mais generalizável e menos restritiva para a detecção de espécies.

Adicionalmente, as abordagens de aprendizado por reforço para limiarização, conforme Ostovar *et al.*, (2018), poderiam ser exploradas como estratégias futuras para determinar limiares adaptativos com base nas características específicas de cada conjunto de dados.

Os resultados deste estudo demonstram que o desempenho do modelo YOLOv7x na detecção de *B. excelsa* varia de acordo com o tamanho das copas das árvores, sendo mais preciso em áreas maiores, como evidenciado na Classe 6 (436–508 m²), que apresentou 100% de taxa de verdadeiros positivos (TP). Esse comportamento reflete a capacidade do modelo em identificar características mais evidentes em alvos maiores, enquanto encontra maior dificuldade em áreas menores, que apresentaram taxas mais elevadas de falsos positivos (FP).

Esse padrão é corroborado por Hui *et al.*, (2024), que relataram a perda de características essenciais em alvos pequenos devido à resolução limitada de imagens obtidas por UAS, então, propuseram o DSAA-YOLO, um algoritmo aprimorado baseado no YOLOv7 para a detecção de alvos pequenos em imagens aéreas. A inclusão de técnicas de super resolução e estratégias adaptativas para caixas delimitadoras mostrou-se eficaz na melhoria da precisão em alvos menores. A integração de abordagens semelhantes poderia ser uma solução viável para melhorar a identificação de castanheiras com copas menores, reduzindo a ocorrência de falsos positivos e aumentando a robustez do modelo.

Além disso, as condições do dossel florestal, como a presença de lianas, arrastamento de *pixels* nas ortoimagens e interferências causadas por árvores vizinhas com copas visualmente semelhantes, contribuíram para a dificuldade do modelo em reduzir os falsos positivos. Esses fatores são agravados ainda por variações fenológicas que influenciam as características texturais das copas, identificadas neste estudo e isso alinha-se às observações de Chen *et al.*, (2023), que relataram dificuldades na identificação de inflorescências de maçãs em fundos complexos. Nesse contexto, o uso de módulos de atenção e de funções de perda avançadas, melhorou significativamente a precisão em cenários desafiadores. A incorporação de tais

estratégias pode beneficiar futuros desenvolvimentos para a detecção de castanheiras, especialmente em áreas menores ou em condições fenológicas variadas.

Para lidar com essas limitações, várias abordagens são sugeridas pela literatura, como (i) aumento do conjunto de dados, em que a inclusão de mais exemplos de copas menores no treinamento pode melhorar a representatividade dessas classes no modelo, alinhando-se às observações de Bai *et al.*, (2024) sobre a importância de conjuntos de dados diversificados para o desempenho do modelo. (ii) Técnicas de super resolução e regressão adaptativa, em que o uso de técnicas como super resolução densa e as estratégias de ajuste adaptativo de caixas delimitadoras, conforme discutido por Hui *et al.*, (2024), podem ajudar a capturar características detalhadas e melhorar a precisão em áreas menores. (iii) Estratégias adaptativas para detecção, a adoção de limiares de confiança diferenciados e a atribuição de maior peso às copas maiores podem melhorar a precisão do modelo em cenários práticos, como sugerido por Bai *et al.*, (2024) e Li *et al.*, (2024).

Além das adaptações mencionadas, é importante considerar a influência da qualidade das imagens no desempenho do modelo. A presença de fatores como o arrastamento de *pixels* e a baixa resolução em áreas específicas compromete as métricas de desempenho, conforme também apontado por Hui *et al.*, (2024). Melhorias na qualidade das imagens e testes em diferentes períodos do ano podem mitigar essas limitações, oferecendo maior robustez ao modelo.

Outro aspecto relevante refere-se à maior representatividade da Classe 3 (217–289 m²) em termos absolutos de TP, destacando a relevância de volumes maiores de dados para a análise. Esse achado é consistente com Estrada *et al.*, (2023), que apontaram que conjuntos de dados densos e complexos podem aumentar a eficácia de redes YOLO em aplicações agrícolas.

Por fim, o desempenho superior do modelo em classes maiores reflete sua robustez em condições mais evidentes de detecção. Li *et al.*, (2024) observaram melhoria similar ao otimizar o YOLOv7 para a contagem de espigas de trigo, utilizando um método aprimorado para reduzir o impacto de oclusões e características semelhantes. Estratégias como a introdução de cabeçalhos adicionais para detecção em alta resolução, como as utilizadas por Bai *et al.*, (2023) em estudos agrícolas, também poderiam ser implementadas para melhorar a precisão em alvos menores e mitigar as dificuldades observadas neste estudo.

Em suma, os desafios e as limitações identificados neste trabalho refletem questões comuns na aplicação de redes YOLO em ambientes complexos e reforçam a necessidade de abordagens inovadoras para otimizar a detecção, especialmente em classes menores ou em cenários fenológicos distintos. Avanços futuros podem beneficiar-se da integração de técnicas de super resolução, estratégias adaptativas para caixas delimitadoras e módulos de atenção, conforme relatado na literatura recente.

5.2 Orientar para a gestão

O modelo de detecção e de classificação treinado, validado e testado (Cenário II), possui robustez, permitindo o uso do mesmo para utilização em ambiente real, podendo ser aplicado por *stakeholders* na automatização do inventário florestal para a cadeia produtiva de *B. excelsa*.

A extração da Castanha do Brasil enfrenta desafios significativos relacionados à conciliação entre a maximização da produtividade e a preservação ecológica das florestas nativas. Conforme destacado por Kainer, Wadt e Staudhammer (2007) e Batista *et al.*, (2021), a pressão por maior produtividade pode comprometer a sustentabilidade das populações de *B. excelsa*, resultando em degradação ambiental e em perdas de biodiversidade. Este estudo demonstrou que o uso de tecnologias de inventário automatizado

baseadas em *deep learning* pode ajudar a mitigar esses impactos, permitindo o mapeamento preciso de áreas produtivas e a gestão estratégica das florestas de maneira mais sustentável.

Os resultados indicam que o modelo permite inventário automatizado, sendo capaz de identificar áreas de maior concentração de indivíduos de dossel (aqueles com maior produtividade de nozes) dentro das florestas, além de fornecer informações sobre o crescimento (Wadt, Kainer, Gomes-Silva, 2005), quando realizado o monitoramento automatizado periódico. Esses dados podem ser cruciais para o planejamento estratégico da cadeia produtiva, permitindo aos *stakeholders* otimizar a colheita de castanhas, reduzir o impacto ambiental da extração e melhorar a eficiência do processo produtivo. Esse achado está em linha com os resultados de Kumar e Kumar (2023), que também destacaram a eficácia de sistemas baseados em *deep learning* no mapeamento de grandes áreas florestais.

Os estudos de Wadt *et al.*, (2005) e Batista *et al.*, (2019) relatam que, de acordo com o tipo de floresta, haverá diferentes associações espaciais para a espécie, “havendo assim necessidade da adoção de diferentes estratégias de manejo e conservação para as espécies arbóreas em relação ao tipo de floresta. Por meio do uso do modelo desenvolvido, é possível identificar a associação espacial da espécie para cada área de interesse, bem como a localização geográfica de cada indivíduo dando suporte ao manejo. Dessa forma, geram-se oportunidades de mercado, impulsionando a inovação na cadeia produtiva e melhorando os ganhos das comunidades envolvidas (Wadt *et al.*, 2023; Araújo *et al.*, 2024).

Embora o modelo de inventário automatizado tenha demonstrado alta precisão em área testada, é importante notar que a qualidade dos dados de entrada influencia nos resultados. A dependência de imagens de alta resolução pode ser um obstáculo em áreas remotas, nas quais o acesso ao processamento dados de qualidade é limitado. Além disso, o modelo ainda precisa ser testado em diferentes tipos de floresta e em diferentes contextos de manejo, o que constitui uma direção importante para futuros estudos.

O uso do modelo automatizado de inventário pode beneficiar diretamente as comunidades extrativistas, proporcionando dados precisos sobre a disponibilidade de árvores de castanha e permitindo um planejamento mais eficiente da colheita. Com a identificação de áreas produtivas e o monitoramento do crescimento das árvores, as comunidades podem evitar a exploração excessiva e garantir a regeneração da floresta, além de maximizar os lucros (Rosenfeld *et al.*, 2024). Esse modelo tem o potencial de transformar a cadeia produtiva da castanha, criando oportunidades para um manejo florestal mais integrado e sustentável, com ganhos econômicos e ambientais.

O algoritmo será disponibilizado à comunidade técnica e científica por meio da plataforma Netflora - Inteligência Artificial (IA) para identificação de espécies florestais, com o propósito de viabilizar a identificação automatizada de forma eficiente e acessível. A tecnologia será disponibilizada gratuitamente no catálogo da Embrapa, promovendo a democratização do acesso a ferramentas avançadas de monitoramento e manejo florestal. Por meio de um protocolo operacional simplificado, os usuários poderão realizar o carregamento de ortoimagens e executar o processamento automatizado para a geração de dados referentes ao inventário florestal da área de interesse, contribuindo para a transferência e a aplicação de tecnologia nos âmbitos científico e técnico.

Os resultados apresentados na dissertação indicam que o algoritmo de reconhecimento de copas de castanheiras pode ser uma ferramenta estratégica para a gestão eficiente da cadeia produtiva da castanha do Brasil. Por meio da aplicação desse sistema, torna-se possível direcionar o manejo florestal de maneira mais assertiva, contribuindo para o aumento da produtividade e para a sustentabilidade ambiental e a econômica.

A utilização do algoritmo permite o mapeamento preciso das áreas onde se encontram as árvores de castanheira, possibilitando a identificação de regiões prioritárias para manejo e exploração. Essa informação é fundamental para o planejamento das

atividades de coleta, pois facilita a definição de rotas logísticas mais eficientes, reduzindo custos operacionais e minimizando os impactos ambientais. Além disso, o reconhecimento detalhado das copas pode auxiliar na expansão sustentável da área de manejo, identificando novas regiões com potencial produtivo e promovendo o uso racional dos recursos florestais.

Outro benefício significativo proporcionado pela tecnologia é o monitoramento contínuo das árvores. O algoritmo pode ser utilizado para acompanhar o estado das copas e identificar eventuais ameaças, como presença de lianas ou danos causados por competidores e eventos naturais. Essas informações permitem ajustes no manejo que garantem a saúde das árvores e a manutenção da produtividade a longo prazo. Paralelamente, a capacidade de monitorar variações fenológicas das castanheiras viabiliza a programação de coletas no momento ideal, reduzindo perdas por maturação inadequada ou manejo ineficiente.

Além dos aspectos relacionados ao manejo, o uso do algoritmo também impacta positivamente a organização social e a comercial da cadeia produtiva. Os dados gerados podem subsidiar associações e cooperativas de extrativistas na negociação de melhores condições comerciais, facilitando o acesso a mercados que valorizam produtos rastreáveis e sustentáveis. A rastreabilidade proporcionada pelo mapeamento permite, ainda, a obtenção de certificações que agregam valor à castanha do Brasil, aumentando sua competitividade no mercado nacional e internacional.

Por fim, a aplicação da tecnologia fornece uma base de dados robusta para apoiar políticas públicas voltadas ao manejo sustentável e ao desenvolvimento socioeconômico de comunidades extrativistas. Os dados podem ser utilizados para justificar políticas de pagamentos por serviços ambientais (PSA), valorizando o papel das comunidades no fornecimento de serviços ecossistêmicos essenciais, como a conservação da biodiversidade e o sequestro de carbono.

Em síntese, a incorporação do algoritmo de reconhecimento na gestão da cadeia produtiva da castanha do brasil representa um avanço significativo. Essa ferramenta não apenas otimiza o manejo e a logística, mas também fortalece as comunidades extrativistas e promove a sustentabilidade ambiental, integrando tecnologia e conhecimento local em prol de um modelo de exploração mais eficiente e responsável.

Considerações Finais

O estudo alcançou avanços importantes na detecção de *Bertholletia excelsa*, especialmente ao integrar espécies com copas semelhantes e ajustar o limiar de confiança. Enquanto o Cenário I revelou limitações de generalização devido à memorização de padrões específicos, o Cenário II demonstrou que a diversificação de dados melhora significativamente a robustez do modelo, evidenciado por métricas como mAP@0.5 (0,97). Esses achados reforçam a importância da variabilidade sazonal e da qualidade dos dados para reduzir falsos positivos e aprimorar a classificação em novos ambientes.

As limitações observadas, como dificuldade em identificar alvos menores e interferências de dossel, podem ser mitigadas por meio de abordagens como super resolução, diversificação do conjunto de dados e estratégias adaptativas para caixas delimitadoras. Os resultados também reforçam o potencial do modelo para aplicações práticas, como a automatização do inventário florestal e o manejo sustentável da cadeia produtiva de *B. excelsa*, contribuindo para a preservação ambiental e para o aumento da produtividade.

Em suma, o modelo YOLOv7x demonstrou ser uma ferramenta promissora para a gestão estratégica de florestas, permitindo identificar e monitorar a *B. excelsa* com eficiência e precisão em diferentes cenários. Nosso estudo contribui para o avanço do uso de redes YOLO em cenários complexos, oferecendo insights práticos para a detecção de espécies em ecossistemas florestais diversos. Avanços futuros podem se beneficiar da integração de novas

técnicas, ampliando ainda mais a aplicabilidade do modelo em sistemas complexos de detecção florestal e em estratégias de manejo sustentável.

Referências Bibliográficas

- ANAC. Cadastro de Drones. Disponível em: < <https://www.anac.gov.br/assuntos/paginas-tematicas/drones/cadastro-de-drones>>. Acesso em: 12 de novembro de 2024
- Anthony, M., & Holden, S. B. (1998, July 24). Cross-validation for binary classification by real-valued functions. *Proceedings of the Eleventh Annual Conference on Computational Learning Theory*. <http://dx.doi.org/10.1145/279943.279987>
- Araujo, E. C. G., Silva, T. C., da Cunha Neto, E. M., Favarin, J. A. S., da Silva Gomes, J. K., das Chagas, K. P. T., Fiorelli, E. C., Sonsin, A. F., & Maia, E. (2024). Bioeconomy in the Amazon: Lessons and gaps from thirty years of non-timber forest products research. *Journal of Environmental Management*, 370, 122420. <https://doi.org/10.1016/j.jenvman.2024.122420>
- Bai, Y., Yu, J., Yang, S., & Ning, J. (2024a). An improved YOLO algorithm for detecting flowers and fruits on strawberry seedlings. *Biosystems Engineering*, 237, 1–12. <https://doi.org/10.1016/j.biosystemseng.2023.11.008>
- Batista, A. P. B., Scolforo, H. F., Mello, J. M. de, Guedes, M. C., Terra, M. C. N. S., Scalon, J. D., Gomide, L. R., Scolforo, P. G. V., & Cook, R. L. (2019). Spatial association of fruit yield of *Bertholletia excelsa* Bonpl. trees in eastern Amazon. *Forest Ecology and Management*, 441, 99–105. <https://doi.org/10.1016/j.foreco.2019.03.043>
- Bhagabati, B., Sarma, K. K., & Bora, K. C. (2024). An automated approach for human-animal conflict minimisation in Assam and protection of wildlife around the Kaziranga National Park using YOLO and SENet Attention Framework. *Ecological Informatics*, 79, 102398. <https://doi.org/10.1016/j.ecoinf.2023.102398>
- Bochkovski, A., Wang, C.-Y., & Liao, H.-Y. M. (2020, April 23). *YOLOv4: Optimal speed and accuracy of object detection*. arXiv.Org.

<https://arxiv.org/abs/2004.10934>.

Bonfanti-Gris, M., Herrera, A., Paraíso-Medina, S., Alonso-Calvo, R., Martínez-Rus, F., & Pradíes, G. (2024). Performance evaluation of three versions of a convolutional neural network for object detection and segmentation using a multiclass and reduced panoramic radiograph dataset. *Journal of Dentistry*, *144*, 104891. <https://doi.org/10.1016/j.jdent.2024.104891>

Brasil, Agência Nacional de Aviação Civil. **Drones**. Disponível em <<https://www.gov.br/anac/pt-br/assuntos/drones>> Acessos em 13 de abril de 2023. Publicado em 2021.

Buchelt, A., Adrowitzer, A., Kieseberg, P., Gollob, C., Nothdurft, A., Eresheim, S., Tschitschek, S., Stampfer, K., & Holzinger, A. (2024a). Exploring artificial intelligence for applications of drones in forest ecology and management. *Forest Ecology and Management*, *551*, 121530. <https://doi.org/10.1016/j.foreco.2023.121530>

Caffaratti, G. D., Marchetta, M. G., Euillades, L. D., Euillades, P. A., & Forradellas, R. Q. (2021). Improving forest detection with machine learning in remote sensing data. *Remote Sensing Applications: Society and Environment*, *24*, 100654. <https://doi.org/10.1016/j.rsase.2021.100654>

Cao, X., Su, Y., Geng, X., & Wang, Y. (2023). YOLO-SF: YOLO for fire segmentationdetection. *IEEE Access*, *11*, 111079–111092. <https://doi.org/10.1109/access.2023.3322143>

Catenacci, F.S.; Ribeiro, M.; Smith, N.P.; Cabello, N. B. Bertholletia in Flora e Funga do Brasil. Jardim Botânico do Rio de Janeiro.Disponível em: <<https://floradobrasil.jbrj.gov.br/FB23424>>. Acesso em: 04 abr. 2023.

Chen, J., Ma, B., Ji, C., Zhang, J., Feng, Q., Liu, X., & Li, Y. (2023). Apple inflorescence

- recognition of phenology stage in complex background based on improved YOLOv7. *Computers and Electronics in Agriculture*, 211, 108048.
<https://doi.org/10.1016/j.compag.2023.108048>
- Dang, F., Chen, D., Lu, Y., & Li, Z. (2023). YOLOWeeds: A novel benchmark of YOLO object detectors for multi-class weed detection in cotton production systems. *Computers and Electronics in Agriculture*, 205, 107655.
<https://doi.org/10.1016/j.compag.2023.107655>
- Estrada, J. S., Vasconez, J. P., Fu, L., & Cheein, F. A. (2024). Deep Learning based flower detection and counting in highly populated images: A peach grove case study. *Journal of Agriculture and Food Research*, 15, 100930.
<https://doi.org/10.1016/j.jafr.2023.100930>
- Ferreira, M. P., Lotte, R. G., D'Elia, F. V., Stamatopoulos, C., Kim, D.-H., & Benjamin, A. R. (2021). Accurate mapping of Brazil nut trees (*Bertholletia excelsa*) in Amazonian forests using WorldView-3 satellite images and convolutional neural networks. *Ecological Informatics*, 63, 101302.
<https://doi.org/10.1016/j.ecoinf.2021.101302>
- Fibich, P., Lepš, J., Novotný, V., Klimeš, P., Těšitel, J., Molem, K., Damas, K., & Weiblen, G. D. (2016). Spatial patterns of tree species distribution in New Guinea primary and secondary lowland rain forest. *Journal of Vegetation Science*, 27(2), 328–339. <https://doi.org/10.1111/jvs.12363>
- Figueiredo, E. O., e Figueiredo, S. M. de M. (2018, December 6). *Planos de voo semiautônomos para fotogrametria com aeronaves remotamente pilotadas de classe 3*. <http://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/1100860>
- Figueiredo, E.O. et al. Manejo Florestal 4.0 – passos para emprego de Aeronaves Remotamente Pilotadas (drones) no planejamento florestal em nativas.(documentos

- 169), Rio Branco, AC : Embrapa Acre, 2020.
- Giatti, O. F., Mariosa, P. H., Alfaia, S. S., Silva, S. C. P. da, & Pereira, H. dos S. (2021). Potencial socioeconômico de produtos florestais não madeireiros na reserva de desenvolvimento sustentável do Uatumã, Amazonas. *Revista de Economia e Sociologia Rural*, 59(3). <https://doi.org/10.1590/1806-9479.2021.229510>
- Gonçalves, D. C.M., Vasconcellos Gama, J. R., Corrêa, J. A. de J., & De Oliveira Junior, R. C. (2021). Uso De Produtos Florestais Não Madeireiros em Comunidades Da Flona Tapajós. *Nativa*, 9(3). <https://doi.org/10.31413/nativa.v9i3.11598>
- Guido, A.C.M. **Introduction to Machine Learning with Python: A guide for data Scientists**. Editora O'reilly, Ed.0 2017, Estados Unidos.
- Hosang, J., Benenson, R., & Schiele, B. (2017, May 8). *Learning non-maximum suppression*. arXiv.Org. <https://arxiv.org/abs/1705.02950>
- Huang, S.-Y., An, W.-J., Zhang, D.-S., & Zhou, N.-R. (2023). Image classification and adversarial robustness analysis based on hybrid quantum–classical convolutional neural network. *Optics Communications*, 533, 129287. <https://doi.org/10.1016/j.optcom.2023.129287>
- Hui, Y., Wang, J., & Li, B. (2024). DSAA-YOLO: UAV remote sensing small target recognition algorithm for YOLOV7 based on dense residual super-resolution and anchor frame adaptive regression strategy. *Journal of King Saud University - Computer and Information Sciences*, 36(1), 101863. <https://doi.org/10.1016/j.jksuci.2023.101863>
- IBGE, Instituto Brasileiro de Geografia e Estatística. Base de Dados Vegetação (2023). Disponível em < <https://www.ibge.gov.br/geociencias/downloads-geociencias.html> > Acesso em 05 de setembro de 2024
- Izbicki, R. e Santos, T. M. dos. Aprendizado de máquina: uma abordagem estatística. 1ª

- edição. 2020. 272 páginas. ISBN: 978-65-00-02410-4.
- Izbicki, R. Mendonça, T. Aprendizado de máquina: uma abordagem estatística. [livro eletrônico]. São Carlos, SP: Rafael Izbicki, 2020.
- Ji, S.-J., Ling, Q.-H., & Han, F. (2023). An improved algorithm for small object detection based on YOLO v4 and multi-scale contextual information. *Computers and Electrical Engineering*, 105, 108490.
<https://doi.org/10.1016/j.compeleceng.2022.108490>
- Kainer, K. A., Wadt, L. H. O., & Staudhammer, C. L. (2007). Explaining variation in Brazil nut fruit production. *Forest Ecology and Management*, 250(3), 244–255.
<https://doi.org/10.1016/j.foreco.2007.05.024>
- Karasinski, M.A. “Utilização de Redes Neurais Convolucionais e Imagens Obtidas por RPA para o Mapeamento de Palmeiras na Amazônia Ocidental”. (2021).
Dissertação, Universidade Estadual do Centro-Oeste/UNICENTRO, Iratí- Paraná.
- Kipli, K., Osman, S., Joseph, A., Zen, H., Awang Salleh, D. N. S. D., Lit, A., & Chin, K. L. (2023). Deep learning applications for oil palm tree detection and counting. *Smart Agricultural Technology*, 5, 100241.
<https://doi.org/10.1016/j.atech.2023.100241>
- Kotivuori, E., Kukkonen, M., Mehtätalo, L., Maltamo, M., Korhonen, L., & Packalen, P. (2020). Forest inventories for small areas using drone imagery without in-situ field measurements. *Remote Sensing of Environment*, 237, 111404.
<https://doi.org/10.1016/j.rse.2019.111404>
- Kumar S, P., & Kumar, N. K. (2023). Drone-based apple detection: Finding the depth of apples using YOLOv7 architecture with multi-head attention mechanism. *Smart Agricultural Technology*, 5, 100311. <https://doi.org/10.1016/j.atech.2023.100311>
- Li, Z., Zhu, Y., Sui, S., Zhao, Y., Liu, P., & Li, X. (2024). Real-time detection and

- counting of wheat ears based on improved YOLOv7. *Computers and Electronics in Agriculture*, 218, 108670. X. <https://doi.org/10.1016/j.compag.2024.108670>
- Lin, T.-Y., Maire, M., Belongie, S., Bourdev, L., Girshick, R., Hays, J., Perona, P., Ramanan, D., Zitnick, C. L., & Dollár, P. (2014a, May 1). *Microsoft COCO: Common objects in context*. arXiv.Org. <https://arxiv.org/abs/1405.0312>
- Morettin, P. A. Estatística e ciência de dados. ed.01, Rio de Janeiro: LTC, 2022. ISBN 978-85-216-3816-2
- Munaretti, A. M., Wadt, L. H. de O., & Papa, D. de A. (2016). *Passo a passo para o mapeamento de produtos florestais não madeireiros com o uso de tecnologia GNSS* (1st ed.). <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1142402/passo-a-passo-para-o-mapeamento-de-produtos-florestais-nao-madeireiros-com-o-uso-de-tecnologia-gnss>
- Ostovar, A., Ringdahl, O., & Hellström, T. (2018). Adaptive image thresholding of yellow peppers for a harvesting robot. *Robotics*, 7(1), 11. <https://doi.org/10.3390/robotics7010011>
- Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., Killeen, T., Lin, Z., Gimelshein, N., Antiga, L., Desmaison, A., Köpf, A., Yang, E., DeVito, Z., Raison, M., Tejani, A., Chilamkurthy, S., Steiner, B., Fang, L., ... Chintala, S. (2019, December 3). *PyTorch: An imperative style, high-performance deep learning library*. arXiv.Org. <https://arxiv.org/abs/1912.01703>
- Pix4D documentation*. (n.d.). Pix4D Documentation. Retrieved November 10, 2024, from <https://support.pix4d.com/hc/pix4dmapper>
- Rosenfeld, T., Pokorny, B., Marcovitch, J., & Poschen, P. (2024). BIOECONOMY based on non-timber forest products for development and forest conservation - Untapped potential or false hope? A systematic review for the BRAZILIAN amazon. *Forest*

- Policy and Economics*, 163, 103228. <https://doi.org/10.1016/j.forpol.2024.103228>
- Rubí, J. N. S., de Carvalho, P. H. P., & Gondim, P. R. L. (2023). Application of machine learning models in the behavioral study of forest fires in the Brazilian Federal District region. *Engineering Applications of Artificial Intelligence*, 118, 105649. <https://doi.org/10.1016/j.engappai.2022.105649>
- Sacande, M. & Parfondry, M (2018). Non-Timber Forest Products: From Restoration To Income Generation. ISBN 978-92-5-131118-9
- Santos, E. K. M. Figueiredo, S. M. M. Figueiredo, E. O. Comportamento Fenológico De Espécies Florestais Detectado Por Sistemas Aéreos Não Tripulados. Biodiversidade e Biotecnologia no Brasil 1. Ed. Stricto Sensu; cap.17, pág.261-277, Rio Branco, 2020. Doi: 10.35170/ss.ed.9786586283280. ISBN: 978-65-86283-28-0
- SAS. Machine Learning: O que é e qual sua importância? Disponível em <https://www.sas.com/pt_br/insights/analytics/machine-learning.html>. Acesso em: 06 de abr de 2023.
- Silva S, L. D. J.S., Pinheiro, J. O.C., Santos, E. M. dos, Costa, J. I., e Meneghetti, G. A. (2019). O cooperativismo como instrumento para a autonomia de comunidades rurais da Amazônia: A experiência dos agricultores extrativistas do município de Lábrea, AM. *Boletín de La Asociación Internacional de Derecho Cooperativo*, 55, 199–226. <https://doi.org/10.18543/baidc-55-2019pp199-226>
- Silva, L. D. J S., Costa Pinheiro, J. O., Dos Santos, E. M., Da Costa, J. I., & Meneghetti, G. A. (2019b). O cooperativismo como instrumento para a autonomia de comunidades rurais da Amazônia: A experiência dos agricultores extrativistas do município de Lábrea, AM. *Boletín de La Asociación Internacional de Derecho Cooperativo*, 55, 199–226. <https://doi.org/10.18543/baidc-55-2019pp199-226>

- Silva, S. D. P.da, Eugenio, F. C., Fantinel, R. A., Amaral, L. de P., dos Santos, A. R., Mallmann, C. L., dos Santos, F. D., Pereira, R. S., & Ruoso, R. (2023). Modeling and detection of invasive trees using UAV image and machine learning in a subtropical forest in Brazil. *Ecological Informatics*, 74, 101989. <https://doi.org/10.1016/j.ecoinf.2023.101989>
- Skalski, P. Make Sense, Disponível em < /url{<https://github.com/SkalskiP/make-sense/>>,2019. Acesso em janeiro de 2024.
- Staudhammer, C. L., Wadt, L. H. O., Kainer, K. A., & Cunha, T. A. da. (2021a). Comparative models disentangle drivers of fruit production variability of an economically and ecologically important long-lived Amazonian tree. *Scientific Reports*, 11(1), 1–12. <https://doi.org/10.1038/s41598-021-81948-4>
- Sturges, H. A. (1926). "The choice of a class interval." *Journal of the American Statistical Association*, 21(153), 65–66.
- Valbuena, R., Hernando, A., Manzanera, J. A., Görgens, E. B., Almeida, D. R. A., Mauro, F., García-Abril, A., & Coomes, D. A. (2017). Enhancing of accuracy assessment for forest above-ground biomass estimates obtained from remote sensing via hypothesis testing and overfitting evaluation. *Ecological Modelling*, 366, 15–26. <https://doi.org/10.1016/j.ecolmodel.2017.10.009>
- Veras, H. F. P., Ferreira, M. P., da Cunha Neto, E. M., Figueiredo, E. O., Corte, A. P. D., & Sanquetta, C. R. (2022). Fusing multi-season UAS images with convolutional neural networks to map tree species in Amazonian forests. *Ecological Informatics*, 71, 101815. <https://doi.org/10.1016/j.ecoinf.2022.101815>
- Wadt, L. H. D. O., Marocco, J. F., Guedes, M. C., & Silva, K. E. D. (2023). *Castanha-da-amazônia: estudos sobre a espécie e sua cadeia de valor: melhoramento genético e cultivo*. (Vol. 4).

<http://www.alice.cnptia.embrapa.br/alice/handle/doc/1155401>

- Wadt, L. H. de O., Faustino, C. L., Staudhammer, C. L., Kainer, K. A., & Evangelista, J. S. (2018). Primary and secondary dispersal of *Bertholletia excelsa*: Implications for sustainable harvests. *Forest Ecology and Management*, 415–416, 98–105. <https://doi.org/10.1016/j.foreco.2018.02.014>
- Wadt, L. H. O., Kainer, K. A., & Gomes-Silva, D. A. P. (2005). Population structure and nut yield of a *Bertholletia excelsa* stand in Southwestern Amazonia. *Forest Ecology and Management*, 211(3), 371–384. <https://doi.org/10.1016/j.foreco.2005.02.061>
- Wang, C.-Y., Bochkovskiy, A., & Liao, H.-Y. M. (2022, July 6). *YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors*. arXiv.Org. <https://arxiv.org/abs/2207.02696>
- Wang, G., Li, H., Xiao, Q., Yu, P., Ding, Z., Wang, Z., & Xie, S. (2025). Fighting against forest fire: A lightweight real-time detection approach for forest fire based on synthetic images. *Expert Systems with Applications*, 262, 125620. <https://doi.org/10.1016/j.eswa.2024.125620>
- WongKinYiu. (2022). *GitHub - WongKinYiu/yolov7: Implementation of paper - YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors*. GitHub. <https://github.com/WongKinYiu/yolov7>
- Xia, R., Li, G., Huang, Z., Meng, H., & Pang, Y. (2023). Bi-path combination YOLO for real-time few-shot object detection. *Pattern Recognition Letters*, 165, 91–97. <https://doi.org/10.1016/j.patrec.2022.11.025>
- Zhang, C., Yang, G., Li, F., Wen, Y., Yao, Y., Shu, H., Simon, A., Dillenseger, J.-L., & Coatrieux, J.-L. (2023). CTANet: Confidence-Based threshold adaption network for semi-supervised segmentation of uterine regions from MR images for HIFU treatment. *IRBM*, 44(3), 100747. <https://doi.org/10.1016/j.irbm.2022.100747>

Zhu, Q., Guo, X., Deng, W., Shi, S., Guan, Q., Zhong, Y., Zhang, L., & Li, D. (2022).

Land-Use/Land-Cover change detection based on a Siamese global learning framework for high spatial resolution remote sensing imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 184, 63–78.

<https://doi.org/10.1016/j.isprsjprs.2021.12.005>

Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., Xiong, H., & He, Q. (2021). A

comprehensive survey on transfer learning. *Proceedings of the IEEE*, 109(1), 43–76. <https://doi.org/10.1109/jproc.2020.3004555>

Reconhecimentos

A pesquisa foi apoiada pela EMBRAPA-Acre (Projeto Geoflora), CAPES (Fundação Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) [88887.925393/2023-00]; Fundo JBB para a Amazônia. Agradecemos aos integrantes do projeto Geoflora e da Embrapa-Acre pela excelente assistência de campo.

Material Suplementar

Número de amostras por tipo de configuração para o algoritmo Castanheira

Configuração do Yolo	Número de amostras utilizadas no treinamento do algoritmo
Cenário I	3.003
Cenário II	11.000

Apêndices

Apêndice 1. Informações e link para as normas de publicação do periódico científico escolhido para submissão do primeiro artigo proveniente desta dissertação.

Nome da revista: Forest Ecology and Management

ISSN Online: 1872-7042

Editora: Elsevier

Fator de Impacto (2023): 3,7

Classificação Qualis/Capes em Ciências Agrárias 01: A1

Link para acesso às normas da revista (instruções para autores):
<<https://www.sciencedirect.com/journal/forest-ecology-and-management/publish/guide-for-authors>>

Link para acesso às normas do programa < <http://www2.ufac.br/ciflor/formularios-para-discentes/modelo-projeto-de-dissertacao-ciflor-formato-artigo.docx/view>>

Anexos – Projeto Geoflora – Geotecnologias aplicadas à automação florestal e espacialização dos estoques de carbono em uso nativo e modificado da terra na Amazônia Ocidental especificação do financiamento:

- Essa tela mostra inicialmente apenas um conteúdo básico. Marque abaixo as opções de sessões da submissão que deseja visualizar e clique no botão 'Consultar' para atualizar a tela.

- ☐ SELECIONAR TODOS
- ☒ Identificação

☒ Soluções de Inovação

☒ Descrição e Estrutura

☐ Orçamento

☒ Equipe

☐ Atividades

☐ Anexos

☐ Orçamento

☐ Dados Gerais do Orçamento

☐ Totalização por itens de dispêndio

Consultar

Voltar

Imprimir

Ver detalhes do orçamento

Ver Questionário de GDP

Ver projeto na linha do tempo

Tabela de Alcance dos Resultados



Empresa Brasileira de Pesquisa Agropecuária
Secretaria de Pesquisa e Desenvolvimento



Visualização da Submissão

Identificação

Edital:

Tipo de Projeto:

Estado da Submissão (na data de impressão - 21/01/2025):

Líder:

Instituição do Líder(Na Submissão):

Cargo no SIRH:

Código SEG:

Título do Projeto:

Data de Início:

Duração(meses):

Data término:

Contrato vinculado:

Chamada 00/2022 - Projetos Cofinanciados 2022 - Nacional e Internacional

Tipo II (Desenvolvimento e Validação)

em execução

EVANDRO ORFANO FIGUEIREDO

Centro de Pesquisa Agroflorestal do Acre

PESQUISADOR A

20.22.00.168.00.00

Geotecnologias aplicadas à automação florestal e espacialização de carbono em uso nativo e modificado da terra na Amazônia Ocidental

01/07/2022

36

30/06/2025

Instituições Financeiras (Lista oriunda do Orçamento)		
Nome	Tipo	Categoria
FUNDO JBS PELA AMAZONIA	Instituição Nacional Privada	Empresa
Outras Instituições Parceiras		
Nome	Tipo	Categoria
Fundação(ções) de Apoio		
FUNDAÇÃO ARTHUR BERNARDES - FUNARBE		

Descrição e Estrutura

Resumo:

Os efeitos antropogênicos do manejo florestal sobre a dinâmica dos estoques e acumulação de carbono dependem da intensidade de corte, tratamentos silviculturais, tempo de ciclo e das técnicas de planejamento e execução das operações florestais. Controles de produção, custos e monitoramento das operações e impactos são negligenciados. Acrescente-se a isto, operadores de máquinas e equipamentos mal treinados e com dificuldades em seguir novos padrões e métodos de trabalho. Este conjunto de fatores resulta em baixa produtividade, planos de manejo e planejamento somente para cumprimento de normativas, baixo nível de profissionalização da atividade de manejo florestal e pouca inovação tecnológica. Portanto a utilização de geotecnologias baseadas em LIDAR e drones, além do monitoramento in loco, insere-se como um para a transformação digital do manejo florestal.

Por serem inovações tecnológicas baseadas em ferramentas amplamente dominadas e/ou de fácil aprendizado por todos os níveis de operação (engenheiros, operadores e auxiliares), utilizarem bases de dados disponíveis e gratuitas, além de outras de custo decrescente (LIDAR/drone), podem tornar o monitoramento e fiscalização rápido, fácil e eficiente.

Assim o projeto pretende desenvolver e aprimorar ferramentas tecnológicas para automatização do planejamento e execução de inventários florestais em sistemas de manejo florestal de precisão e espacialização das emissões de carbono em diferentes usos da terra na Amazônia.

Objetivo Geral:

Gerar um conjunto de soluções tecnológicas baseadas em usos inovadores de geotecnologias e inteligência artificial, com de alta precisão, baixo custo operacional e portabilidade aplicadas ao estudo da dinâmica de carbono em diferentes usos da terra e modelagem bioeconômica ex-ante para projetos de desenvolvimento sustentável na Amazônia.

	Objetivo Específico
1/3	Desenvolver Dataset NetFlora com imagens catalogadas para deep learning de 15 espécies florestais de interesse econômico;
2/3	Desenvolver algoritmos com o peso treinado para o reconhecimento da arquitetura de copa de diferentes espécies florestais da Amazônia;
3/3	Gerar modelos de dinâmica de estoques de carbono e gases de efeito em florestas manejadas

Campos Adicionais:

Equipe

Nome	Função	Instituição	E-mail
EVANDRO ORFANO FIGUEIREDO	Responsável por PA/Solução/Contribuição, Líder Projeto, Responsável Atividade	Centro de Pesquisa Agroflorestal do Acre	evandro.figueiredo@embrapa.br
FALBERNI DE SOUZA COSTA	Responsável Atividade	Centro de Pesquisa Agroflorestal do Acre	falberni.costa@embrapa.br
FERNANDO WAGNER MALAVAZI	Responsável Atividade	Centro de Pesquisa Agroflorestal do Acre	fernando.malavazi@embrapa.br
JULIANA DE OLIVEIRA SANTOS MARCATTO	Responsável Atividade	Centro Nacional de Pesquisa de Monitoramento e Avaliação de Impacto Ambiental	juliana.oliveira@embrapa.br
LUIS CLAUDIO DE OLIVEIRA	Responsável Atividade, Responsável por PA/Solução/Contribuição	Centro de Pesquisa Agroflorestal do Acre	luis.oliveira@embrapa.br
MARCUS VINICIO NEVES D OLIVEIRA	Responsável Atividade	Centro de Pesquisa Agroflorestal do Acre	marcus.oliveira@embrapa.br

Gestão, Soluções para Inovação, Resultados e Atividades

Solução para Inovação: Gestão do Projeto	
Código SEG:	20.22.00.168.00.01
Descrição:	A SI propõe a criação de uma solução de forma disruptiva, promover a transformação digital do manejo de recursos florestais na Amazônia, desde sua quantificação, planejamento, e monitoramento das operações. A definição de processo de obtenção de métricas a partir dos produtos gerados pela fotogrametria digital com UAS permitirá obter, de maneira mais automatizada, as variáveis necessárias para realizar o planejamento florestal do POA, reduzindo sensivelmente a demanda por mão de obra em campo para realizar o inventário florestal. A TT tem importância estratégica no resultado final, que envolvem o treinamento de algoritmos para desempenhar o papel do olhar humano na localização, identificação de espécies e extração de métricas. Essa experiência de "treinar e usar máquinas" no planejamento de nativas pode ser considerado a fronteira do conhecimento da área e demanda muitas especialidades que a Embrapa compartilhará de forma direta junto com a JBS às informações geradas e analisadas nas Atividades 1 e 2 da SI, serão disponibilizadas aos colaboradores numa nuvem de dados (a ser alugada pelo projeto, pois são dezenas de TBs). Cada colaborador terá acesso parcial na nuvem e terão ações pontuais, sendo: 1. a UFAC/Ciflor será responsável pelas amostras de treinamento dos algoritmos (ATA) e apoio em TT; 2. o SFB vai disponibilizar a base de dados de IF das FLONAs do Jacundá e Jamari, onde serão implantadas URTs; 3. o INPA fornecerá assessoria em botânica para estabelecer uma rotina de reconhecimento de padrões de espécies florestais a partir das ortofotos; 4. a FUNTAC auxiliará na formação da ATA e TT; 5. a USP buscará ajustar scripts para processar algoritmos de identificação em softwares livres; 6. o IFAC dará apoio a coleta de dados e na TT; 7. o IME será o responsável por ajustar rotinas de reconhecimento de espécie por Learning Machine (LM) em ambiente MATLAB; 8. a UFPI vai trabalhar com LM para ajuste de modelos para as variáveis dendrométricas, em ambiente R; e, finalmente a Embrapa Acre estará envolvida em todas as atividades, sendo que no ajuste dos algoritmos será dada prioridade ao GEOBIA e LM em ambiente R, ArcGIS, SAS e e-Cognition, sendo a licença deste último deverá ser adquirida pelo projeto. Como ferramenta de gestão serão realizadas WebConf em cada etapa vencida por um dos parceiros.
Data de Início:	01/07/2022
Duração(meses):	36
Data término:	30/06/2025
Responsável:	EVANDRO ORFANO FIGUEIREDO
Instituição:	Centro de Pesquisa Agroflorestal do Acre
Resultados:	Resultado nº: 1 tipo de Resultado: Capacitação e atualização tecnológica de agentes multiplicadores Sigiloso: Não Responsável: LUIS CLAUDIO DE OLIVEIRA Descrição: Capacitação de analistas ambientais, engenheiros florestais, professores universitários e discentes de cursos de mestrado e doutorado em técnicas de planejamento visando a automação para o manejo florestal 4.0, através do desenvolvimento de competência em TI aplicadas em estruturação de Bigdata e inteligência artificial (Rede Neural Convolutacional ou Convolutional Neural Network (CNN), aplicadas ao desenvolvimento de algoritmos de reconhecimento, geoprocessamento e espacialização de dados LIDAR. Ano previsão de Alcance : 2024 Status do resultado em 21/01/2025: Alcançado Totalmente TRL prevista: Não se aplica

Solução para Inovação: Geotecnologias aplicadas a automação de inventários florestais prospectivos em planos de manejo florestal sustentável e geração de estimativas e espacialização de estoques de carbono na Amazônia	
Código SEG:	20.22.00.168.00.02
Descrição:	A solução proposta visa aumentar a automação nas atividades de inventário florestal prospectivo e espacialização de estimativas de estoques de carbono, através do desenvolvimento e transferência de tecnologia para: i) ampliar a escala temporal e padrões de reconhecimento e identificação de espécies florestais em três diferentes tipologias florestais na Amazônia (floresta densa, floresta aberta com bambu e floresta aberta com palmeiras); ii) Estruturar bancos de dados de imagens catalogadas para deep learning (Dataset) de copas; iii) Ajustar algoritmos de aprendizagem profunda de máquina com

Benefícios Diferencial:

pesos treinados, visando a automação de detecção e geolocalização para inventários florestais de espécies madeiras e não-madeiras da Amazônia; iv) Desenvolver competência em TI aplicadas em estruturação de Bigdata e inteligência artificial (Rede Neural Convolutacional ou Convolutional Neural Network (CNN), aplicadas ao desenvolvimento de algoritmos de reconhecimento, geoprocessamento e espacialização de dados LiDAR e v) Transferência de tecnologias para: a) planejamento de missões de mapeamento florestal com UAS; b) processamento da fotogrametria digital; c) segmentação e classificação de imagens de alta resolução; d) técnicas de extração métricas e estimativas variáveis florestais e e) identificação de espécies por reconhecimento de copas. A geração de informações sobre as fenofases de diferentes tipologias florestais permitirá estabelecer um calendário de inventário florestal amplificado, indicando os meses do ano mais propícios para realizar as missões de voo de mapeamento florestal, com a finalidade de localizar geograficamente e extrair métricas de copa de um conjunto de espécies de interesse. A definição de processo de obtenção de métricas a partir dos produtos gerados pela fotogrametria digital com UAS permitirá obter, de maneira mais automatizada, as variáveis necessárias para realizar o planejamento florestal do POA, reduzindo a demanda por mão de obra.

A geração de informações sobre as fenofases de diferentes tipologias florestais permitirá estabelecer um calendário de inventário florestal amplificado, indicando os meses do ano mais propícios para realizar as missões de voo de mapeamento florestal, com a finalidade de localizar geograficamente e extrair métricas de copa de um conjunto de espécies de interesse. A identificação de espécies por reconhecimento de copas e estimativas de volume do fuste, altura comercial /ou total, altura de copa, presença de cipós, copas quebradas, presença de inflorescências e frutos métricas das copas das árvores dominantes a partir da extração de métricas e ajustes de modelos permitirá obter, de maneira mais automatizada, as variáveis necessárias para realizar o planejamento florestal do POA, reduzindo sensivelmente a demanda por mão de obra em campo para realizar o inventário florestal.

Data de Início:

01/07/2022

Duração(meses):

36

Data término:

30/06/2025

Responsável:

LUIS CLAUDIO DE OLIVEIRA

Instituição:

Centro de Pesquisa Agroflorestal do Acre

Vinculação desta Solução para Inovação aos Desafios de Inovação	
Portfólio	Desafio de Inovação
Florestal	Manejar de forma sustentável a madeira e produtos não madeireiros de espécies florestais nativas
	compromisso da UD nesse DI
	Definir uma estratégia de manejo para mitigar a lenta recomposição dos estoques de madeira, em florestas naturais manejadas, até 2025.

Resultados:

Resultado nº: 1

tipo de Resultado: Banco de dados

Sigiloso: Não

Responsável: EVANDRO ORFANO FIGUEIREDO

Descrição: Conjunto de ortofotos coletadas por RPA e arquivos originais de projetos fotogramétricos dos pontos de catalogados, constituído de imagens de copas catalogadas para Deep Learning, de 15 espécies florestais madeiras e não madeiras, além de palmeiras da Amazônia, coletadas em 19 sítios (Iracema; Flonas Jacundá e Jamari; áreas indígenas Poyanawa e Kaxinawa, e áreas de manejo florestal autorizadas pelo IMAC). Dados armazenados e disponibilizados na Infraestrutura de dados espaciais da Emb

Ano previsão de Alcance : 2024

Status do resultado em 21/01/2025: Alcançado Totalmente

TRL prevista: Não se aplica

Resultado nº: 2

tipo de Resultado: Produto/Insumo agropecuário ou Industrial

Sigiloso: Não

Responsável: EVANDRO ORFANO FIGUEIREDO

Descrição: Sistema automatizado de inventário florestal para Aeronaves Remotamente Pilotadas (ARP), baseado em algoritmos com o peso treinados (yolo) para o reconhecimento da arquitetura de copa de diferentes espécies florestais de 15 espécies florestais, e captação de ortofotos e upload de imagens para o planejamento da exploração em bases sustentáveis.

Ano / TRL:

Ano	TRL	Informações Adicionais	Status do resultado em 21/01/2025
2024	TRL/MRL 8	Sistema automatizado prevê um rendimento de 100 hectares inventariados por dia	Alcançado Totalmente

Referência Técnica:

Coefficiente Técnico	Unidade de Medida	Valor de Referência	Referência Bibliográfica	Tipo
área inventariada por equipe de campo (hectare/dia)	hectare/dia	10	FIGUEIREDO, E. O.; LIMA, Q de. Coeficientes Técnicos para o Inventário e Manejo Florestal com Emprego do Modelo Digital de Exploração Florestal (Modelflora). Comunicado Técnico 169. Rio Branco, AC. Dezembro, 2008. 169ISSN 0100-8668.	Original

Resultado nº: 3

tipo de Resultado: Banco de dados

Sigiloso: Não

Responsável: MARCUS VINICIO NEVES D OLIVEIRA

Descrição: Conjunto de nuvens de pontos e imagens rgb coletadas por drones Matrice com RTK e Zenmuse L1 (LiDAR), e validados por dados LIDAR coletados por aeronaves nas Florestas Estaduais do

Gregório e Mogno, e áreas indígenas Poyanawa e Kaxinawa, para upscale de carbono acima do solo.). Dados armazenados e disponibilizados na Infraestrutura de dados espaciais da Embrapa (Geoinfo).
Ano previsão de Alcance : 2024
Status do resultado em 21/01/2025: Alcançado Totalmente
TRL prevista: Não se aplica

Resultado nº: 4
tipo de Resultado: Banco de dados
Sigiloso: Não
Responsável: MARCUS VINICIO NEVES D OLIVEIRA
Descrição: Conjunto de dados de parcelas permanentes de 1ha georeferenciadas e estruturados, registrados e ordenados contendo: identificação do indivíduo, ano, número da parcela permanente, número da subparcela e número da plaqueta (na floresta), nomes comuns, científico, gênero, família, característica ecológica (pioneira), estado de saúde da árvore, CAP, DAP, equivalência em área basal (AB), etc. Dados armazenados e disponibilizados na Infraestrutura de dados espaciais da Embrapa (Geoinfo).
Ano previsão de Alcance : 2024
Status do resultado em 21/01/2025: Alcançado Parcialmente
TRL prevista: Não se aplica

Resultado nº: 5
tipo de Resultado: Metodologia técnico-científica
Sigiloso: Não
Responsável: MARCUS VINICIO NEVES D OLIVEIRA
Descrição: Modelos de inferência e estimativa de estoques de carbono e biomassa baseados na combinação de dados de câmeras RGB coletadas por drones Matrice com RTK e Zenmuse L1 (LiDAR) e sensores LiDAR em aeronaves tripuladas. Depois de convertido em algoritmo escalável, o modelo dará subsídio ao Mapeamento de estoques de carbono em florestas da Amazônia Ocidental.
Ano previsão de Alcance : 2025
Status do resultado em 21/01/2025: Previsto
TRL prevista: Não se aplica

Resultado nº: 6
tipo de Resultado: Metodologia técnico-científica
Sigiloso: Não
Responsável: MARCUS VINICIO NEVES D OLIVEIRA
Descrição: Modelos de predição de produção florestal baseados na combinação de dados de dados de câmeras RGB coletadas por drones Matrice com RTK e Zenmuse L1 (LiDAR) e dados de crescimento coletados em parcelas permanentes de 1ha com idades de medição entre 30 e 15 anos. Depois de convertido em tabelas de predição de crescimento, o modelo dará subsídio a definição do ciclo de corte em florestas manejadas na Amazônia Ocidental.
Ano previsão de Alcance : 2025
Status do resultado em 21/01/2025: Previsto
TRL prevista: Não se aplica

Resultado nº: 7
tipo de Resultado: Banco de dados
Sigiloso: Não
Responsável: FALBERNI DE SOUZA COSTA
Descrição: Conjunto de dados de fatores de emissão de dióxido de carbono, óxido nítrico e metano de biomassa e solos, coletados por cromatografia e IRGA, em ambientes de manejo florestal georeferenciados e espacializados, para ajustes de balanços de gases de efeito estufa e modelos de crescimento. Dados armazenados e disponibilizados na Infraestrutura de dados espaciais da Embrapa (Geoinfo).
Ano previsão de Alcance : 2024
Status do resultado em 21/01/2025: Alcançado Totalmente
TRL prevista: Não se aplica

Referências bibliográficas

ALBUQUERQUE, R.W.; OLIVEIRA, C.M.; FERREIRA, M.; CARRERO, G.; GROHMANN, C.H. Remotely Piloted Aircraft Imagery for Automatic Tree Counting in Forest Restoration Areas: a Case Study in the Amazon. Journal of Unmanned Vehicle Systems, n. ja, 2020.
AIRMAP. Airspace intelligence to Power the Drone Economy. Disponível em: < <https://www.airmap.com/>>. Acesso em: 27 de maio de 2020.
ANAC. Cadastro de Drones. Disponível em:< <https://www.anac.gov.br/assuntos/paginas-tematicas/drones/cadastro-de-drones>>. Acesso em: 24 de abril de 2017.
ARDILA, J.P.; BIJKE, W.; TOLPEKIN, V.A.; STEIN, A. Context-sensitive extraction of tree crown objects in urban areas using VHR satellite images. International journal of applied earth observation and geoinformation, v. 15, p. 57-69, 2012.
ARDUPILOT. License (GPLv3). Disponível em: < <https://ardupilot.org/dev/docs/license-gplv3.html>>. Acesso em: 27 de maio de 2020.
BARUSO, A.P. A determinação de funções de crescimento mediante análise do tronco. Curitiba: UFPR, 1977. (Tese não defendida).
BRAZ, E.M.; OLIVEIRA, M.V.N.; ARAUJO, H.J.B.; MIRANDA, E.M. Plano de exploração sob critérios de manejo florestal de baixo impacto. Embrapa Acre-Circular Técnica (INFOTECA-E). 1998.
BURGER, A. Helveta: Supply Chain Software Firm Tackles Deforestation by Digitizing Trees, Timber. 2012. Disponível em: < <https://www.triplepundit.com/story/2012/helveta-supply-chain-software-firm-tackles-deforestation-digitizing-trees-timber/67296>>. Acesso em: 01 de junho de 2020.
CEPEA. Informativo Setor Florestal. Cepea, n.199, Julho, 2018.
CHATTERJEE, S.; HADI, A.S. 1986. Influential observations, high leverage points, and outliers in linear regression. Statistical Science, 3(1): 379-416.
CHEHAIBOU, B.; BADAWI, M.; BUČKO, T.; BAZHIROV, T.; ROCCA, D. Computing RPA adsorption enthalpies by machine learning thermodynamic perturbation theory. Journal of Chemical Theory and Computation, v. 15, n. 11, p. 6333-6342, 2019.
CHEN, G.; HAY, G.J.; ST-ONGE, B. A GEOBIA framework to estimate forest parameters from lidar transects, Quickbird imagery and machine learning: A case study in Quebec, Canada. International Journal of Applied Earth Observation and Geoinformation, v. 15, p. 28-37, 2012.

CLEWLEY, D.; BUNTING, P.; SHEPHERD, J.; GILLINGHAM, S.; FLOOD, N.; DYMOND, J.; MOGHADDAM, M. A python-based open source system for geographic object-based image analysis (GEOBIA) utilizing raster attribute tables. *Remote Sensing*, v. 6, n. 7, p. 6111-6135, 2014.

CONFORTO, E.; BARRETO, F.; AMARAL, D. C.; REBENTISCH, E. Modelos Híbridos: unindo complexidade, agilidade e inovação. *Revista Mundo PM*, 11(64), 10-17. 2015.

CUNHA, R.M.; FIGUEIREDO, E.O.; D'OLIVEIRA, M.V.N.; PAPA, D.A. Estimativa da perda de biomassa em área de manejo florestal sustentável na Amazônia por meio da combinação de dados LiDAR e câmeras RGB a bordo de Aeronave Remotamente Pilotada (ARP). In: XIX Simpósio Brasileiro de Sensoriamento Remoto, 2019, Santos. XIX Simpósio Brasileiro de Sensoriamento Remoto, 2019. v. 1. p. 1-4.

CUNHA, T.A.; CAVALLI, J.P.; FINGER, C.A.G. Relação entre alongamento anual da copa e o incremento diamétrico de árvores singulares de *Cedrela fissilis* (Vell). *Ciência Florestal*, [S.l.], v. 23, n. 4, p. 703-712, 2013.

D'OLIVEIRA, M.V.N.; BROADBENT, E.N.; OLIVEIRA, L.C.; ALMEIDA D.R.A.; PAPA, D.A.; FERREIRA, M.E.; ZAMBRANO, A.M.A.; SILVA, C.A.; AVINO, F.S.; PRATA, G.A.; MELLO, R.A.; FIGUEIREDO, E.O.; CASTRO JORGE, L.A.; JUNIOR, L.; ALBUQUERQUE, R.W.; BRANCALION, P.H.S.; WILKINSON, B.; COSTA, M.O. Aboveground Biomass Estimation in Amazonian Tropical Forests: a Comparison of Aircraft- and GatorEye UAV-borne LiDAR Data in the Chico Mendes Extractive Reserve in Acre, Brazil. *Remote Sensing*, v.12, n.1754; doi:10.3390/rs12111754.

D'OLIVEIRA, M.V.N.; FIGUEIREDO, E.O.; PAPA, D.A. Uso do LiDAR como Ferramenta para o Manejo de Precisão em Florestas Tropicais. *Embrapa Acre-Livro técnico (INFOTECA-E)*, 2014. 130 p.

DA ROSA, C.N.; PICCILLI, D.G.A.; TASSI, R.; FAVARETTO, J.R.; LIMBERGER, M.F. Utilização de Veículos Aéreos Não Tripulados em Projetos de Drenagem Urbana. *Anuário do Instituto de Geociências*, v. 41, n. 1, p. 308-317, 2019.

DALLA CORTE, A.P.; REX, F.E.; ALMEIDA, D.R.A.D.; SANQUETTA, C.R.; SILVA, C.A.; MOURA, M.M.; MORAES, A.D. Measuring Individual Tree Diameter and Height Using GatorEye High-Density UAV-Lidar in an Integrated Crop-Livestock-Forest System. *Remote Sensing*, v. 12, n. 5, p. 863, 2020.

DEFINIENS, A.G. Definiens Developer 7 - Guia do Usuário. Versão do documento , v. 7, n. 5.968, 2007.

DESCLEE, B.; BOGAERT, P.; DEFOURNY, P. Forest change detection by statistical object-based method. *Remote Sensing of Environment*, v. 102, n. 1-2, p. 1-11, 2006.

DJI. DJI AirSense. Disponível em: < <https://www.dji.com/br/flysafe/airsense>>, 2020. Acesso em: 02 de junho de 2020.

DJI. Download Center. Disponível em: < <https://www.dji.com/br/downloads/djiapp/dji-go-4>>. Acesso em: 27 de maio de 2020.

DJI. Phantom 4 Pro. Disponível em: . Acesso em: 4 abr. 2019.

DO NASCIMENTO SILVA, L.C.; BACANI, V.M. Classificação orientada a objeto (GEOBIA) aplicada à análise das alterações do uso e cobertura da terra da Bacia Hidrográfica do Rio da Prata em Jardim e Bonito-MS. *Geografia (Londrina)*, v. 26, n. 1, p. 05-18, 2017.

D'OLIVEIRA, M.V.; REUTEBUCH, S.E.; MCGAUGHY, R.J.; ANDERSEN, H.E. Estimating forest biomass and identifying low-intensity logging areas using airborne scanning lidar in Antimary State Forest, Acre State, Western Brazilian Amazon. *Remote Sensing of Environment*, v. 124, p. 479-491, 2012.

DRĂGUȚ, L.; TIEDE, D.; LEVICK, S. R. ESP: a tool to estimate scale parameter for multiresolution image segmentation of remotely sensed data. *International Journal of Geographical Information Science*, v. 24, p. 859-871, 2010.

DRONEDEPLOY. Aplicativo de voo para empresas. Disponível em: < <https://www.dronedeploy.com/product/mobile/>>. Acesso em: 27 de maio de 2020.

DURLO, M.A. Relações morfométricas para *Cabralea canjerana* (Well.) Mart. *Ciência Florestal*, v. 11, n. 1, p. 141-149, 2001.

DURLO, M.A.; SUTILI, F.J.; DENARDI, L. Modelagem da copa de *Cedrela fissilis* Vellozo. *Ciência Florestal*, Santa Maria, v. 14, n. 2, p. 79-89, dez. 2004.

FERNANDES, R.R.; NUNES, G.M.; SILVA, T.S.F. Classificação orientada a objetos aplicada na caracterização da cobertura da terra no Araguaia. *Pesq. agropec. bras.*, Brasília, v. 47, n. 9, p. 1251-1260, 2012.

FERREIRA DA SILVA, E.; DA SILVA, G.; FIGUEIREDO, E.O.; BREDA, D.B.; MENDONÇA, A.R.; TORRES, C.M.M.E.; PEZZOPANE, J.M. Allocation of Storage Yards in Management Plans in the Amazon by Means of Mathematical Programming. *Forests*, v. 9, p. 127, 2018.

FERREIRA DA SILVA, E.; SILVA, R.F.; VIEIRA, G.C.; LEITE, C.C.C.; OTONE, M.A.; FIGUEIREDO, E.O.; SILVA, G.F. Planejamento de unidades de produção para áreas de manejo de floresta nativa na Amazônia. *Revista Brasileira de Ciências Agrárias (Agrária)*, v. 13, n. 1, p. 5502, 2018.

FIGUEIREDO, E. O. Modelagem biométrica para árvores individuais a partir do LiDAR em área de manejo de precisão em florestas tropicais na Amazônia Ocidental. 2014 Manaus: [s.n.], Tese (Doutorado) INPA, Manaus, 2014.

FIGUEIREDO, E.O.; BRAZ, E. M.; OLIVEIRA, M.V.N.d'. Manejo de precisão em florestas tropicais: Modelo Digital de Exploração Florestal. Rio Branco, AC: Embrapa Acre, 2007. 183 p.

FIGUEIREDO, E.O.; D'OLIVEIRA, M. V. N., FEARNSIDE, P. M., BRAZ, E. M., PAPA, D. de A. Equations to estimate tree gaps in a precision forest management area the amazon based on crown morphometry. *Rev. Árvore, Viçosa* , v. 41, n. 3, e410313, 2017.

FIGUEIREDO, E.O.; D'OLIVEIRA, M. V. N.; FIGUEIREDO, S.M.M. Uso de aeronaves remotamente pilotadas (arp) no planejamento florestal. In: ABREU, D.C.. (Org.). VIII Simpósio Brasileiro de Agropecuária. Fed.Sinop: UFV, 2016, v. 1, p. 65-72.

FIGUEIREDO, E.O.; D'OLIVEIRA, M.V.N.; FIGUEIREDO, S.M.M.; CUNHA, R.M. Dimensionamento da área de impacto na exploração florestal na Amazônia, a partir da fotogrametria com Aeronaves Remotamente Evandro Orfanó Figueiredo Pilotada (RPA), Classe III. In: X Simpósio Brasileiro de Pós-Graduação em Ciências Florestais, 2018, Natal - Rio Grande do Norte. X Simpósio Brasileiro de Pós-Graduação em Ciências Florestais. Natal - RN: UFRN, 2018. v. 1. p. 622-626.

FIGUEIREDO, E.O.; D'OLIVEIRA, M.V.N.; LOCKS, C.J.; PAPA, D.A. Estimativa do Volume de Madeira em Pátios de Estocagem de Toras por meio de Câmeras RGB Instaladas em Aeronaves Remotamente Pilotada. Rio Branco: Embrapa Acre, 2016 (Boletim de Pesquisa).

FIGUEIREDO, E.O.; FIGUEIREDO, S.M.M. Planos de voo semiautônomos para fotogrametria com aeronaves remotamente pilotadas de classe 3. Rio Branco, AC: Embrapa Acre, 2018. 50 p. (Embrapa Acre. Circular técnica, 75).

FIGUEIREDO, E.O.; FIGUEIREDO, S.M.M.; D'OLIVEIRA, M. V. N.; SANTOS, E. K. M. dos. Manejo Florestal 4.0: Calendário Preliminar de Inventário Florestal com Aeronaves Remotamente Pilotadas. Rio Branco, AC: Embrapa Acre, 2018.

FIGUEIREDO, E.O.; FIGUEIREDO, S.M.M.; OLIVEIRA, M.D.; SANTOS, E.K.M. Manejo florestal 4.0-planejamento com aeronaves remotamente pilotadas (RPAs). In: Embrapa Acre-Resumo em anais de congresso (ALICE). Pesquisa Florestal Brasileira, v. 39, e201902043, p. 525, 2019. Special issue., 2019.

FIGUEIREDO, E.O.; LIMA, Q.S. Coeficientes técnicos para o inventário e manejo florestal com emprego do Modelo Digital de Exploração Florestal (MODEFLORA). Embrapa Acre-Comunicado Técnico, 2008. (INFOTECA-E).

FIGUEIREDO, E.O.; MOURA, D.S.; FIGUEIREDO, S.M.M.; PAPA, D.A. Modelagem da hidrografia em planos de manejo e critérios para definição de árvores em APP pelo Modeloflora. Embrapa Acre-Circular Técnica (INFOTECA-E). 2009.

FIGUEIREDO, E.O.; OLIVEIRA, M. V. N. d'; BRAZ, E. M.; PAPA, D. A.; EARNSIDE, P. M. LiDAR-based estimation of bole biomass for precision management of an Amazonian forest: comparisons of ground-based and remotely sensed estimates. *Remote Sensing of Environment*, v. 187, p. 281-293, Dec. 2016.

FIGUEIREDO, S.M.M.; FIGUEIREDO, E.O. Espacialização de espécies florestais por classe diamétrica usando máxima entropia no sudoeste da Amazônia. In: Embrapa Acre-Artigo em anais de congresso (ALICE). In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 19., 2019, Santos, SP. Anais... São José dos Campos: INPE, 2019. 2019.

GALEANO, I.A.S.; MALDONADO, J.A.H. Detección de baches en vías urbanas a partir de imágenes de alta resolución espacial, mediante técnicas de GEOBIA. *Revista de Topografía AZIMUT*, v. 10, n. 1, 2019.

GOODBODY, T.R.; COOPS, N.C.; MARSHALL, P.L.; TOMPALSKI, P.; CRAWFORD, P. Unmanned aerial systems for precision forest inventory purposes: A review and case study. *The Forestry Chronicle*, v. 93, n. 1, p. 71-81, 2017.

GRAÇA, N.L.S.D.S.; MITSHITA, E. A.; GONÇALVES, J. E. Use of UAV platform as an autonomous tool for estimating expansion on invaded agricultural land. *Boletim de Ciências Geodésicas*, Curitiba, v. 23, n. 3, 2017, p. 509-519

HAY, G.J.; CASTILLA, G. Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline. In: Object-based image analysis. Springer, Berlin, Heidelberg, 2008. p. 75-89.

IZUKA, K.; YONEHARA, T.; ITOH, M.; KOSUGI, Y. Estimating Tree Height and Diameter at Breast Height (DBH) from Digital surface models and orthophotos obtained with an unmanned aerial system for a Japanese Cypress (*Chamaecyparis obtusa*) Forest. *Remote Sensing*, v. 10, n. 1, p. 13, 2018.

INAMASU, R. Y.; BELLOTE, A. F. J.; LUCHIARI JUNIOR, A.; SHIRATSUCHI, L. S.; ARMANDO, P.; OLIVEIRA, V. DE; BERNARDI, A. C. DE C.; Portfólio automação agrícola, pecuária e florestal /- São Carlos, SP: Embrapa, 2016

JÚNIOR, R.T.; SILVA, V.S.M.; BERGER, R.; MELLO, R.A.T. Rentabilidade econômica do manejo de baixo impacto em florestas tropicais: um estudo de caso. *Floresta*, v.38, 4p. 2008.

KAINER, K.A.; WADT, L.H.; GOMES-SILVA, D.A.; CAPANU, M. Liana loads and their association with *Bertholletia excelsa* fruit and nut production, diameter growth and crown attributes. *Journal of Tropical Ecology*, 22(2), 147-154. 2006

KAMAL, M.; JOHANSEN, K. Explicit area-based accuracy assessment for mangrove tree crown delineation using Geographic Object-Based Image Analysis (GEOBIA). In: Earth Resources and Environmental Remote Sensing/GIS Applications VIII. International Society for Optics and Photonics, 2017. p. 104280I.

KIM, M.; WARNER, T.A.; MADDEN, M.; ATKINSON, D.S. Multi-scale GEOBIA with very high spatial resolution digital aerial imagery: scale, texture and image objects. *International Journal of Remote Sensing*, v. 32, n. 10, p. 2825-2850, 2011.

LITCHI. Unlock the full potencial of your DJI drone with Litchi. Disponível em: < <https://flylitchi.com/>>. Acesso em: 27 de maio de 2020.

LIU, K.; SHEN, X.; CAO, L.; WANG, G.; CAO, F. The evaluation of parametric and non-parametric models for total forest biomass estimation using UAS-LIDAR. In: 2018 Fifth International Workshop on Earth Observation and Remote Sensing Applications (EORSA). IEEE. 2018. p. 1-5.

LOWE, D. G. Distinctive Image Features from ScaleInvariant Keypoints. *International Journal of Computer Vision*, vol. 60, n.2, 2004, pp 91-110.

LOWE, D. G. Object recognition from local scale-invariant features. In: Proceedings of the International Conference on Computer Vision. Vol 2, 1999 p. 1150-1157.

MAPS. Aerial Map Processing & Hosting. Disponível em: < <https://www.mapsmadeeasy.com/>>. Acesso em: 27 de maio de 2020.

MATOS, M. A. Manual operacional para a regressão linear. Porto, Portugal: Feup, 1995.

MAXWELL, A.E.; STRAGER, M.P.; WARNER, T.A.; RAMEZAN, C.A.; MORGAN, A.N.; PAULEY, C.E. Large-Area, High

Spatial Resolution Land Cover Mapping Using Random Forests, GEOBIA, and NAIP Orthophotography: Findings and Recommendations. *Remote Sensing*, v. 11, n. 12, p. 1409, 2019.

MELO JÚNIOR, A. Uso de Unmanned Aircraft Systems (UAS) em um inventário florestal censitário, para estimativa do DAP. 2019. Rio Branco: [s.n.], Dissertação (Mestrado) UFAC, Rio Branco, 2019.

MIKITA, T.; JANATA, P.; SUROVÝ, P. Forest stand inventory based on combined aerial and terrestrial close-range photogrammetry. *Forests*, v. 7, n. 8, p. 165, 2016.

MING, D.; LI, J.; WANG, J.; ZHANG, M. Scale parameter selection by spatial statistics for GeoBIA: Using mean-shift based multi-scale segmentation as an example. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 106, p. 28-41, 2015.

MINISTÉRIO DA DEFESA. 2018. ICA 100-40, reeditada em 20 de novembro de 2018. Dispõe sobre a regulamentar os procedimentos e responsabilidades necessários para o acesso seguro ao Espaço Aéreo Brasileiro por aeronaves não tripuladas. (www.decea.gov.br) Acesso em: 11 de abril de 2019.

NUIJTEN, R.J.; COOPS, N.C.; GOODBODY, T.R.; PELLETIER, G. Examining the Multi-Seasonal Consistency of Individual Tree Segmentation on Deciduous Stands Using Digital Aerial Photogrammetry (DAP) and Unmanned Aerial Systems (UAS). *Remote Sensing*, v. 11, n. 7, p. 739, 2019.

NUNES, G.M.; DE SIQUEIRA, T.M.D. Análise Temporal de Macro-habitat no Pantanal via Processamento de Fotografias Aéreas e Dados Obtidos por Sistemas de Aeronaves Remotamente Pilotadas. *Biodiversidade Brasileira*, n. 2, p. 71-85, 2019.

OLIVEIRA SOBRINHO M. F. DE, CORTE, A. P. D.; VASCONCELLOS, B. N. DE.; SANQUETTA, C. R.; REX, F. E.; Uso de Veículos Aéreos Não Tripulados (vant) para Mensuração de Processos Florestais. *Enciclopédia Biosfera*, Centro Científico Conhecer - Goiânia, v.15 n.27; p. 2018.

PIX4D. Free drone flight planning APP for optimal 3D mapping and modeling. Disponível em: . Acesso em: 27 de maio de 2020.

PIX4D. Getting GCPs on the field or through other sources (optional but recommended). 2015. Disponível em: . Acesso em: 5 de abril 2019.

POWERS, R.P.; HAY, G.J.; CHEN, G. How wetland type and area differ through scale: A GEOBIA case study in Alberta's Boreal Plains. *Remote Sensing of Environment*, v. 117, p. 135-145, 2012.

PULITI, S.; ØRKA, H.O.; GOBÄKKEN, T.; NÆSSET, E. Inventory of small forest areas using an unmanned aerial system. *Remote Sensing*, v. 7, n. 8, p. 9632-9654, 2015.

REX, F. E., SILVA, C. A., DALLA CORTE, A. P., KLAUBERG, C., MOHAN, M., CARDIL, A., ... & VALBUENA, R. Comparison of Statistical Modelling Approaches for Estimating Tropical Forest Aboveground Biomass Stock and Reporting their Changes in Low-intensity Logging Areas using Multi-temporal LiDAR Data. *Remote Sensing*, v. 12, n. 9, p. 1498, 2020.

ROMAN, M.; BRESSAN, D. A.; DURLIO, M. A. Variáveis morfométricas e relações interdimensionais para Cordia trichotoma (Vell.) Arrab. ex Steud. *Ciência Florestal*, Santa Maria, v. 19, n. 4, p. 473-480, 2009.

RUTISHAUSER, E.; HÉRAULT, B.; BARALOTO, C.; BLANC, L.; DESCROIX, L.; SOTTA, E.D.; OLIVEIRA, L.C. Rapid tree carbon stock recovery in managed Amazonian forests. *Current Biology*, v. 25, n. 18, p. R787-R788, 2015.

RYAN, T.P. Estatística moderna para engenharia. Rio de Janeiro: Elsevier, 2011. 324p.

SANQUETTA, C.R.; BEHLING, A.; CORTE, A.P.D.; FERNANDES, A.C.; BECKERT, S.M.; SIMON, A.A. Equações para estimativa do diâmetro de copa para Acácia-negra. *Floresta e Ambiente*, v. 21, n. 2, p. 192-205, 2014.

SAS INSTITUTE. SAS User's guide: statistics. Release 6.03. Cary, 1990. 584p.

SCOLFORO, J. R. S. Biometria florestal: parte I: modelos de regressão linear e não linear: parte II: modelos para relação hipsométrica, volume, afilamento e peso da matéria seca. Lavras: UFLA/FAEPE, 2005. 352 p.

SHEN, X.; CAO, L.; YANG, B.; XU, Z.; WANG, G. Estimation of forest structural attributes using spectral indices and point clouds from UAS-based multispectral and RGB imageries. *Remote Sensing*, v. 11, n. 7, p. 800, 2019.

SHIN, P.; SANKEY, T.; MOORE, M.M.; THODE, A.E. Evaluating unmanned aerial vehicle images for estimating forest canopy fuels in a ponderosa pine stand. *Remote Sensing*, v. 10, n. 8, p. 1266, 2018.

SILVA, J.N.M. Manejo florestal. Brasília, DF: EMBRAPA-SPI; Belém, PA: EMBRAPA-CPATU, 1996.

SMITH, G.M.; MORTON, R.D. Real world objects in GEOBIA through the exploitation of existing digital cartography and image segmentation. *Photogrammetric Engineering & Remote Sensing*, v. 76, n. 2, p. 163-171, 2010.

SOARES P.; FIRMINO P.; TOMÉ M.; CAMPAGNOLO M.; OLIVEIRA J.; OLIVEIRA B.; ARAÚJO J.; CÂMARA F. A utilização de Veículos Aéreos Não Tripulados no inventário florestal – o caso do montado de sobre. In: Conferência Nacional de Cartografia e Geodésia-CNCG, 8. Lisboa. Anais...Lisboa: VII CNCG, 2015. p. 1- 8.

SOUZA, G.S. Introdução aos modelos de regressão linear e não-linear. Brasília: Embrapa-SPI/Embrapa-SEA, 1998. 505 p.

STATGRAPHICS. 2006. Statgraphics Centurion XV: User's guide. StatPoint Inc. EUA, 299p.

STOURNARA, P.; PATIAS, P.; KARAMANOLIS, D. Evaluating wood volume estimates derived from Quickbird imagery with GEOBIA for Pinus nigra trees in the Pentalofos forest, northern Greece. *Remote Sensing Letters*, v. 8, n. 1, p. 96-105, 2017.

TONINI, H.; KAMINSKI, P.E.; COSTA, P. Relação da produção de sementes de castanha-do-brasil com características morfométricas da copa e índices de competição. *Pesquisa Agropecuária Brasileira*, v. 43, n. 11, p. 1509-1816, 2008.

TUOMINEN, S.; BALAZS, A.; SAARI, H.; PÖLÖNEN, I.; SARKEALA, J.; VIITALA, R. Unmanned aerial system imagery and photogrammetric canopy height data in area-based estimation of forest variables. *Silva Fennica*, v. 49, 2015.

UGCS. Leading drone control software to elevate your productivity. Disponível em: < https://www.ugcs.com/>. Acesso em: 27 de maio de 2020.

WINK, C.; MONTEIRO, J.S.; REINERT, D.J.; LIBERALESSO, E. Parâmetros da copa e a sua relação com o diâmetro e altura das árvores de eucalipto em diferentes idades, *Scientia Forestalis*, Piracicaba, 40(93): p.057-067.2012.