



**UNIVERSIDADE FEDERAL DO TOCANTINS
PRÓ-REITORIA DE PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM AGROENERGIA DIGITAL**

WELLINGTON RANGEL DOS SANTOS

**ESTIMATIVA DE ACÚMULO DE CARBONO EM MACAÚBAS A
PARTIR DE IMAGENS DE DRONE E INTELIGÊNCIA ARTIFICIAL**

**Palmas, TO
2025**

WELLINGTON RANGEL DOS SANTOS

**Estimativa de acúmulo de carbono em macaúbas a partir de imagens de
drone e inteligência artificial**

Dissertação apresentada ao Programa de Pós-Graduação
em Agroenergia Digital (PPGAD) da Universidade
Federal do Tocantins (UFT), como requisito à obtenção
do grau de Mestre em Agroenergia Digital.

Orientador (a): Dr. Erich Collicchio
Coorientador(a): Dra. Simone Palma Fávaro

**Palmas, TO
2025**

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da Universidade Federal do Tocantins

S237e Santos, Wellington Rangel dos.

Estimativa de acúmulo de carbono em macaúbas a partir de imagens de drone e inteligência artificial. / Wellington Rangel dos Santos. – Palmas, TO, 2025.

79 f.

Dissertação (Mestrado Acadêmico) - Universidade Federal do Tocantins – Câmpus Universitário de Palmas - Curso de Pós-Graduação (Mestrado) em Agroenergia, 2025.

Orientador: Erich Collicchio

Coorientadora: Simone Palma Fávaro

1. macaúba. 2. sequestro de carbono. 3. drone. 4. inteligência artificial. I. Título

CDD 333.7

TODOS OS DIREITOS RESERVADOS – A reprodução total ou parcial, de qualquer forma ou por qualquer meio deste documento é autorizado desde que citada a fonte. A violação dos direitos do autor (Lei nº 9.610/98) é crime estabelecido pelo artigo 184 do Código Penal.

Elaborado pelo sistema de geração automática de ficha catalográfica da UFT com os dados fornecidos pelo(a) autor(a).

WELLINGTON RANGEL DOS SANTOS

Estimativa de acúmulo de carbono em macaúbas a partir de imagens de drone e inteligência artificial

Dissertação apresentada ao Programa de Pós-Graduação em Agroenergia Digital (PPGAD) da Universidade Federal do Tocantins (UFT), como requisito à obtenção do grau de Mestre em Agroenergia Digital.

Orientador (a): Dr. Erich Collicchio
Coorientador(a): Dra. Simone Palma Fávaro

Data de aprovação: _____ / _____ / _____

Banca Examinadora:

Prof. Dr. Erich Collicchio, UFT

Prof. Dra. Simone Palma Fávaro, EMBRAPA

Prof. Dr. Guilherme Benko de Siqueira, UFT

Prof. Dr. Leonardo Duarte Pimentel, UFV

AGRADECIMENTOS

Agradeço, primeiramente, a Deus pela saúde, força e sabedoria durante toda essa caminhada. Ao meu orientador, Dr. Erich Collicchio, pela orientação, paciência, incentivo constante e valiosas contribuições ao longo deste trabalho.

À minha coorientadora, Dra. Simone Palma Fávaro, por sua atenção, disponibilidade e pelas sugestões fundamentais que enriqueceram significativamente esta pesquisa.

Aos professores do Programa de Pós-graduação — Guilherme Benko, Erich Collicchio, Flavia Lucila Tonani, Solange Aparecida e Horllys Barreto — pelo conhecimento compartilhado ao longo do curso.

Aos professores Sérgio Motoike e Leonardo Pimentel pelas importantes contribuições no fornecimento de dados para a realização deste trabalho.

Ao Sr. Richard Mesquita (Empresa Ventusmap) pela obtenção das imagens de drone nas áreas de Palmas – TO e ao professor Lucas de Paula Corrêdo pelas imagens de drones nas áreas de Viçosa – MG. Ao Sr. Vicente Wagner pelas imagens na área de ocorrência natural em Dois Irmãos do Tocantins e ao professor Anderson Evaristo pela disponibilidade dos dados do campo experimental.

Aos colegas e amigos de mestrado Lúcio, Tallyrand, Neliâne, Ana Lúcia pela parceria, troca de ideias e amizade ao longo dessa trajetória.

Ao Marcelo Vicente, pela amizade e por estar sempre apoiando meus projetos.

E a todos que, de alguma forma, contribuíram para a realização deste trabalho — Tony, Alexandre Cardoso, Sandro, Mailson, Lucas — meu muito obrigado!

À minha família, um especial agradecimento.

À Carla, minha esposa, por seu apoio, pelas palavras de incentivo nos momentos de incerteza.

Aos meus filhos, Olívia e Noah, por iluminarem meus dias e tornarem essa caminhada mais leve e cheia de sentido.

RESUMO

A crescente demanda por soluções sustentáveis na agroenergia e no mercado de carbono, aliada à necessidade de subsidiar políticas públicas de crédito de carbono, planejamento agrícola e iniciativas de restauração ecológica em regiões tropicais, tem impulsionado o desenvolvimento de métodos mais precisos e escaláveis para mensurar o acúmulo de carbono em culturas agrícolas. Entre essas, destaca-se a macaúba (*Acrocomia aculeata*), uma palmeira nativa com elevado potencial oleaginoso, ampla adaptabilidade e alta capacidade de sequestro de carbono, sendo considerada estratégica para a bioeconomia brasileira. No entanto, a quantificação do carbono acumulado na macaúba ainda é limitada por métodos convencionais, como análises destrutivas e equações alométricas aplicadas a dados coletados manualmente, os quais são onerosos, imprecisos e inviáveis em larga escala. Este trabalho teve como objetivo propor e validar uma metodologia não destrutiva para estimar, de forma individualizada, o acúmulo de carbono em plantas de macaúba por meio da integração entre equações alométricas com sensoriamento remoto, drones e inteligência artificial (IA). Foram realizadas coletas em quatro áreas experimentais e naturais nos estados de Tocantins e Minas Gerais. As imagens capturadas por Veículos Aéreos Não Tripulados (VANTS) foram processadas com o uso de redes neurais convolucionais (YOLOv8-Seg) para segmentar automaticamente as copas das palmeiras. A partir disso, foram extraídos o maior diâmetro da copa e a altura das plantas, utilizados como variáveis preditoras em equações alométricas previamente definidas. A acurácia das estimativas foi avaliada por meio da correlação entre os valores estimados e os medidos em campo, utilizando métricas como Erro Absoluto Médio (MAE) e coeficiente de correlação de Pearson. Os resultados demonstraram elevada correlação ($R > 0,80$) entre as estimativas computacionais e os dados de campo, tanto para o diâmetro da copa quanto para a altura das plantas, com baixos valores de MAE. A estimativa de carbono, baseada nesses parâmetros, também apresentou forte concordância com os valores reais, validando a eficácia do método proposto. Além disso, observou-se que o uso de IA reduziu significativamente o tempo de processamento e a intervenção manual, tornando o processo mais eficiente e aplicável em grandes áreas. Conclui-se que a metodologia desenvolvida representa potencial para a mensuração do carbono em sistemas agroflorestais de forma individualizada, contribuindo para a consolidação da macaúba como cultura estratégica para políticas públicas de crédito de carbono.

Palavras-chave: *Acrocomia*. Sequestro de carbono. VANT. Inteligência artificial. Equações alométricas.

ABSTRACT

The growing demand for sustainable solutions in agroenergy and the carbon market, along with the need to support public policies for carbon credit programs, agricultural planning, and ecological restoration in tropical regions, has driven the development of more accurate and scalable methods to estimate carbon accumulation in agricultural systems. Among promising crops, *Acrocomia aculeata* (macauba) stands out as a native palm with high oil yield, broad environmental adaptability, and significant carbon sequestration potential, positioning it as a strategic asset for Brazil's bioeconomy. However, traditional approaches to estimating carbon stock in macauba—often reliant on destructive sampling or manual data collection for allometric models—remain costly, labor-intensive, and impractical for large-scale application. The study aimed to develop and validate a non-destructive, individualized methodology to estimate carbon accumulation in macauba palms by integrating allometric equations with remote sensing, drone imagery, and artificial intelligence (AI). Field campaigns were carried out across four experimental and natural sites in the states of Tocantins and Minas Gerais. High-resolution aerial images obtained via Unmanned Aerial Vehicles (UAVs) were processed using convolutional neural networks (YOLOv8-Seg) to automatically segment individual palm crowns. From the segmented imagery, key dendrometric variables, crown diameter and tree height, were extracted and used as input for predefined allometric models. Model accuracy was assessed through comparisons with field data, employing Mean Absolute Error (MAE) and Pearson's correlation coefficient. The results revealed strong correlations ($R > 0.80$) for both variables, with low MAE values. Carbon estimates closely matched field measurements, confirming the reliability of the proposed approach. Additionally, the use of AI significantly reduced manual labor and processing time, enhancing overall efficiency and scalability. By enabling individual-level, non-invasive analysis, the methodology shows strong potential for improving carbon accounting in agroforestry systems and reinforces the role of macauba as a strategic crop for sustainable land management, forest inventories, and carbon credit initiatives in tropical regions.

Keywords: *Acrocomia aculeata*. Carbon estimation. UAV. Artificial intelligence. Allometric equations.

LISTA DE ILUSTRAÇÃO

Figura 1 – Palmeira <i>Acrocomia aculeata</i> (Macaúba)	19
Figura 2 – Fruto da macaúba com sua estrutura: i) epicarpo (casca); ii) mesocarpo (polpa); iii) endocarpo (encobre a amêndoas); e iv) endosperma (amêndoas)	19
Figura 3 – Ilustração das sobreposições longitudinal (b) e lateral (s) do voo	24
Figura 4 – Esquema mostrando as visões em perspectiva e ortográfica.....	25
Figura 5 – Distância de Amostragem do Solo (GSD): a) GSD com 5 cm, corresponde a uma imagem mais detalhada; b) GSD com 30 cm, define uma imagem menos detalhada	26
Figura 6 - Ilustração dos mapas de superfície (DSM) e do terreno (DTM) e obtenção do modelo CHM	27
Figura 7 – Diagrama mostrando a relação entre a Inteligência Artificial, Aprendizado de Máquina e Aprendizagem Profunda.....	29
Figura 8 – Aprendizado de Máquina Supervisionado.....	30
Figura 9 – Aprendizado de Máquina Não-Supervisionado	30
Figura 10 – Aprendizado de Máquina por Reforço	31
Figura 11 – Comparação conceitual entre neurônio biológico e digital	31
Figura 12 – Redes neurais artificiais e algumas das principais arquiteturas.	32
Figura 13 – Camadas convolucionais de uma rede neural artificial.....	33
Figura 14 – Áreas com cultivo de macaúba em Palmas – TO.....	41
Figura 15 – Área experimental em Unaí – MG	42
Figura 16 – Área experimental em Viçosa – MG.....	43
Figura 17 – Área de ocorrência natural em Dois Irmãos do Tocantins – TO	44
Figura 18 – Ferramenta para identificação individual das macaúbas	46
Figura 19 – Processo de treinamento do modelo de IA para segmentação das palmeiras de macaúba	47
Figura 20 – Interface do software Roboflow exemplificando a anotação dos dados de treinamento do modelo.....	49
Figura 21 – Ilustração do processo de segmentação da copa. a) resultado do modelo de IA; b) máscara extraída e c) cálculo do maior diâmetro.....	51
Figura 22 – Processo de estimativa da altura das palmeiras a partir de imagens	52
Figura 23 – Processo de estimativa de carbono por imagens aéreas	54
Figura 24 – Exemplos do resultado da segmentação das copas de macaúba, a partir do uso do modelo YOLO	56
Figura 25 – Análises descritiva para o diâmetro da copa: a) Correção entre diâmetro real e estimado; b) Comparação entre diâmetro real e estimado; c) Erro absoluto médio (MAE)	59
Figura 26 – Análises descritiva para a altura da macaúba. a) Correção entre altura real e estimada; b) Comparação entre altura real e estimada; c) Erro absoluto médio (MAE) .	61
Figura 27 – Análises descritivas para a acúmulo de carbono (AC) por diâmetro de copa. a) Correlação entre AC e diâmetro no campo; b) Correlação entre AC e diâmetro estimado; e c) Correlação entre AC no campo e estimado.....	63
Figura 28 – Percentis de carbono acumulado em palmeira macaúba utilizando visão computacional a partir do diâmetro da copa e por área, utilizando simulações Monte Carlo	64
Figura 29 – Análises descritivas acúmulo de carbono (AC) determinado pela altura das palmeiras. a) Correlação entre altura real e AC; b) Correlação entre altura estimada e AC; c) Correlação entre AC real e estimado com base na altura da planta.....	66

Figura 30 – Percentis de carbono acumulado a partir da altura e por área usando simulações Monte Carlo	67
Figura 31 – Comparação entre acúmulo de carbono em macaúba por altura e diâmetro da copa por área, obtidos por ferramentas computacionais.....	69
Figura 32 – Comparação da média por planta de carbono acumulado em plantas de macaúba por idade, obtido por imagens de drones e ferramentas computacionais	70

LISTA DE ABREVIATURAS E SIGLAS

AC	Acúmulo de Carbono
AI / IA	Inteligência Artificial
ARVI	Índice de Vegetação Resistente à Atmosfera (Atmospherically Resistant Vegetation Index)
CHM	Modelo de Altura da Copa (Canopy Height Model)
CNN	Rede Neural Convolucional (Convolutional Neural Network)
DTM	Modelo Digital de Terreno (Digital Terrain Model)
DSM	Modelo Digital de Superfície (Digital Surface Model)
GCP	Ponto de Controle no Solo (Ground Control Point)
GSD	Distância de Amostragem do Solo (Ground Sample Distance)
LiDAR	Light Detection and Ranging
MAE	Erro Absoluto Médio (Mean Absolute Error)
NDVI	Índice de Vegetação por Diferença Normalizada (Normalized Difference Vegetation Index)
PRI	Índice de Refletância Fotoquímica (Photochemical Reflectance Index)
RGB	Canais Vermelho, Verde e Azul (Red, Green, Blue)
RNA	Rede Neural Artificial
RTK	Cinemática em Tempo Real (Real-Time Kinematic)
SAVI	Soil-Adjusted Vegetation Index (Índice de Vegetação Ajustado ao Solo)
SR	Sensoriamento Remoto
VANT	Veículo Aéreo Não Tripulado
YOLO	You Only Look Once

LISTA DE TABELAS

Tabela 1 – Modelos de VANT e dados do voo, utilizados por área de estudo	44
Tabela 2 – Resultados do diâmetro da copa de plantas de macaúba, medido em campo e o estimado (em metros), em Unaí - MG.....	58
Tabela 3 – Resultados das alturas de plantas de macaúba, medidas no campo e o estimado (em metros), em Unaí – MG.....	60
Tabela 4 – Acúmulo de carbono em palmeira macaúba obtido pelo diâmetro da copa definido por segmentação de imagem coletada por drone e simulado por Monte Carlo.....	65
Tabela 5 – Acúmulo de carbono em palmeira macaúba estimada pela altura da planta obtida por ferramentas computacionais e simulado por Monte Carlo	68

SUMÁRIO

1	INTRODUÇÃO	15
1.1	<i>Objetivos.....</i>	17
1.1.1	Objetivo Geral	17
1.1.2	Objetivos Específicos	17
2	REVISÃO BIBLIOGRÁFICA	18
2.1	<i>Aspectos gerais e importância da macaúba (<i>Acrocomia spp</i>).....</i>	18
2.2	<i>Sensoriamento remoto</i>	22
2.2.1	Veículos aéreos não tripulados (VANT).....	23
2.2.2	Sobreposição entre imagens	23
2.2.3	Ortofoto	24
2.2.4	Distância de Amostragem no Solo (<i>Ground Sample Distance</i>)	25
2.2.5	Modelos digitais de elevação	26
2.3	<i>Visão Computacional.....</i>	27
2.3.1	Objetivo Geral	28
2.4	<i>Inteligência Artificial (IA)</i>	28
2.4.1	Aprendizado de máquina (<i>Machine learning</i>)	29
2.4.2	Aprendizado profundo de máquina (<i>Deep learning</i>)	31
2.4.3	Redes neurais convolucionais (CNN)	32
2.4.4	YOLO	34
2.5	<i>Sensoriamento remoto e IA na estimativa de carbono.....</i>	35
3	METODOLOGIA.....	41
3.1	<i>Áreas de estudo.....</i>	41
3.2	<i>Obtenção das imagens por VANT.....</i>	44
3.3	<i>Pré-processamento das imagens</i>	45
3.4	<i>Cálculo do diâmetro das copas das palmeiras</i>	46
3.4.1	Segmentação das copas usando inteligência artificial	46
3.4.2	Criação do <i>dataset</i> de imagens	47
3.4.3	Anotação das imagens para o treinamento do modelo.....	48
3.4.4	Pré-processamento e aumento de dados	49
3.4.5	Treinamento do modelo computacional.....	50
3.4.6	Análise de desempenho do modelo computacional.....	50
3.4.7	Geração das máscaras e cálculo do maior diâmetro das copas das palmeiras	51
3.4.8	Análise estatística	52
3.5	<i>Estimativa da altura das palmeiras.....</i>	52
3.5.1	Análise estatística	53
3.6	<i>Estimativa de Acúmulo de Carbono.....</i>	53
3.6.1	Análise estatística	54
4	RESULTADOS E DISCUSSÃO	56
4.1	<i>Segmentação das copas das palmeiras com o uso de IA</i>	56
4.2	<i>Estimativa do diâmetro da copa das plantas de macaúbas.....</i>	57
4.3	<i>Estimativa da altura das palmeiras de macaúba</i>	60
4.4	<i>Estimativa de acúmulo de carbono em plantas de macaúba.....</i>	62

4.4.1	Estimativa de acúmulo de carbono a partir do diâmetro da copa.....	62
4.4.2	Estimativa de acúmulo de carbono a partir da altura da palmeira.....	65
4.5	<i>Comparação entre o acúmulo de carbono pelo diâmetro da copa e altura da palmeira macaúba ...</i>	68
5	CONCLUSÃO	72
	REFERÊNCIAS	73

1 INTRODUÇÃO

A macaúba é uma palmeira nativa presente em toda a América Tropical e Subtropical. No Brasil, ocorre na Mata Atlântica, na Amazônia, no Cerrado, no Pantanal e em algumas regiões do Nordeste. É considerada uma palmeira com alto grau de adaptação a diferentes aspectos climáticos e condições do solo (CROCOMO; MELO, 1996). Sua aplicação é ampla, abrangendo desde o fornecimento de alimentos e rações até a produção de biocombustíveis líquidos e sólidos (CARRERA, 2010; VARGAS-CARPINTERO et al., 2021; SANTOS; COLLICCHIO; SIQUEIRA, 2024). Possui alto rendimento na produção de óleo e pode ser uma alternativa viável para regiões onde a presença do dendê (*Elaeis guinensis*) seja impeditiva. A grande amplitude de ocorrência natural é uma importante característica para a implementação de cultivos organizados, inclusive por suportar maiores restrições hídricas, poderá ser produzida em regiões marginais, como algumas áreas da região Nordeste do Brasil (CARDOSO et al., 2017; COLOMBO et al., 2018; CARDOSO et al., 2020). Outra contribuição importante está relacionada à recuperação ou manutenção de áreas de conservação, associada a ações de sequestro de carbono (FÁVARO; ROCHA, 2022). A macaúba apresenta um alto potencial de acumulação de carbono, o que pode viabilizar oportunidades para a negociação de créditos de carbono no mercado internacional (MOREIRA, 2019), superando inclusive áreas de pastagem e vegetação nativa do Cerrado (MOREIRA et al., 2024). No entanto, apesar de sua importância, a estimativa de carbono em macaúba ainda enfrenta desafios significativos.

Os métodos convencionais para a estimativa de carbono, que frequentemente demandam o abate de plantas e análises laboratoriais demoradas, são inviáveis para aplicações em larga escala. O uso de equações alométricas, que relacionam variáveis facilmente mensuráveis, como o diâmetro do tronco ou a altura da árvore, com a biomassa, simplifica o processo de estimativa de carbono, eliminando a necessidade de abate de plantas para análises laboratoriais (FERREIRA et al., 2013; MOREIRA, 2019). Entretanto, ainda tem limitações como poder oferecer medidas com base em amostragens, consumir bastante tempo e mão de obra para a coleta de dados a campo numa escala comercial de produção ou mesmo em maciços naturais. Além disso, tem imprecisões associados às medições manuais de altura e diâmetro de copa com o crescimento das palmeiras, tornando-se mais desafiadora devido a fatores como erros de instrumentos, variação entre operadores, condições ambientais adversas e inabilidade em larga escala, reforçando a importância de tecnologias avançadas para maior

precisão e eficiência. Diante das limitações dos métodos tradicionais, a busca por alternativas mais eficientes e menos invasivas tem impulsionado o uso de tecnologias avançadas como o Sensoriamento Remoto (SR), Veículos Aéreos Não Tripulados (VANTs), popularmente conhecidos como drones, e a Inteligência Artificial (IA).

Estudos recentes demonstram a eficácia do uso combinado dessas tecnologias em diferentes tipos de vegetação para estimativa de acúmulo de carbono. Stangarlin, (2023), por exemplo, utilizou Redes Neurais Artificiais (RNA) para estimar o CO₂ equivalente em sistemas agroflorestais silvibananeiros, integrando dados de sensoriamento remoto e equações alométricas. Oliveira, (2023) aplicou métodos de sensoriamento remoto em florestas regeneradas, destacando a importância da tecnologia no monitoramento de áreas em recuperação. Em plantações comerciais, Dahy et al., (2023) analisaram tamareiras no Emirado de Abu Dhabi, empregando imagens de satélite e modelos alométricos para mapear o estoque de carbono em diferentes estágios de desenvolvimento.

No entanto, apesar de tais avanços, ainda há uma lacuna na literatura quanto à aplicação dessas tecnologias na estimativa de carbono em culturas específicas, como a macaúba. Diante disso, o presente trabalho propõe uma abordagem para a estimativa individualizada de carbono em macaúbas, combinando equações alométricas e imagens capturadas por drones. Essa tecnologia é uma ferramenta para o avanço do potencial de exploração econômica em bases sustentáveis da macaúba a qual é um ativo de grande relevância para a bioeconomia brasileira.

1.1 Objetivos

1.1.1 Objetivo Geral

Avaliar o uso de sensoriamento remoto e inteligência artificial para variáveis dendrométricas da macaúba e estimar o acúmulo de carbono por meio de equações alométricas.

1.1.2 Objetivos Específicos

1. Capturar as imagens aéreas de VANTs das áreas de estudo;
2. Desenvolver programa de computador para realizar o pré-processamento das imagens;
3. Segmentar a copa usando modelo de inteligência artificial;
4. Desenvolver método computacional para estimar o diâmetro das copas de macaúba;
5. Desenvolver método computacional para estimar a altura das palmeiras macaúba;
6. Aplicar equações alométricas para estimativa de carbono pelo diâmetro da copa e altura da planta obtidos por método computacional.

2 REVISÃO BIBLIOGRÁFICA

Neste estudo, foram aplicados conhecimentos das áreas de processamento de imagens e aprendizado de máquina para interpretar dados obtidos por meio de imagens capturadas por Veículos Aéreos Não Tripulados (VANTs). Inicialmente, serão apresentadas as características da palmeira macaúba e sua importância no contexto acúmulo do carbono. Em seguida, descrevem-se as tecnologias utilizadas no desenvolvimento deste trabalho. Por fim, será realizada uma revisão dos estudos disponíveis na literatura que abordam a estimativa do acúmulo de carbono em outras espécies com base em imagens aéreas, utilizando visão computacional e inteligência artificial.

2.1 Aspectos gerais e importância da macaúba (*Acrocomia spp*)

As palmeiras do gênero *Acrocomia* são encontradas em toda América do Sul e Central (CROCOMO; MELO, 1996). As principais espécies de interesse econômico são a *Acrocomia aculeata* (predominante no Brasil Central em áreas de Cerrado), *A. totai* (maior ocorrência no Pantanal e oeste de São Paulo, Paraná e leste de Mato Grosso do Sul) e *A. intumescens* (espontânea de certas regiões no Nordeste brasileiro). No Brasil, desempenham um papel fundamental na rica biodiversidade brasileira, uma vez que conta com uma grande diversidade de espécies de palmeiras com importância econômica, cultural e ambiental. A macaúba pode ser encontrada em diferentes biomas, como a Floresta Amazônica, o Cerrado, a Mata Atlântica, o Pantanal e a Caatinga. A depender da região, pode receber diversas denominações, como coco-baboso no sudeste do Brasil, macaíba na região norte (CROCOMO; MELO, 1996) e bocaiuva na região central (CARDOSO et al., 2020). Outros nomes também podem ser encontrados na literatura, como macaúva, mucaja, mucuja, macajuba, coco-de-catarro, chiclete-de-baiano (CARVALHO, 2008). A macaúba é uma palmeira perene que pode atingir de 4 a 15 m de altura e apresentar de 20 a 40 folhas concentradas no alto da planta (Figura 1) (COLOMBO et al., 2018). Seu caule, também conhecido como estipe, tem um diâmetro médio que varia de 30 a 45 cm e pode conter espinhos longos e pontiagudos (CARVALHO; SOUZA; MACHADO, 2011). Os frutos da macaúba são do tipo drupa e contém polpa e amêndoas oleaginosas comestíveis, medindo entre 3,5 a 5,0 cm de diâmetro e com casca de cor marrom-amarelada quando maduros (COSTA, 2009).

Figura 1 – Palmeira *Acrocomia aculeata* (Macaúba)



Fonte: Próprio autor (2025)

A partir da macaúba, podem ser obtidos diversos produtos, tais como alimentos (farinha e nozes), rações (frutas trituradas, tortas e folhas), biocombustíveis líquidos (óleo do mesocarpo e da amêndoas), biocombustíveis sólidos (endocarpo) (Figura 2) (CROCOMO; MELO, 1996; CARRERA, 2010; VARGAS-CARPINTERO et al., 2021).

Figura 2 – Fruto da macaúba com sua estrutura: i) epicarpo (casca); ii) mesocarpo (polpa); iii) endocarpo (encobre a amêndoas); e iv) endosperma (amêndoas)



Fonte: Elaborado pelo autor (2025)

A partir de processos específicos, os óleos são convertidos a biocombustíveis, como o biodiesel e bioquerosene de aviação (combustível de aviação sustentável), que podem ser misturados aos combustíveis fósseis tradicionais (FÁVARO; ROCHA, 2022). Santos et al.

(2024) reforçam o grande potencial da macaúba para a produção de biocombustíveis, destacando sua adaptabilidade ecológica e a alta produtividade de óleo, especialmente em áreas de vegetação nativa. Essa versatilidade da planta é um ponto-chave para sua utilização em diferentes tipos de solo, clima e uso da terra, como demonstrado no estudo realizado na região central do Tocantins, onde foi evidenciada a capacidade da macaúba de se adaptar tanto a áreas de Cerrado quanto a pastagens extensivas.

Do ponto de vista de consumo como alimento, tanto o óleo da polpa como de amêndoas, apresentam propriedades nutricionais e funcionais bastante desejáveis, sendo sucedâneos do óleo de palma e de palmiste (PLATH et al., 2016; FÁVARO; ROCHA, 2022). No Brasil, a estimativa de produtividade dos óleos de macaúba varia bastante, indo de 2,5 toneladas por hectare/ano até, em cenários otimistas, podendo chegar a 5 t/ha/ano (COLOMBO et al., 2018) ou 6 t/ha/ano (MOTOIKE et al., 2013; NAVARRO-DÍAZ et al., 2014).

A macaúba é valorizada como um grande potencial como cultura oleaginosa por diversas razões. Uma delas é que seu cultivo pode abranger vasta extensão do território nacional, incluindo locais com restrições hídricas (MOTOIKE, 2013; COLOMBO et al., 2018; CARDOSO et al., 2020), oferecendo uma alternativa competitiva em regiões inaptas ao dendê (palma de óleo) por insuficiência hídrica e baixas temperaturas. Ressaltando essa capacidade de adaptação a diversos ambientes, em fevereiro de 2024 foi publicado o primeiro Zoneamento Agrícola de Risco Climático (ZARC) para a macaúba, visando identificar as regiões mais favoráveis ao cultivo, reduzir riscos climáticos e apoiar políticas de crédito e seguro rural (EMBRAPA, 2024). Outro aspecto muito importante é o seu potencial de recuperação de pastagens degradadas – especialmente quando integradas a lavouras e/ou pecuária em sistemas agroflorestais (MOTOIKE et al., 2013). Ademais, essa espécie se destaca também devido à sua alta capacidade de sequestrar e estocar carbono em sua biomassa, tanto acima quanto abaixo do solo. Em consonância com essas vantagens, o interesse no cultivo da macaúba para a geração de créditos de carbono tem ganhado destaque, impulsionado por acordos internacionais voltados à mitigação dos efeitos das mudanças climáticas (MOREIRA, 2019). Estudos como os de Toledo (2010), Ferreira et al. (2013) e Moreira et al. (2024), têm apontado para o elevado potencial da macaúba no sequestro e estoque de carbono. Moreira et al. (2024) demonstraram que o estoque de carbono em cultivos de macaúba pode superar o encontrado em áreas de pastagem e vegetação nativa de

Cerrado, especialmente em cultivos comerciais com manejo otimizado de solo e plantas. O autor estimou um ganho de estoque de carbono, considerando o intervalo entre os cultivos de macaúba de 4,8 e 9 anos, de $75,36 \text{ MgC.ha}^{-1}$. Em contrapartida, Toledo, (2010) relatou um estoque médio de $33,851 \text{ MgC.ha}^{-1}$ em áreas de regeneração natural de macaúba. Complementando esses resultados, o projeto INOCAS (Innovative Oil and Carbon Solutions), conduzido pelo IMAFLORA (2020), destacou que a maioria das compensações de emissões de gases de efeito estufa (GEE) em seus experimentos provém do sequestro de carbono na biomassa de macaúba, com um potencial de reduzir as emissões em uma taxa de 20,75 t $\text{CO}_2/\text{ha/ano}$, equivalendo ao estoque de carbono de 5,65 t C/ha/ano.

É importante ressaltar que a quantificação com maior precisão do potencial de sequestro de carbono da macaúba requer a utilização de metodologias adequadas e a consideração de fatores específicos da espécie. O uso de valores *default* do IPCC (Painel Intergovernamental sobre Mudanças Climáticas) pode levar à superestimativa do estoque de carbono (FERREIRA et al., 2013), enquanto a análise da concentração de carbono por seção da planta (raiz, caule, folhas etc.) garante maior precisão nos cálculos (MOREIRA, 2019). Entretanto, o método direto de estimativa do carbono em macaúba exige o abate das plantas para a coleta de amostras de diferentes partes da macaúba (FERREIRA, 2013; MOREIRA, 2019). Esse processo, por si só, já demanda altos investimentos de mão de obra, de tempo e de recursos financeiros. Além do abate em si, o processo de preparo de amostra (secagem das amostras em estufa, a moagem e a posterior calcinação em mufla) e de análises químicas, acrescentam etapas adicionais ao processo, tornando-o ainda mais demorado e dispendioso. Moreira (2019) sugere a exploração de métodos alternativos para estimar a biomassa e o carbono de forma mais eficiente e com menos impacto, especialmente em estudos de larga escala. Entre esses métodos, destaca-se o uso de equações alométricas, que são definidas por Brianezi et al. (2013) como: "Um modelo alométrico é uma relação empírica entre a variável de interesse (neste caso, o estoque de carbono) e as variáveis facilmente mensuráveis..." (BRIANEZI et al., 2013). No campo, medições manuais como da altura e diâmetro de copa tornam-se desafiadoras à medida que as palmeiras crescem, não apenas pela dificuldade física, mas também pelo risco de erros associados aos instrumentos utilizados, à variabilidade entre operadores e à dificuldade de aplicação em larga escala. Além disso, fatores como condições ambientais adversas, como vento ou terreno irregular, podem comprometer a precisão das medições, assim como erros de registro e interpretação dos dados. Para

minimizar os erros inerentes às medições realizadas manualmente no campo, o uso de tecnologias avançadas tem se mostrado essencial. Sobre isso, Moreira (2019) observa:

A determinação do diâmetro de copa, apesar de ser de fácil mensuração no campo com o uso de uma trena, pode apresentar erros no momento das medições, porém devemos considerar outras formas de mensuração dessa variável, como a utilização de técnicas de sensoriamento remoto e o uso de drones, técnicas que podem agilizar o processo de medição e ser mais confiáveis (Moreira, 2019).

Dessa forma, torna-se evidente que a estimativa do acúmulo de carbono pode ser aprimorada por meio de métodos alternativos aos tradicionais, que fazem uso de tecnologias avançadas para oferecer maior eficiência e precisão nos resultados. Nas próximas seções, estão apresentadas as definições de sensoriamento remoto, veículos aéreos não tripulados e inteligência artificial, destacando suas aplicações no acúmulo de carbono.

2.2 Sensoriamento remoto

O sensoriamento remoto (SR) é o campo de estudo que envolve a obtenção de dados sobre a superfície terrestre sem a necessidade de contato direto. Esta tecnologia é caracterizada pelo uso de sensores e dispositivos localizados em plataformas como satélites, aviões, Veículos Aéreos Não Tripulados (VANTS) ou estações terrestres (MOREIRA, 2001; MORAES, 2002). A energia eletromagnética é refletida e emitida pelos objetos terrestres nas formas de: i) radiação ultravioleta; ii) radiação infravermelha; iii) raios-X; iv) ondas de rádio; e v) micro-ondas (FERNANDO et al., 2014).

O SR fornece dados e informações das características físicas, químicas, biológicas e geológicas dos objetos ou áreas em estudo que seriam difíceis ou impossíveis de ser acessados de forma convencional. A técnica possui várias aplicações, desde cartografia, agricultura, previsão de desastres naturais e estudos climáticos (MORAES, 2002). Esse sensoriamento mais versátil, com coletas de dados mesmo em áreas de difícil acesso, imagens em alta resolução e em tempo real se tornou mais recorrente, em boa parte, devido à popularização dos VANTS.

2.2.1 Veículos aéreos não tripulados (VANT)

Os VANTs - conhecidos popularmente como drones - possuem uma longa trajetória de desenvolvimento até se tornarem uma ferramenta de uso comum na agricultura moderna. Os primeiros protótipos de aeronaves remotamente controladas foram desenvolvidos durante a Primeira e Segunda Guerra Mundial. Esses veículos eram usados principalmente para fins militares, como alvos aéreos (GONZÁLEZ-JORGE et al., 2017). Somente em 1995, durante o período da Guerra Fria, o primeiro drone com a finalidade de captura de imagens foi produzido. No Brasil, na década de 80, os primeiros projetos com VANTs foram iniciados. O Centro Tecnológico Aeroespacial (CTA) desenvolveu o projeto Acauã para fins militares e o projeto Helix para a área civil (CASTRO JORGE; INAMASU, 2014). A partir de 2010 a popularização dos VANTs para uso recreativo e comercial impulsionou a disponibilidade dessas aeronaves. A integração de câmeras de alta resolução e sistemas de estabilização permitiu a captura de imagens e vídeos de qualidade.

Atualmente, os VANTs desempenham um papel crucial na agricultura. Vem sendo adotado como ferramenta de aquisição de dados de sensoriamento remoto devido a sua alta resolução espacial quando comparados a satélite (JENSEN, 2009). Sua capacidade de sobrevoar áreas agrícolas de maneira rápida e eficiente permitiu o monitoramento de cultivos, detecção de doenças e pragas, análise do vigor das plantas e mapeamento de áreas cultivadas. Quando equipados com sensores de imagem e espectroscopia, podem fornecer informações detalhadas sobre a saúde das plantas, o estado do solo e as condições ambientais (MOREIRA, 2001). Esses dados são usados para otimizar o uso de recursos, como água e fertilizantes, maximizando a produtividade das colheitas e reduzindo os impactos ambientais.

De forma resumida, Castro; Inamasu (2014) apresentaram etapas do uso de VANTs na agricultura, como: i) planejamento de voo; ii) voo com sobreposição; iii) obtenção das imagens georreferenciadas; iv) processamento das imagens; v) geração de mosaico; vi) análises; e vi) geração de relatórios. A seguir, serão apresentados conceitos relativos às etapas de obtenção e processamento das imagens. Essas etapas são importantes para a viabilidade das análises de reconhecimento de padrões usando modelos computacionais.

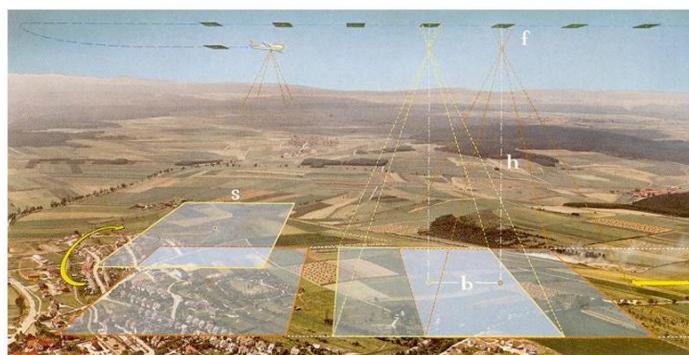
2.2.2 Sobreposição entre imagens

A estratégia de captura das imagens durante o voo deve ser cuidadosamente planejada, levando em consideração vários fatores como a área a ser mapeada, a altitude de voo, a

velocidade da aeronave, a resolução da câmera e a sobreposição desejada entre as imagens. A sobreposição é fundamental para garantir que não haja perdas nas imagens capturadas (Figura 3). Essa consideração é particularmente importante quando as imagens são processadas para criar mosaicos ou modelos em grandes áreas.

Existem dois tipos de sobreposição que são expressos em percentagem: Sobreposição Longitudinal (*Forward Overlap*) que ocorre na direção do voo, com valores indicados de entre 60% e 90% e Sobreposição Lateral (*Side Overlap*) que ocorre lateralmente, com percentagens sugeridas variando entre 20% e 60% (REDWEIK, 2007).

Figura 3 – Ilustração das sobreposições longitudinal (b) e lateral (s) do voo



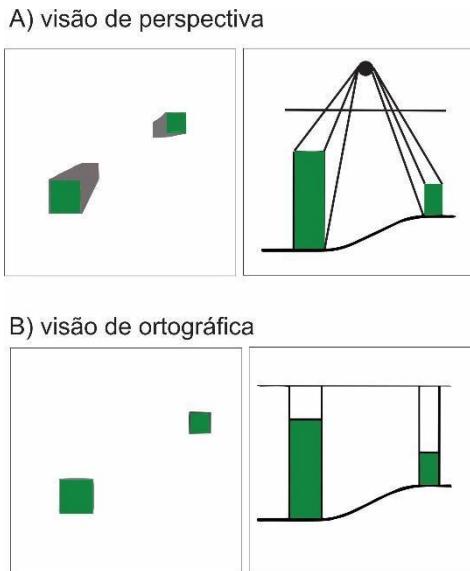
Fonte: (Redweik, 2007)

2.2.3 Ortofoto

As imagens obtidas pelas câmeras em VANTs encontram-se em uma visão de perspectiva, na qual os raios de luz refletidos passam por um único ponto central do capturador óptico da câmera (Figura 4A) (NÓBREGA; MOURA, 2013). Essa perspectiva é influenciada por diversos fatores, incluindo a altitude de voo, a inclinação da câmera e o relevo do solo (GEOSENSORI, 2019). Para aplicações que exigem uma representação precisa e sem distorções, é essencial realizar a correção dessas imperfeições, o que pode ser alcançado por meio de técnicas de correção geométrica, como a geração de ortofotos. Uma ortofoto é uma imagem georreferenciada e retificada que reproduz a superfície terrestre com uma perspectiva ortogonal (Figura 4B), ou seja, sem as distorções causadas pela inclinação e relevo do terreno. De acordo com Idoeta (2007), uma ortofoto é uma imagem aérea corrigida geometricamente que representa os objetos na sua posição real sobre a superfície terrestre, como se estivesse sendo visualizada de cima, sem distorções causadas pelo relevo ou pela

inclinação da câmera. A criação de uma ortofoto envolve o uso de algoritmos computacionais embarcados em softwares especializados em fotogrametria, como o Agisoft Metashape (AGISOFT, 2019), Pix4Dmapper (PIX4D, 2024), DroneDeploy (DRONEDEPLOY, 2025) e (OPENDRONEMAP, 2025). O resultado é uma imagem que se assemelha a uma fotografia aérea tirada de uma posição vertical acima do terreno, permitindo medições precisas de distâncias, áreas e ângulos.

Figura 4 – Esquema mostrando as visões em perspectiva e ortográfica



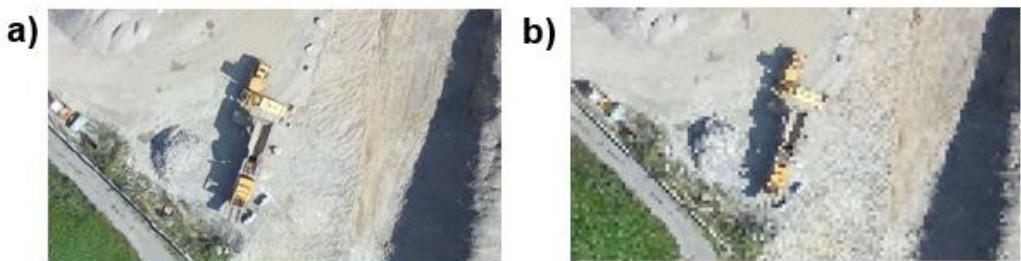
Fonte: Elaborado pelo autor (2025)

2.2.4 Distância de Amostragem no Solo (*Ground Sample Distance*)

A Distância de Amostragem do Solo, conhecida pela sigla GSD (do inglês *Ground Sample Distance*), é uma medida que indica a distância física no terreno representada por um único *pixel* em uma imagem aérea ou obtida por sensoriamento remoto (DRAEYER; STRECHA, 2014; PENG et al., 2019). O GSD é a resolução espacial real da imagem, expressa em unidades de comprimento por pixel e determina o tamanho mínimo de um detalhe que pode ser identificado na imagem. A título de ilustração, quando se fala de uma imagem com 10 cm de GSD, significa que cada *pixel* na imagem equivale a 10 cm de distância no solo. A relação entre o valor do GSD e qualidade da imagem é direta: quanto menor o valor do GSD, maior é a resolução da imagem. Isso resulta em imagens mais nítidas

e precisas, nas quais objetos pequenos e características sutis podem ser identificados e analisados com maior clareza (Figura 5).

Figura 5 – Distância de Amostragem do Solo (GSD): a) GSD com 5 cm, corresponde a uma imagem mais detalhada; b) GSD com 30 cm, define uma imagem menos detalhada



Fonte: (Singh, 2019)

A faixa geralmente recomendada para a obtenção de variáveis dendrométricas de palmeiras um valor de GSD entre 2 a 20 centímetros por pixel, pois nesse intervalo é possível capturar detalhes distintivos das copas das palmeiras. Para o cálculo do GSD utiliza-se a equação abaixo, com os seguintes parâmetros (PENG et al., 2019):

$$GSD = \frac{(hg * b)}{f}$$

Onde:

b – tamanho do pixel do sensor

f – distância focal

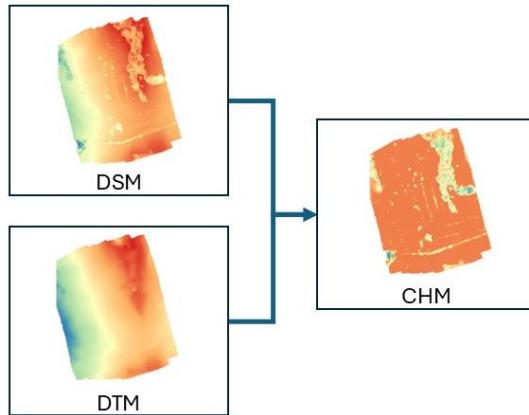
hg – altura acima do nível do solo

2.2.5 Modelos digitais de elevação

Os Modelos Digitais de Terreno (DTM), Modelos Digitais de Superfície (DSM) e ortofotos são ferramentas essenciais em geoprocessamento e sensoriamento remoto e representam a elevação da superfície terrestre. O DTM representa a elevação da superfície terrestre e, geralmente, é usado para análises que requerem uma representação precisa do terreno "nu" (GUTH et al., 2021). O DSM, por outro lado, inclui todas as estruturas verticais da superfície terrestre, como edifícios, árvores, dentre outras. Ou seja, o DSM representa a elevação da superfície que inclui tanto o solo quanto os objetos que estão sobre ele (GUTH et

al., 2021). No contexto de estudos com árvores, um terceiro modelo importante é o que representa a altura da copa em relação ao solo, na sigla em inglês CHM (*Canopy Height Model*) o qual é obtido a partir da diferença entre os mapas DSM e DTM (Figura 6) (NASIRI et al., 2021).

Figura 6 - Ilustração dos mapas de superfície (DSM) e do terreno (DTM) e obtenção do modelo CHM



Fonte: Elaborado pelo autor (2025)

2.3 Visão Computacional

A visão computacional é um campo da inteligência artificial e da ciência da computação que visa capacitar os sistemas de computadores a interpretarem e compreenderem o conteúdo visual, como imagens e vídeos, de forma similar ao modo como os seres humanos o fazem (BALLARD; BROWN, 1982; FORSYTH; PONCE, 2002). O objetivo da visão computacional é tomar decisões úteis a respeito de objetos e cenários do mundo físico, fundamentadas na análise das imagens identificadas (SHAPIRO; STOCKMAN, 2001). Para isso, é necessário extraír informações utilizando vários tipos de estruturas de dados, incluindo matrizes de *pixels*, representações geométricas e gráficos (ROSENFELD, 1988). A visão computacional tem várias aplicações como processamento de documentos, sensoriamento remoto, radiologia, microscopia, inspeção industrial e orientação de robôs. Envolve o desenvolvimento de algoritmos e técnicas para a extração, análise e interpretação de informações visuais a partir de dados capturados por câmeras. Dentre essas técnicas, os algoritmos de inteligência artificial, principalmente aqueles que utilizam redes neurais em suas arquiteturas, são os mais amplamente usados.

2.3.1 Objetivo Geral

Avaliar o uso de sensoriamento remoto e inteligência artificial para variáveis dendrométricas da macaúba e estimar o acúmulo de carbono por meio de equações alométricas.

2.4 Inteligência Artificial (IA)

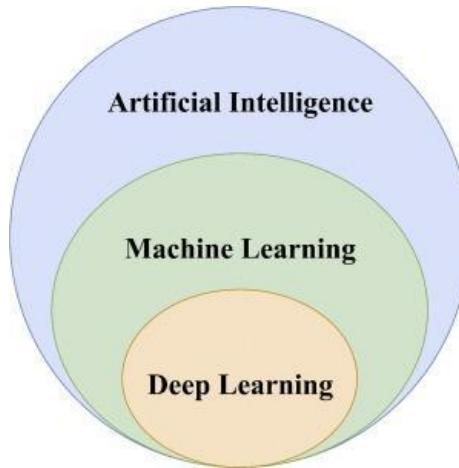
A inteligência artificial (IA) é um campo multidisciplinar da ciência da computação que se concentra no desenvolvimento de sistemas, máquinas e programas de computador capazes de realizar tarefas que normalmente requerem inteligência humana. Para Russell e Norvig (2010), com IA, tenta-se não apenas entender, mas também construir entidades inteligentes. Essas tarefas englobam o reconhecimento de padrões, tomada de decisões, aprendizado, resolução de problemas e interação com humanos de maneira natural.

A história da IA é marcada por inúmeros avanços, ideias e momentos-chave que moldaram o desenvolvimento desse campo multidisciplinar. Em 1950, Alan Turing introduziu o conceito do "Teste de Turing" como uma maneira de avaliar a inteligência de máquinas. Na década de 1960, surgiram os primeiros programas de jogos de tabuleiro e pesquisas em linguagem natural para tradução automática (RUSSELL; NORVIG, 2010). Nos anos de 1974 e 1980, ocorreu o que ficou conhecido como “inverno da IA”, um período com poucos avanços, de desaceleração no financiamento e sem muitas inovações para a área. O ressurgimento da IA veio em seguida, a partir do final dos anos 80. O projeto *Deep Blue* da IBM se destacou vencendo o maior jogador de xadrez até então, Garry Kasparov, em uma partida oficial.

A partir anos 2000, com o crescimento exponencial dos dados da internet, redes sociais, dispositivos móveis e sensores em conjunto com o aumento do poder computacional das máquinas, principalmente, o uso de processadores gráficos (geralmente abreviados como GPU, do inglês *Graphics Processing Unit*, que são componentes de hardware projetados especificamente para processar tarefas relacionadas a gráficos e imagens. Contudo, tornaram vitais para tarefas de aprendizado profundo de máquina, acelerando o treinamento de redes neurais profundas devido à sua capacidade de paralelismo, permitiram o treinamento de modelos complexos. Esses dois fenômenos popularizaram o aprendizado de máquina e o

aprendizado profundo de máquina, que serão apresentados a seguir como subáreas da Inteligência Artificial (Figura 7) (MUTHUKRISHNAN et al., 2020).

Figura 7 – Diagrama mostrando a relação entre a Inteligência Artificial, Aprendizado de Máquina e Aprendizagem Profunda



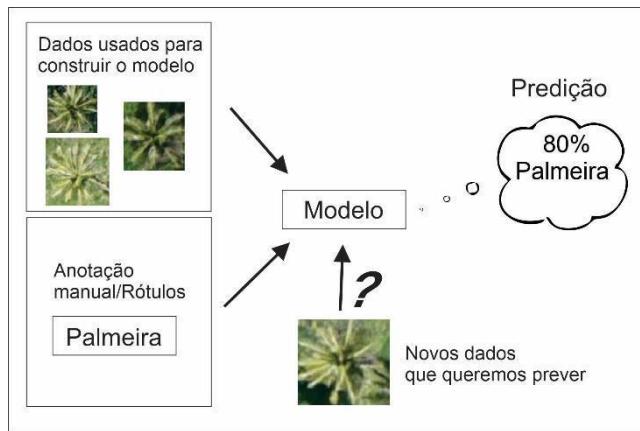
Fonte: Elaborado pelo autor (2023)

2.4.1 Aprendizado de máquina (*Machine learning*)

O aprendizado de máquina é um subcampo da inteligência artificial (IA) que se concentra no desenvolvimento de algoritmos e modelos para que as máquinas possam "aprender" a partir de dados. Em vez de serem explicitamente programadas para realizar tarefas específicas, os modelos de aprendizado de máquina podem descobrir padrões e regras a partir de exemplos e dados, permitindo a automação de tarefas complexas (MONARD; BARANAUSKAS, 2003; IZBICKI; SANTOS, 2020; MUTHUKRISHNAN et al., 2020). Segundo Russell e Norvig (2010), há três tipos principais de aprendizado de máquina: a) Supervisionado; b) Não supervisionado e c) por Reforço.

- a) Aprendizado supervisionado: neste método, o modelo é treinado com pares de entrada-saída para aprender a mapear entradas para saídas orientadas por um "instrutor" humano. Para ilustrar seu funcionamento básico, imagens de plantas são fornecidas ao modelo juntamente com seu rótulo (Figura 8), ou seja, o modelo "sabe" que são imagens de palmeiras. Quando uma nova imagem é apresentada ao modelo, é realizada a predição do seu rótulo (MA et al., 2018). Este é o tipo de aprendizado de máquina utilizado neste estudo.

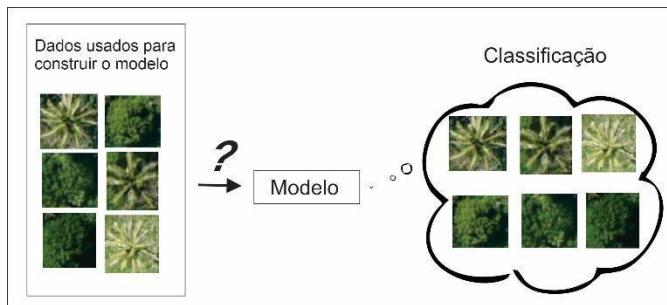
Figura 8 – Aprendizado de Máquina Supervisionado



Fonte: Elaborado pelo autor (2025)

b) Aprendizado não supervisionado: o modelo é treinado em dados não rotulados, ou seja, não são conhecidas as saídas mapeadas (Figura 9). O modelo procura padrões e estruturas intrínsecas, sendo comumente usados para tarefas como agrupamentos por semelhança e redução de dimensionalidade.

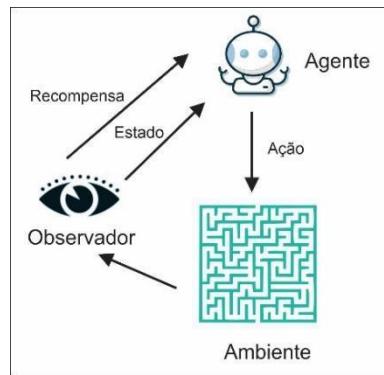
Figura 9 – Aprendizado de Máquina Não-Supervisionado



Fonte: Elaborado pelo autor (2025)

c) Aprendizado por reforço: neste tipo de aprendizado, os modelos aprendem a tomar decisões sequenciais interagindo com as variáveis do ambiente e recebendo recompensas ou penalizações (Figura 10). Suas aplicações incluem jogos, robótica e otimização, entre outros.

Figura 10 – Aprendizado de Máquina por Reforço



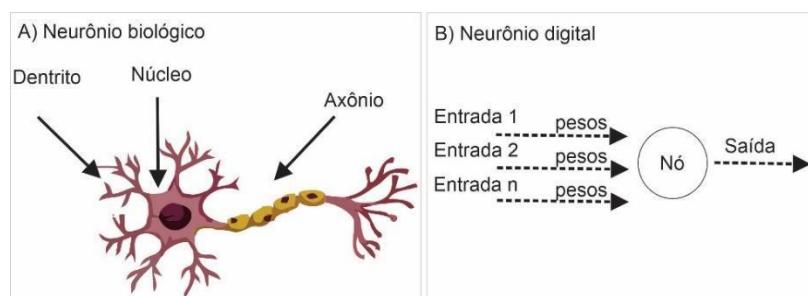
Fonte: Elaborado pelo autor (2023)

Distribuídos entre esses três tipos de aprendizado de máquina, existem diversos algoritmos amplamente utilizados e aplicáveis em uma variedade de cenários. Alguns deles incluem Máquinas de Vetores de Suporte (SVM), K-Vizinhos Mais Próximos (K-NN), Árvores de Decisão, *Random Forest*, Regressão Linear, Regressão Logística, Redução de Dimensionalidade (PCA, LDA): Agrupamentos (K-Means, Hierárquico), Redes Bayesianas (RUSSELL; NORVIG, 2010; IZBICKI; SANTOS, 2020).

2.4.2 Aprendizado profundo de máquina (*Deep learning*)

O aprendizado profundo de máquina, também conhecido como *deep learning*, é uma subárea do aprendizado de máquina e tem como objetivo aprimorar a capacidade das máquinas em reconhecer, classificar, detectar padrões. Sua arquitetura é inspirada no funcionamento do cérebro humano. Os primeiros modelos tentaram simular a função de um único neurônio (Figura 11A), implementando seu funcionamento artificial (Figura 11B). Rosenblatt (1958) desenvolveu o primeiro modelo chamado Perceptron de Camada Única.

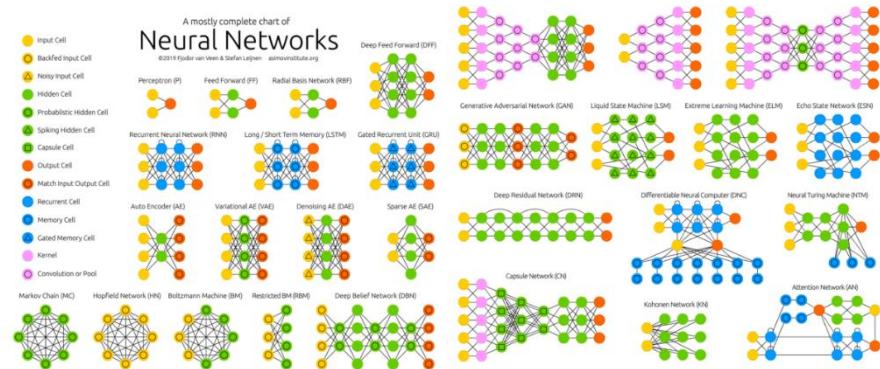
Figura 11 – Comparação conceitual entre neurônio biológico e digital



Fonte: Elaborado pelo autor (2025)

Com o passar dos anos, novos modelos foram propostos e evoluindo para redes interconectadas de neurônios, o que conhecemos hoje como redes neurais artificiais profundas. O termo "profundo" refere-se ao fato de que esses modelos geralmente possuem muitas camadas em comparação com as redes neurais tradicionais. A Figura 12 exemplifica a evolução das redes neurais desde o Perceptron de camada única até as redes neurais de aprendizado profundo de máquina como, por exemplo, as Redes Neurais Convolucionais (CNN, do inglês *Convolutional Neural Network*) (GOODFELLOW; BENGIO; COURVILLE, 2017).

Figura 12 – Redes neurais artificiais e algumas das principais arquiteturas.



Fonte: Adaptado de Van Venn; Leijnen, (2019)

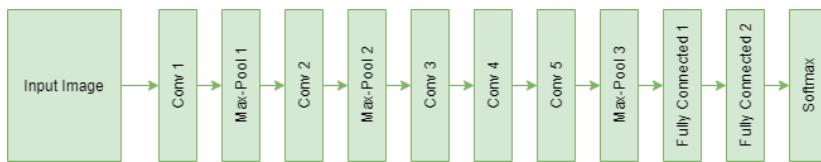
Essa tarefa nem sempre é trivial e demanda criação de programas (*scripts*) para automatizar estas extrações, bem como a participação de especialistas multidisciplinares. Por outro lado, com o aprendizado profundo de máquina, a extração de características de objeto em uma imagem ocorre de forma automática durante a etapa de treinamento da rede neural profunda. Neste trabalho, adotou-se essa abordagem de aprendizado profundo de máquina por meio de redes neurais convolucionais (CNN), as quais serão apresentadas a seguir.

2.4.3 Redes neurais convolucionais (CNN)

As redes neurais convolucionais (CNN) são provavelmente o modelo de aprendizado profundo de máquina mais conhecido para resolver tarefas de visão computacional, especialmente na classificação de imagens (GOODFELLOW; BENGIO; COURVILLE, 2017; PONTI et al., 2017). Elas são capazes de aprender automaticamente características relevantes diretamente das imagens, o que permite a identificação de padrões complexos e hierárquicos.

Lecun et al. (1998) contribuíram significativamente para o desenvolvimento e a popularização das CNNs, introduzindo a LeNet-5, uma arquitetura pioneira da CNN para o reconhecimento de caracteres escritos à mão. Outro marco importante na história ocorreu em uma competição anual de visão computacional (ImageNet Large Scale Visual Recognition Challenge) (RUSSAKOVSKY et al., 2015) que em 2012 apresentaram uma arquitetura AlexNet, que utilizou CNNs para alcançar resultados notáveis até essa competição (KRIZHEVSKY; SUTSKEVER; HINTON, 2017). A AlexNet superou as abordagens tradicionais anteriores e a partir deste trabalho, todos os vencedores nos anos seguintes tinham componentes de IA em suas arquiteturas, marcando como um ponto de virada no campo da visão computacional. A Figura 13 mostra detalhes de como a rede neural profunda é composta por várias camadas, cada uma desempenhando um trabalho específico.

Figura 13 – Camadas convolucionais de uma rede neural artificial



Fonte: Adaptado de Krizhevsky; Sutskever; Hilton, (2017)

Os dados (*pixels* da imagem) passam por essas camadas, começando com características pequenas e simples, e avançando para características maiores e mais complexas, até que rede chegue a uma conclusão sobre o que está na imagem. As principais camadas são:

- **Camadas de convolução:** Cada neurônio nessas camadas é responsável por detectar características específicas nas imagens, como bordas, texturas ou padrões simples. Isso é feito aplicando operações de convolução nas entradas da rede, que consistem em passar filtros pequenos sobre a imagem para extraír informações relevantes.
- **Camadas de *pooling*:** Camadas de *pooling* são responsáveis pela redução da dimensionalidade das representações, mantendo as informações mais importantes.
- **Camadas de convolução profunda:** À medida que a rede avança, camadas de convolução mais profundas capturam características complexas e hierárquicas, como partes específicas de objetos ou texturas mais elaboradas.

- Camadas totalmente conectadas: As camadas totalmente conectadas permitem haja uma integração nas informações de alto nível de todas as regiões da imagem.
- Camada de saída: A última camada da rede que normalmente utiliza uma função de ativação *softmax* para atribuir probabilidades às diferentes classes de objetos. Cada neurônio na camada de saída representa uma classe, e a saída final é a classe com a probabilidade mais alta.

Especificamente para segmentação de objetos, o uso de modelos baseados em CNNs otimiza o processo de extração de características do objeto de estudo. Entre as abordagens mais utilizadas, destaca-se a segmentação semântica, que consiste em classificar cada pixel de uma imagem com um rótulo correspondente à classe do objeto ou região ao qual pertence (GARCIA-GARCIA et al., 2017). Portanto, a segmentação semântica vai além de simplesmente dividir a imagem em regiões, ela atribui significado a cada região, identificando, por exemplo, todos os pixels que pertencem a árvores, solo, água, entre outros. Existem vários outros tipos de CNNs criadas para abordar problemas específicos de acordo com suas aplicações como: *Single Shot Detector* (SSD), CenterNet, YOLO (You Only Look Once), Faster R-CNN entre outros.

2.4.4 YOLO

O YOLO (*You Only Look Once*) é uma arquitetura de rede neural convolucional projetada para detecção de objetos em tempo real. Introduzido em 2016, o YOLO revolucionou o campo da visão computacional com sua abordagem inovadora de estágio único, diferenciando-se das arquiteturas tradicionais de dois estágios. Ao contrário dos métodos anteriores que envolviam etapas separadas para geração de propostas de regiões e classificação, o YOLO prevê caixas delimitadoras e probabilidades de classe simultaneamente, tudo em uma única passagem pela rede (HUSSAIN, 2024). Desde a sua versão inicial (YOLOv1), o YOLO passou por inúmeras iterações, cada uma apresentando avanços arquitetônicos e melhorias de desempenho. A versão 8 do YOLO introduziu um modelo de segmentação semântica denominado YOLOv8-Seg, que é empregado neste trabalho.

2.5 Sensoriamento remoto e IA na estimativa de carbono

A estimativa de biomassa e estoques de carbono é uma área em expansão, essencial para o monitoramento ambiental e o manejo sustentável de recursos. Diversas culturas agrícolas e ecossistemas têm sido estudados para avaliar a captura de carbono a partir de imagens obtidas por satélites e drones, abrangendo sistemas agroflorestais, (STANGARLIN, 2023), florestas regeneradas (OLIVEIRA, 2023), manguezais (BASYUNI et al., 2023), plantações (DAHY; ISSA; SALEOUS, 2023; LIU et al., 2024; SOUSA, 2023) e ecossistemas urbanos (BALESTRA et al., 2024). As principais técnicas incluem índices de vegetação, equações alométricas, algoritmos de aprendizado de máquina, LiDAR (*Light Detection and Ranging*) e imagens RGB e multiespectrais. Entre as principais técnicas mencionadas, os índices de vegetação têm sido utilizados para quantificar características biofísicas da vegetação a partir de imagens de sensores remotos. Cada índice é calculado com base na reflectância da vegetação em diferentes bandas do espectro eletromagnético, como o infravermelho próximo (NIR), o vermelho (RED) e o azul (BLUE). A seguir, são apresentados os índices mais comumente utilizados como variáveis para estimativa de carbono:

- NDVI (Normalized Difference Vegetation Index): utiliza a diferença normalizada entre as bandas NIR e RED para estimar a densidade e a saúde da vegetação. É amplamente aplicado em diversos ecossistemas, por sua simplicidade e eficácia no monitoramento de vegetação (PETTORELLI et al., 2005).
- PRI (Photochemical Reflectance Index): este índice é calculado com base na reflectância nas bandas específicas de comprimento de onda centradas em 531 nm (R531) e 570 nm (R570). Ele mede mudanças na reflectância associadas à atividade da xantofila, um pigmento vegetal que regula a dissipação do excesso de energia luminosa absorvida pelas folhas durante a fotossíntese. (GAMON et al., 1990).
- ARVI (Atmospherically Resistant Vegetation Index): é uma variação do NDVI, ajustada para reduzir interferências atmosféricas como poeira e poluição, sendo ideal para monitoramento em regiões com condições atmosféricas adversas (GAMON et al., 1990).
- SAVI (Soil-Adjusted Vegetation Index): O SAVI foi desenvolvido para corrigir a influência do solo em áreas com vegetação esparsa, onde a presença do solo exposto

pode distorcer os valores de índices de vegetação tradicionais, como o NDVI. (HUETE, 1988).

- EVI (Enhanced Vegetation Index): este índice permite melhorar a sensibilidade em áreas com alta densidade de biomassa, onde índices como o NDVI podem sofrer saturação (quando a vegetação é muito densa e os valores de reflectância no infravermelho próximo atingem um limite máximo) (MATSUSHITA et al., 2007).

Alguns trabalhos têm se utilizado dos mais variados tipos de índices de vegetação como variáveis preditoras do acúmulo de carbono. Fonseca et al., (2024), propuseram uma metodologia para estimar estoques de biomassa no bioma Caatinga em Pernambuco, Brasil, usando drones equipados com câmeras RGB e nove diferentes índices de vegetação. Um índice de vegetação é uma medida obtida através da combinação de dados de diferentes faixas espectrais da radiação eletromagnética refletida pela vegetação. Dois modelos foram gerados: o modelo 1, que diferenciou Caatinga Densa, Aberta e Pastagem, alcançou um R^2 ajustado de 0,6738, enquanto o modelo 2, com apenas duas categorias (Caatinga e Pastagem), obteve um R^2 ajustado de 0,8235, mas violou a homogeneidade dos resíduos. Ainda com uso de índices de vegetação, Stangarlin, (2023), por sua vez, desenvolveu modelos de redes neurais artificiais (RNA) para estimar o CO₂ equivalente (CO₂eq) em um Sistema Agroflorestal (SAF) silvibananheiro no Litoral Norte do Rio Grande do Sul, Brasil. Utilizando 18 índices de vegetação derivados de imagens de satélites e drones, dois modelos foram testados, sendo que o modelo com todas as variáveis apresentou ligeira superioridade em precisão. O sistema analisado registrou valores médios de biomassa de 90,59 Mg ha⁻¹, carbono de 45,3 Mg ha⁻¹ e CO₂eq de 166,23 Mg ha⁻¹.

Estudos em áreas urbanas também têm explorado sensoriamento remoto para estimativas de carbono. Ribeiro et al., (2024) combinaram imagens de satélite de alta resolução (Planet, 3x3m) com medições de biomassa em campo para quantificar o sequestro de carbono em parques do Cerrado urbano em Brasília, Brasil. A metodologia, que incluiu índices de fluxo de CO₂, obtido da relação entre os índices de vegetação NDVI (Índice de Vegetação por Diferença Normalizada) e PRI (Índice de Refletância Fotoquímica). O grupo de plantas lenhosas apresentou uma biomassa média variando entre 8.915,68 e 11.545,12 kg ha⁻¹. O resultado mostrou forte correlação ($R^2=1$) entre os dados de campo e as imagens de satélite, fornecendo subsídios para políticas de mitigação climática. De maneira similar, Nuñez et al. (2024) analisaram o sequestro de carbono em um parque metropolitano de Quito,

Equador. O estudo utilizou o Índice de Vegetação de Diferença Normalizada (NDVI), derivado de imagens dos satélites Landsat 8 e Sentinel-2, e integrou medições *in situ* do diâmetro e da altura das árvores. Com base nessas medições, foram aplicadas equações alométricas para estimar a biomassa das árvores e, consequentemente, o sequestro de carbono. O resultado foi uma estimativa de 42.150 toneladas de CO₂ armazenado. Slavskiy et al., 2024 também exploraram áreas urbanas e ecossistemas florestais, combinando imagens de drones (RGB, LiDAR e hiperespectrais) com modelos de aprendizado de máquina para estimar a fitomassa e o estoque de carbono em ecossistemas da estepe florestal central da planície euro-asiática oriental na região de Voronezh, Rússia. Os estoques totais de carbono nas florestas variaram de 58,6 t ha⁻¹ em áreas dominadas por bétulas, com poucos estoques de madeira de tronco, até 167,8 t ha⁻¹ em áreas com pinheiros mistos. A contribuição da vegetação rasteira e do sub-bosque foi de até 3,8 t C ha⁻¹, e os estoques de carbono na fitomassa acima do solo raramente superaram 1,0 t ha⁻¹. Os autores destacam que a principal vantagem da metodologia proposta é a minimização do trabalho de campo, resultando em redução de custos sem perda de qualidade da informação.

Os manguezais também têm sido alvo de estudos devido à sua alta capacidade de armazenamento de carbono. Larekeng et al., (2024) empregaram drones com câmeras multiespectrais no ecossistema de Lantebung, Indonésia, para correlacionar NDVI e estoques de carbono. Os resultados mostraram uma forte correlação entre o NDVI e os estoques de carbono, o que possibilitou a criação de um modelo para estimar a distribuição espacial do carbono nos manguezais. Assim, os estoques de carbono nas áreas de manguezal de baixa densidade foram estimados entre 17,24 e 288,64 t/ha, nas áreas de densidade média variaram de 126,04 a 391,14 t/ha, e nas áreas de alta densidade, os valores ficaram entre 258,04 e 491,85 t/ha. De forma semelhante, Basyuni et al., (2023) compararam estoques de carbono em manguezais e plantações comerciais na Indonésia. O objetivo foi avaliar a redução significativa dos estoques de carbono nos manguezais convertidos em plantações de dendê e coqueiro. A metodologia envolveu a geração de modelos digitais de superfície e terreno a partir de imagens de VANT, que, combinados com dados de campo, permitiram estimar a biomassa. Os resultados indicaram que os manguezais armazenam mais carbono que as plantações. Em Lubuk Kertang, por exemplo, a biomassa média acima do solo (AGB) dos manguezais foi de 52,7 Mg ha⁻¹, com um estoque de carbono de 26,4 MgC ha⁻¹. Em comparação, as plantações de dendê apresentaram uma AGB média de 2,66 Mg ha⁻¹, e as de coqueiro, 0,98 Mg ha⁻¹, com os estoques de carbono nas plantações de dendê variando entre

0,7 e 6,7 MgC ha⁻¹. Em Pulau Sembilan, os manguezais apresentaram uma AGB média de 85 Mg ha⁻¹, com um estoque de carbono de 42,5 MgC ha⁻¹, enquanto as plantações de dendê tiveram uma AGB média de 3,6 Mg ha⁻¹, com estoques de carbono variando de 0 a 5,5 MgC ha⁻¹. Os autores ressaltam a importância da conservação e restauração dos manguezais para a mitigação das mudanças climáticas.

A tecnologia LiDAR (*Light Detection and Ranging*) tem se mostrado essencial para mapear biomassa e carbono com precisão. Fadil et al., (2024a) utilizaram essa tecnologia acoplada a drones para estimar biomassa em florestas de sobreiros na Maamora, Marrocos. A análise das mudanças na biomassa e nos estoques de carbono na área de estudo durante 35 anos (1985–2020) revelou um pequeno aumento de menos de 10 Mg/há. O estudo destacou o Índice de Vegetação Resistente à Atmosfera (ARVI) como o melhor índice para prever biomassa, permitindo a criação de mapas detalhados da dinâmica do carbono ao longo de 35 anos. Fadil, Sebari, Moulay, et al., (2024) expandiram essa abordagem, usando regressões lineares e LiDAR-VANT para prever carbono em florestas degradadas da mesma região. De maneira geral, os resultados das três pesquisas com Lidar-UAV indicam valores baixos de estoque de carbono, variando de 1,4 a 19,2 Mg/ha nas áreas de estudo, o que confirma que parte da floresta de Maâmora se encontra em estado de degradação.

De maneira similar, Toneli et al., (2024) combinaram sensores ópticos e LiDAR para estimar biomassa no Cerrado brasileiro, utilizando dados de altura do dossel obtidos por sensores ópticos e a laser. A pesquisa combinou uma revisão sistemática de estudos publicados sobre biomassa no Cerrado com um modelo alométrico, que relaciona a altura do dossel à biomassa acima do solo. Os resultados das parcelas de amostragem deste estudo indicaram um valor de 12,3 Mg ha⁻¹. Nas formações de savana, a média de biomassa de raízes foi de 13,3 Mg ha⁻¹, enquanto nas formações florestais, o valor médio foi de 18,63 Mg ha⁻¹. Esses achados demonstram uma boa concordância entre as estimativas do modelo e os dados da literatura, ainda que existam incertezas maiores em formações arbustivas devido à sua estrutura menos densa.

Estudos em plantações comerciais também destacam o potencial do sensoriamento remoto. Dahy et al., (2023) analisaram tamareiras no emirado de Abu Dhabi em três estágios de idade: madura, média e jovem, empregando imagens Landsat-8 e modelos de regressão para mapear carbono resultando em um total de 2.447.856,87 toneladas em uma área de 7588,04 hectares. Wungshap et al., (2023) investigaram florestas e plantações em Manipur,

Índia, utilizando geoinformática e dados de campo para comparar estoques de carbono acima e abaixo do solo, enfatizando a importância de índices de vegetação como o Índice de Vegetação Ajustado do Solo (SAVI) na precisão das estimativas.

Alguns estudos têm integrado o aprendizado de máquina com sensoriamento remoto para aumentar a precisão das estimativas. Sharma et al., (2022) fizeram uma revisão do potencial do uso de drones e aprendizado de máquina para estimar o armazenamento de carbono florestal. Os autores argumentam que a integração de dados de drones com modelos de aprendizado de máquina pode fornecer uma abordagem rápida, precisa e econômica para estimar e modelar a captura e armazenamento de carbono.

Os drones podem ser equipados com câmeras RGB ou LiDAR para capturar imagens da floresta, que podem ser usadas para derivar parâmetros estruturais da floresta, como área da copa, altura e diâmetro das árvores. Esses dados podem ser usados em modelos de aprendizado de máquina e equações alométricas para estimar o armazenamento de carbono na biomassa viva das florestas. Su et al., (2024) compararam LiDAR portátil e imagens multiespectrais de drones em modelos de regressão linear multivariada e de aprendizado de máquina, como *Random Forest*, empregando dados de duas espécies de árvores (*Larix gmelinii* e *Betula platyphylla*) na Fazenda Florestal Nacional de Dural, cidade de Arxan, China. As médias de estoque de carbono acima do solo para as espécies estudadas foram de 31.910 kg para *Larix gmelinii* e 28.390 kg para *Betula platyphylla*. Os resultados mostraram que os modelos de *Random Forest* superaram os modelos de regressão, e que a integração de dados de ambas as fontes melhorou significativamente a acurácia das estimativas de carbono acima do solo, especialmente para o diâmetro à altura do peito (DAP) das árvores. Nascetti et al., (2023) apresentaram o conjunto de dados BioMassters, que integra dados do Sentinel-1 e do Sentinel-2 - séries de satélites da Agência Espacial Europeia (ESA). Os satélites Sentinel-1 são equipados com sensores de radar de abertura sintética (SAR) e são utilizados principalmente para o monitoramento terrestre e oceânico. Já o par de satélites Sentinel-2 é voltado para o monitoramento da vegetação, dos solos e de áreas costeiras, contando com sensores ópticos multiespectrais de alta resolução espacial. Esses dados foram combinados com informações de LiDAR aéreo em florestas da Finlândia para modelar a biomassa florestal acima do solo em larga escala, explorando técnicas de aprendizado profundo de máquina para aprimorar a precisão das estimativas.

Em resumo, os avanços no sensoriamento remoto e algoritmos de aprendizado de máquina têm apresentado novas soluções às estimativas de biomassa e estoques de carbono, permitindo maior precisão, redução de custos e maior eficiência no monitoramento ambiental. Embora estes estudos demonstrem o uso das novas tecnologias para estimativa de carbono em diversas culturas, nenhum estudo foi realizado com dados de imagens aéreas e inteligência artificial para estimativa de carbono com macaúbas.

3 METODOLOGIA

3.1 Áreas de estudo

O presente trabalho, utilizou sete áreas de estudo, onde foram obtidas imagens capturadas por VANTs em três campos experimentais com cultivo de macaúba e uma área de ocorrência natural da macaúba.

O campo experimental de Unaí - MG foi utilizado para a validação das estimativas dos diâmetros das copas e das alturas das palmeiras macaúbas, com base nos dados de campo previamente obtidos nessa localidade.

Área 1: Palmas, Tocantins

A Área de Pesquisa da Universidade Federal do Tocantins – UFT, está localizada dentro do Parque Agrotecnológico Engenheiro Agrônomo Mauro Mendenha ($10^{\circ}24'09''S$ $48^{\circ}21'41''W$ e altitude de 220 metros), distante 37 km de Palmas, no estado de Tocantins. A área com cultivo de macaúba possui aproximadamente 1,2 hectares e está dividida em dois plantios realizados em duas épocas distintas, 2009 e 2021, correspondendo a idades de 15 e 3 anos, respectivamente (Figura 14). Para os plantios com 3 anos de idade, os espaçamentos utilizados foram: 7×4 metros (357 plantas/ha), 12×4 metros (208 plantas/ha) e $12 \times 4 \times 4$ metros (350 plantas/ha). Já para o plantio com 15 anos, o espaçamento adotado foi de 6×5 metros, resultando em uma densidade de 333 plantas por hectare.

Figura 14 – Áreas com cultivo de macaúba em Palmas – TO

A) Área com 15 anos



B) Área com 3 anos



Fonte: Elaborado pelo autor (2025)

Área 2: Unaí, Minas Gerais

Esta área de estudo está localizada no município de Unaí, no estado de Minas Gerais e encontra-se situada em 16° 26' 42"S 46° 54' 13"W com altitude de 615 metros. A área de cultivo de macaúba possui aproximadamente 1,7 hectares, com idade de 3 anos e plantio realizado em 2021 (Figura 15). Os dados de campo obtidos em setembro de 2024 foram usados para validar os diâmetros das copas e as alturas das palmeiras macaúbas estimadas pelo modelo computacional.

Figura 15 – Área experimental em Unaí – MG



Fonte: Elaborado pelo autor (2025)

Área 3: Viçosa, Minas Gerais

A área de estudo está localizada na região de Viçosa, no estado de Minas Gerais, nas coordenadas 20°39'09"S e 42°32'00"W, a uma altitude de 800 metros. Sua extensão é de aproximadamente 6 hectares, e os plantios de macaúba ocorreram nos anos de 2010, 2014 e 2019 (Figura 16). O espaçamento adotado foi de 5 x 5 metros, resultando em uma densidade de aproximadamente 400 plantas por hectare. Em outras áreas, foram utilizados dois arranjos alternativos: fileiras duplas com espaçamento de 4 x 4 metros entre plantas dentro da dupla e 8 metros entre as duplas; e o espaçamento regular de 7 x 3,5 metros, com 7 metros entre fileiras e 3,5 metros entre plantas na linha.

Figura 16 – Área experimental em Viçosa – MG



Fonte: Elaborado pelo autor (2025)

Área 4: Dois Irmãos do Tocantins, Tocantins

Esta área está localizada no município de Dois Irmãos do Tocantins, a 190 km de Palmas (sentido norte), no estado do Tocantins. Trata-se de uma área de ocorrência natural de palmeiras macaúbas, entre outras espécies. A altitude é de 450 metros, e a área abrange aproximadamente 16 hectares, com a idade das plantas não conhecida (Figura 17).

Figura 17 – Área de ocorrência natural em Dois Irmãos do Tocantins – TO



Fonte: Elaborado pelo autor (2025)

3.2 Obtenção das imagens por VANT

As imagens aéreas de ocorrência natural em Dois Irmãos do Tocantins foram obtidas em 2023. As demais imagens das áreas de estudo foram capturadas em 2024. A Tabela 1 apresenta os principais aspectos relacionados ao processo de obtenção das imagens capturadas por drone, abrangendo informações sobre o equipamento utilizado, a data do voo, as condições de captura e a resolução espacial média das imagens (GSD), além da altitude do voo. Esses detalhes asseguram a consistência e a qualidade dos dados visuais obtidos ao longo do trabalho.

Tabela 1 – Modelos de VANT e dados do voo, utilizados por área de estudo

Área de estudo	Data do voo	Equipamento (VANT)	GSD médio (cm / pixel)	Altitude do voo (metros)
Unaí - MG	Set/2024	DJI Mavic 3 Pro	3,8	40
Dois Irmãos do Tocantins - TO	Set/2023	DJI Mavic Air 2	4,23	138
Palmas - TO	Out/2024	DJI Mavic Air 2	1,45	60
Viçosa - MG	Out/2024	DJI Mavic 3 Multispectral	2,0	70

Os voos foram realizados em faixas paralelas, com sobreposições laterais e longitudinais mínimas de 70%. As imagens brutas foram processadas utilizando o software

WebODM, gerando ortofotos com uma distância de amostragem terrestre (GSD) variando entre 1 cm e 5 cm na área de estudo.

3.3 Pré-processamento das imagens

A identificação de cada indivíduo de macaúba nas imagens geradas a partir do processo de ortofotogrametria foi essencial para possibilitar a comparação das medidas individuais de altura e diâmetro da copa com as informações coletadas em campo. Além disso, essa identificação foi fundamental para o cálculo da altura máxima e para o treinamento do modelo de inteligência artificial destinado à segmentação da copa das palmeiras. Para atender a essa necessidade, foi desenvolvida uma ferramenta em Python, com o objetivo de extrair cada indivíduo de macaúba da imagem principal, gerando uma tabela contendo as seguintes informações:

- Nome do arquivo;
- Posição X, Y do centro da imagem;
- Coordenadas X1, Y1, X2, Y2 do retângulo que envolve a palmeira;
- Latitude e Longitude

A Figura 18 ilustra a execução da ferramenta desenvolvida. Para cada macaúba identificada, foi gerado um novo arquivo de imagem individual. O nome de cada arquivo é utilizado para mapear o respectivo indivíduo na tabela de monitoramento de campo, permitindo associar as medidas inferidas às observações obtidas em campo, o que possibilita a comparação entre elas. Todas as áreas de estudo deste trabalho passaram por este processamento resultando em 2.329 arquivos de imagens individuais de macaúba.

Figura 18 – Ferramenta para identificação individual das macaúbas



Fonte: Elaborado pelo autor (2025)

3.4 Cálculo do diâmetro das copas das palmeiras

Para estimar o maior diâmetro das copas das palmeiras de macaúba, foram adotadas duas abordagens. Na primeira abordagem utilizou-se um modelo de aprendizado de máquina, que foi treinado para segmentar a copa da palmeira. Na segunda abordagem, foram implementadas técnicas de visão computacional, sendo desenvolvido um *script* para encontrar o maior diâmetro, a partir da máscara gerada com base na segmentação da copa da etapa anterior.

3.4.1 Segmentação das copas usando inteligência artificial

A segmentação da copa da macaúba é uma etapa crucial para a estimativa mais precisa do diâmetro da copa. Esse processo permite contornar as limitações de métodos que utilizam inferências circulares ao redor da copa, os quais podem introduzir erros devido à irregularidade natural das formas. A segmentação também reflete com maior fidelidade o procedimento utilizado em campo, garantindo maior consistência e alinhamento entre as medições digitais e as reais.

O uso de aprendizado profundo de máquina potencializa a qualidade da segmentação, pois o modelo é treinado para identificar padrões complexos nas copas das palmeiras, mesmo em situações com sobreposição de vegetação ou condições desafiadoras, como sombras e variações de luminosidade. Essa abordagem é especialmente vantajosa em cenários de larga escala, permitindo a análise automatizada de grandes conjuntos de dados. Apesar de uma fração do total de indivíduos de macaúba precisarem ser rotulados manualmente para treinar o modelo, otimizando o esforço e os recursos empregados no processo de anotação. Além disso,

o modelo apresenta boa capacidade de generalização, podendo ser aplicado a diferentes regiões e condições de cultivo, com alto grau de precisão após o treinamento.

As etapas desse processo, em que se destaca a integração entre as fases manuais e automatizadas, bem como os resultados obtidos, estão apresentadas na Figura 19.

Figura 19 – Processo de treinamento do modelo de IA para segmentação das palmeiras de macaúba



Fonte: Elaborado pelo autor (2025)

De acordo com a Figura 19, o processo inicia com a rotulagem de um conjunto mínimo das imagens de cada área de estudo. Em seguida, o modelo é treinado utilizando esses dados rotulados, e seu desempenho é avaliado. Após a validação, o modelo treinado é aplicado a 100% das imagens de cada área. A partir das segmentações geradas, as máscaras de cada copa são extraídas, permitindo, finalmente, a identificação e o cálculo do maior diâmetro das copas.

3.4.2 Criação do *dataset* de imagens

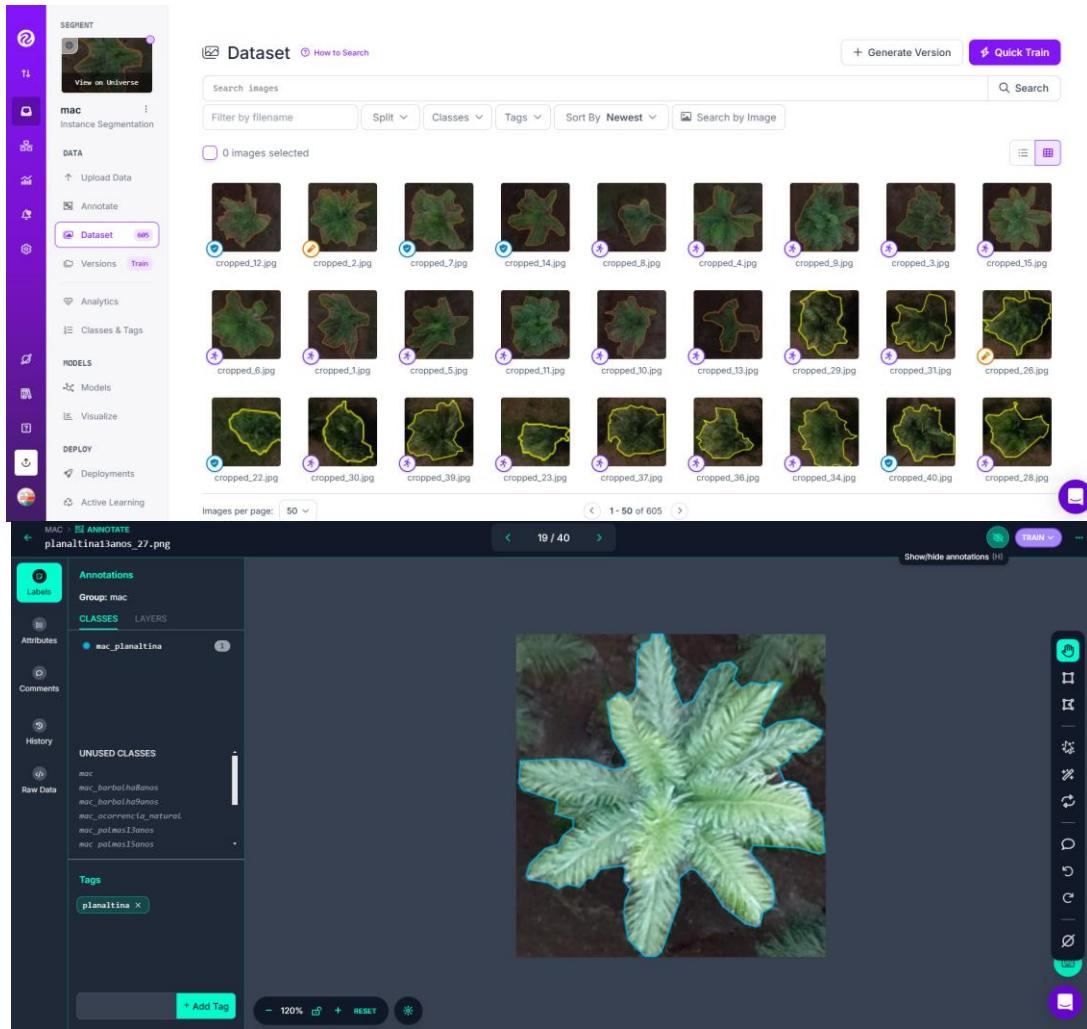
A elaboração do *dataset* (ou conjunto de dados) é uma etapa importante no treinamento de um modelo computacional de desempenho aceitável, pois uma vez bem elaborado, tem papel fundamental na qualidade, eficácia e generalização do modelo, ou seja, na sua aplicação em escala de produção. Ter um *dataset* diversificado, representativo e bem anotado é crucial para garantir que o modelo possa aprender padrões relevantes e generalizar para diferentes situações do mundo real (RUSSAKOVSKY et al., 2015). Para tanto, neste trabalho, o *dataset* foi composto por imagens de todas as áreas de estudo nas diferentes

regiões e com suas características próprias. As imagens que compõem o *dataset* de treinamento foram selecionadas aleatoriamente e respeitando a quantidade por região e idade para manter uma distribuição uniforme entre as classes. No total, foram anotadas 329 imagens, o que representa 14,1% do total de 2.329 palmeiras macaúbas.

3.4.3 Anotação das imagens para o treinamento do modelo

O processo de anotação das imagens envolve a marcação manual, feita por humanos, das regiões de interesse em uma imagem. É um componente crítico no desenvolvimento de sistemas de reconhecimento e segmentação de imagens baseados em aprendizado de máquina. Anotações imprecisas podem levar o modelo a aprender informações incorretas ou confusas sobre os objetos presentes nas imagens. Isso resulta em um desempenho geral insatisfatório do modelo, com taxas de erro elevadas e previsões incorretas aumentando o número de falsos positivos (áreas fora das copas sendo erroneamente segmentadas como parte da copa) e falsos negativos (áreas das copas não sendo detectadas). Com o objetivo de minimizar esse tipo de erro, utilizou-se a ferramenta Roboflow, amplamente utilizada em tarefas semelhantes por disponibilizar recursos que otimizam a anotação, tornando-a mais ágil e precisa. O Roboflow é uma plataforma que utiliza inteligência artificial para tarefas de anotação disponível em <https://app.roboflow.com>. Essa ferramenta facilitou significativamente o processo de anotação, mesmo diante de desafios como algumas imagens com sombras ou com menor resolução (Figura 20).

Figura 20 – Interface do software Roboflow exemplificando a anotação dos dados de treinamento do modelo



Fonte: Elaborado pelo autor (2025)

3.4.4 Pré-processamento e aumento de dados

Um pré-processamento foi aplicado para padronizar o tamanho das imagens em 640×640 pixels para reduzir o custo computacional do treinamento. Por fim, o dataset foi submetido a um processo de aumento de dados conhecido como *Data Augmentation* com o objetivo de melhorar a generalização e reduzir o risco de *overfitting* (*Overfitting* ocorre quando um modelo de aprendizado de máquina se ajusta excessivamente aos dados de treinamento (BEJANI; GHATEE, 2021). Desta maneira, foram aplicadas rotações de 90° (horário e anti-horário) para gerar novas imagens.

3.4.5 Treinamento do modelo computacional

O modelo de segmentação foi treinado utilizando o YOLOv8, uma arquitetura de aprendizado profundo de máquina especializada em tarefas de detecção e segmentação de objetos. A versão YOLOv8s-seg foi escolhida devido à sua eficiência e rapidez em tarefas de segmentação (ZHANG et al., 2024). As imagens utilizadas no treinamento foram distribuídas da seguinte forma: 560 imagens para treinamento, 56 para validação e 30 para testes. O treinamento foi realizado em uma infraestrutura equipada com uma GPU para otimizar o desempenho e garantir o processamento rápido. Este processamento ocorreu em um laptop com especificações de hardware, incluindo uma CPU Intel(R) Core (TM) i7-7700HQ 2.80 GHz, 32 GB de memória RAM, SSD de 1 TB e uma GPU NVIDIA® GeForce GTX 1050 Ti com 4 GB de memória dedicada, além de CUDA® versão 11.4. O Google Colaboratory foi usado para treinamento do modelo YOLO. Os *scripts* utilizados para o treinamento e avaliação foram implementados em Python 3.10.12.

3.4.6 Análise de desempenho do modelo computacional

A avaliação do desempenho do modelo de segmentação foi realizada utilizando as métricas mAP (*mean Average Precision*), Precisão e Recall, que são amplamente utilizadas para medir a eficácia de modelos em tarefas de segmentação e detecção de objetos.

A Precisão (*Precision*) foi calculada como a razão entre o número de verdadeiros positivos (TP) e o número de verdadeiros positivos mais falsos positivos (FP), conforme a fórmula:

$$\text{Precisão} = \frac{TP}{TP + FP}$$

O Recall, por sua vez, foi calculado como a razão entre o número de verdadeiros positivos (TP) e a soma dos verdadeiros positivos e falsos negativos (FN), conforme a fórmula:

$$\text{Recall} = \frac{TP}{TP + FN}$$

O modelo também classifica cada macaúba em relação a sua região, para isto a acurácia foi usada como critério de avaliação do desempenho, considerando os seguintes

elementos: TP (Verdadeiros Positivos), TN (Verdadeiros Negativos), FP (Falsos Positivos) e FN (Falsos Negativos):

$$Acurácia = \frac{(TP + TN)}{(TP + TN + FP + FN)}$$

3.4.7 Geração das máscaras e cálculo do maior diâmetro das copas das palmeiras

Um *script* em Python foi desenvolvido para aplicar o modelo de segmentação previamente treinado e validado a cada imagem de copa de macaúba. A biblioteca OpenCV foi usada para gerar máscaras binárias que delimitam as áreas segmentadas obtidas pelo modelo de IA (Figura 211a). Além disso, uma camada de transparência foi adicionada à visualização das máscaras, permitindo uma exibição clara e eficiente das áreas segmentadas sobre a imagem original. As máscaras geradas foram sobrepostas à imagem original, com a transparência controlada por um parâmetro alfa. O parâmetro alfa determina o grau de transparência da máscara, variando de 0 (totalmente transparente) a 1 (totalmente opaco). Esse controle garante que tanto a máscara quanto a imagem original sejam visíveis, facilitando a interpretação visual dos resultados (Figura 211b). A partir de cada máscara binária, foi desenvolvido um *script* para identificar a maior reta em *pixels* dentro da máscara utilizando a biblioteca OpenCV. Após calcular a distância em *pixels*, a conversão para metros é realizada multiplicando a distância obtida pela resolução espacial específica de cada imagem, correspondente a cada região de estudo, a qual é extraída do arquivo TIFF georreferenciado (Figura 21c).

Figura 21 – Ilustração do processo de segmentação da copa. a) resultado do modelo de IA; b) máscara extraída e c) cálculo do maior diâmetro



Fonte: Elaborado pelo autor (2025)

3.4.8 Análise estatística

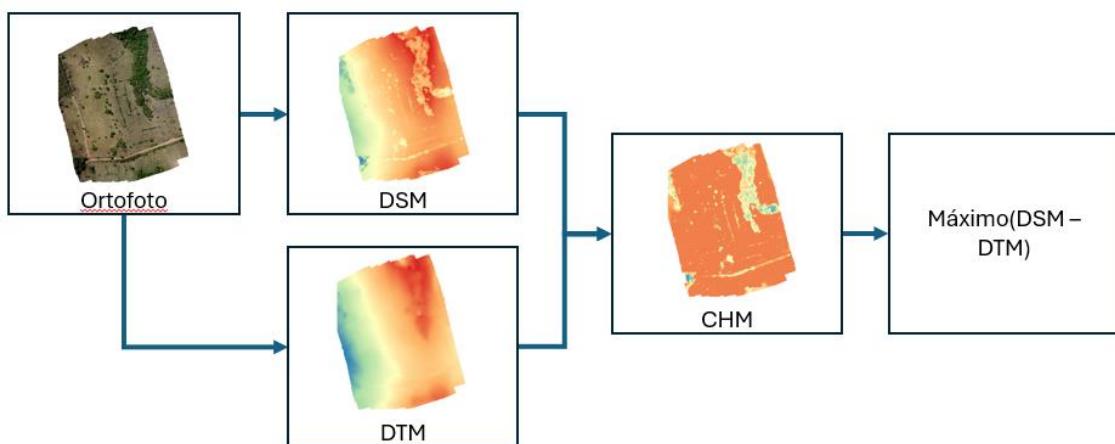
Para avaliar a precisão e a confiabilidade das estimativas de diâmetro de copa geradas pelo modelo de IA, foram realizadas análises estatísticas descritivas. Adicionalmente, gráficos de dispersão e boxplots foram utilizados para comparar visualmente as distribuições dos diâmetros reais e estimados, evidenciando padrões e possíveis diferenças entre os conjuntos de dados. A relação entre as variáveis foi avaliada por meio do teste de correlação de Pearson e a precisão do modelo foi mensurada pelo Erro Absoluto Médio (MAE). Além disso, foi realizada uma análise de outliers com base no método do intervalo interquartil (IQR).

3.5 Estimativa da altura das palmeiras

O Modelo Digital de Terreno (DTM) e Modelo Digital de Superfície (DSM) foram gerados como parte dos requisitos para estimar a altura das palmeiras macaúbas. A geração do Modelo de Altura da Copa (CHM) que representa o modelo de altura do dossel, conforme equação abaixo, foi realizada por meio do software de código aberto QGIS, usando a ferramenta calculadora Raster (Figura 222):

$$CHM = DSM - DTM$$

Figura 22 – Processo de estimativa da altura das palmeiras a partir de imagens



Fonte: Elaborado pelo autor (2025)

Por fim, foi desenvolvido um *script* para calcular a maior altura local entre os pontos delimitados pela copa das macaúbas. Neste contexto, a "maior altura local" corresponde à elevação máxima observada dentro dos limites da copa da macaúba, ou seja, o ponto de maior altura dentro da área definida pela copa da árvore na imagem. O código processa dados geoespaciais para calcular e transferir essas elevações máximas do Modelo de Altura da Copa (CHM) para a imagem ortofoto associada, realizando o ajuste das coordenadas. O resultado gerou uma tabela contendo as informações obtidas, as quais foram utilizadas para análise e comparação.

3.5.1 Análise estatística

Para avaliar a precisão e a confiabilidade das estimativas da altura das palmeiras, foram aplicadas análises estatísticas descritivas. A relação entre as variáveis foi analisada por meio do teste de correlação de Pearson, enquanto a precisão do modelo foi avaliada utilizando o Erro Absoluto Médio (MAE). Além disso, foi realizada uma análise de outliers com base no método do intervalo interquartil (IQR).

3.6 Estimativa de Acúmulo de Carbono

A estimativa do acúmulo de carbono para a planta de macaúba foi calculada a partir de equações alométricas usando o diâmetro da copa e altura (MOREIRA et al., 2025):

- a) Equação alométrica utilizando o diâmetro da copa:

$$\text{Carbono}(kg) = 0,000051 \cdot x^{8,308809},$$

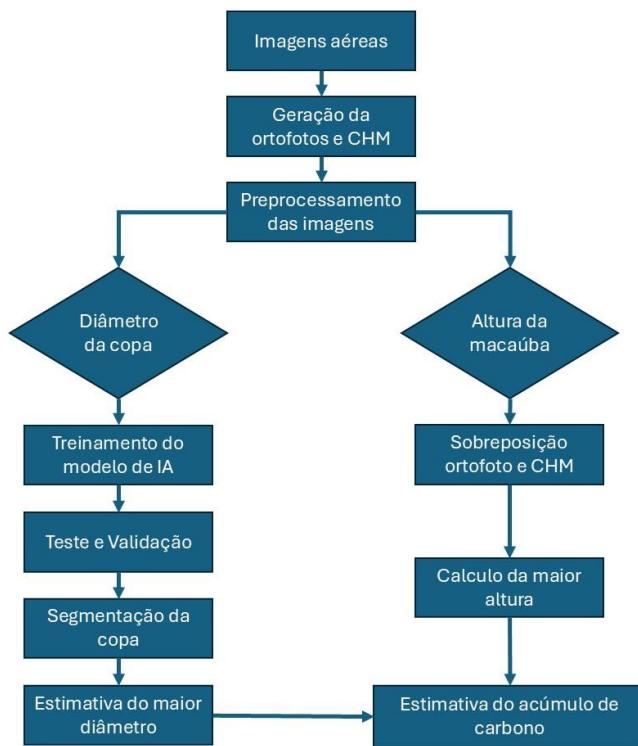
- b) Equação alométrica utilizando a altura da planta:

$$\text{Carbono}(kg) = 0,127580 \cdot x^{3,078920}$$

Foi realizada a estimativa do acúmulo de carbono em palmeiras de macaúba, utilizando imagens capturadas por VANTs tomando-se como base os parâmetros estruturais de diâmetro de copa e altura da planta. A estimativa do acúmulo de carbono baseada no diâmetro da copa

se deu em duas etapas (Figura 23): i) treinamento de um modelo de segmentação da copa das macaúbas usando técnicas de aprendizado profundo de máquina (*deep learning*) e; ii) desenvolvimento de um algoritmo de visão computacional para calcular o maior diâmetro da copa segmentada. Para a estimativa do acúmulo de carbono baseada na altura, foi desenvolvido um algoritmo para calcular a altura das plantas a partir de mapas de solo e de superfície, obtidos como resultado do processamento das imagens aéreas. O estudo é de natureza exploratória, visando realizar uma prova conceitual da abordagem proposta.

Figura 23 – Processo de estimativa de carbono por imagens aéreas



Fonte: Elaborada pelo autor (2025)

3.6.1 Análise estatística

Para a estimativa do carbono nas áreas onde os dados de campo não estavam acessíveis, foi utilizado o método de Monte Carlo, uma técnica estatística que permite simular diversas possibilidades e fornecer uma distribuição de resultados. Esse método foi empregado para modelar a incerteza associada às variáveis de entrada. As estimativas do carbono foram obtidas a partir das simulações, sendo apresentados os percentis P10, P50 (mediana) e P90, que representam, respectivamente, os valores correspondentes a 10%, 50% e 90% da

distribuição, fornecendo uma visão abrangente sobre o intervalo de possíveis resultados e a incerteza associada à estimativa do acúmulo de carbono. Quando expresso por hectare, o valor estimado de carbono foi obtido pela multiplicação do acúmulo de carbono individual pelo stand de plantas adotado no sistema de cultivo solteiro (400 plantas por hectare), considerando o espaçamento de 5×5 metros entre as palmeiras (MOTOIKE et al., 2013; UFV, 2020).

4 RESULTADOS E DISCUSSÃO

Os resultados obtidos neste trabalho estão apresentados em quatro etapas principais. Inicialmente, descreve-se o desempenho do modelo de inteligência artificial na segmentação das copas das árvores, seguido da análise das estimativas de diâmetro da copa e da comparação com os dados coletados em campo. Em seguida, aborda-se a estimativa da altura das árvores, destacando-se os métodos de validação com os dados empíricos coletados. Por fim, os resultados relacionados à estimativa do acúmulo de carbono são apresentados a partir do diâmetro da copa e da altura das plantas de macaúba.

4.1 Segmentação das copas das palmeiras com o uso de IA

O modelo YOLOv8s-seg, utilizado para segmentação das copas das macaúbas, foi composto por uma arquitetura de 195 camadas e 11.783.470 parâmetros treináveis. Este processo foi realizado em 100 épocas, i.e., a quantidade de vezes que o modelo passou por todo o conjunto de dados de treinamento, ajustando-se a cada passagem, com cerca de 2 horas de duração para cada tentativa de ajuste. A métrica de Precisão (P) foi de 0.946, ou seja, das áreas que o modelo previu como pertencentes às copas das árvores, 94,6% estavam corretas. O Recall (R) de 0.944 significa que 94,4% das copas verdadeiras das árvores foram corretamente identificadas pelo modelo. O mAP50 de 0.956 significa que, em média, o modelo obteve 95,6% de precisão ao avaliar as previsões com base em um limiar de 50% de sobreposição entre a previsão do modelo e a área real da copa da árvore. Finalmente, a classificação das áreas de origem das macaúbas alcançou a acurácia de 92,1%. A Figura 244 exemplifica o resultado do processo de segmentação por inteligência artificial em plantas de macaúba em diferentes áreas.

Figura 24 – Exemplos do resultado da segmentação das copas de macaúba, a partir do uso do modelo YOLO



Fonte: Elaborado pelo autor (2025)

Os resultados obtidos pelo modelo YOLOv8s-seg evidenciam sua eficiência na segmentação das copas das palmeiras de macaúba, alcançando desempenho semelhante ao reportado em estudos anteriores sobre a segmentação de oliveiras em imagens de drones, onde o YOLOv8 obteve Precisão: 0.898, Recall: 0.868 e mAP50: 0.919 (PROUSALIDIS et al., 2024). Da mesma forma, os resultados são comparáveis à segmentação de dendê (*Elaeis guineensis*), que atingiu precisão e recall de 98,5% e 98,6%, respectivamente (KWONG et al., 2024). Além disso, estudos sobre a classificação e segmentação de outras palmeiras na Amazônia, como *Attalea butyracea*, *Euterpe precatoria* e *Iriartea deltoidea*, relataram acurácia de $73,2 \pm 5,3\%$, $96,5 \pm 3,5\%$ e $87,8 \pm 4,7\%$, respectivamente (FERREIRA et al., 2020).

Esses resultados indicam que o modelo foi capaz de identificar e segmentar as copas de forma consistente, além de demonstrar o potencial da inteligência artificial para substituir métodos tradicionais de segmentação. Os achados ressaltam vantagens como maior agilidade, precisão e redução de erros. A eficácia do modelo também estabelece uma base para análises subsequentes, como a estimativa do diâmetro das copas, reforçando sua aplicabilidade em estudos de larga escala para extração de medidas a partir de imagens aéreas.

4.2 Estimativa do diâmetro da copa das plantas de macaúbas

A partir das imagens segmentadas pelo modelo de IA, foram extraídas as máscaras e calculado o maior diâmetro da copa de cada palmeira. A área de Unaí - MG foi utilizada para comparação entre a medida de campo e a estimada por este processo computacional. A análise estatística descritiva revelou que o diâmetro médio de copa real é de 4,03 metros, enquanto o diâmetro estimado é ligeiramente inferior, com média de 3,92 metros (Tabela 2). O desvio padrão do diâmetro real (0,52 metros) é um pouco maior do que o do diâmetro estimado (0,51 metros), sugerindo que, embora ambos os conjuntos de dados possuam variações semelhantes, o diâmetro real apresenta uma leve maior dispersão em torno da média.

Tabela 2 – Resultados do diâmetro da copa de plantas de macaúba, medido em campo e o estimado (em metros), em Unaí - MG

Estatística	Diâmetro Campo (m)	Diâmetro Estimado (m)
Média do diâmetro por planta (m)	4,03	3,92
Desvio Padrão do diâmetro por planta (m)	0,52	0,51
Mínimo	1,25	0,98
1º Quartil (Q1)	3,73	3,66
Mediana (Q2)	4,08	3,94
3º Quartil (Q3)	4,35	4,21
Máximo	5,85	5,83

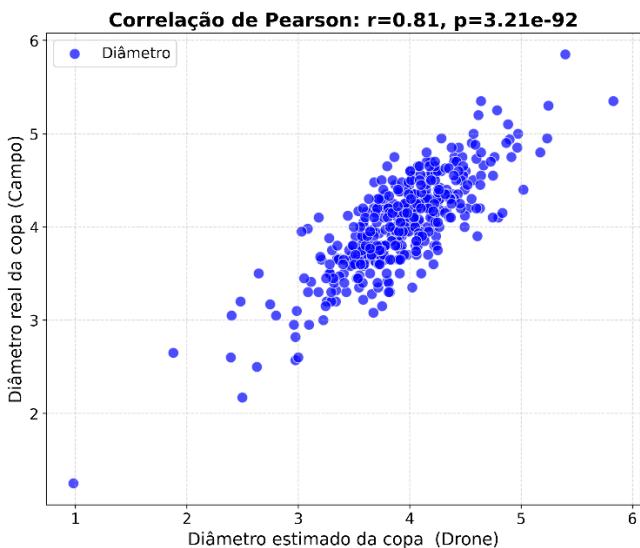
Obs.: Número de plantas medidas no campo e estimado = 389 plantas

O teste de correlação de Pearson revelou uma forte correlação positiva entre as duas variáveis ($r = 0,81$, $p < 0,001$), indicando uma relação significativa e confiável entre as estimativas do modelo e as medições reais de diâmetro de copa (Figura 255a). Além disso, a comparação visual das distribuições, através dos gráficos de dispersão e boxplots (Figura 255b), indica que ambas as medições seguem padrões semelhantes, com distribuições consistentes entre os dados reais e estimados.

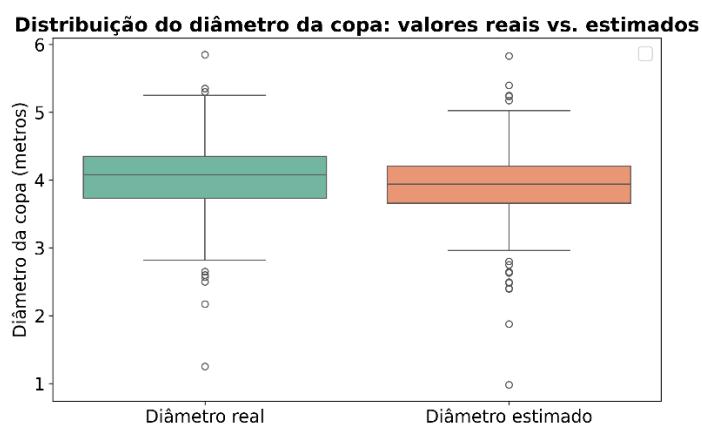
O modelo utilizado apresentou um erro médio de 0,26 metros (Erro Absoluto Médio, MAE), evidenciando uma boa precisão nas estimativas, com um erro relativamente pequeno em comparação aos valores reais (Figura 255c). Esse erro é inferior ao MAE de 0,73 metros e 0,80 metros encontrados em um estudo que estimou o diâmetro das copas de árvores das espécies *Picea abies* L., *Larix decidua* Mill., *Pinus sylvestris* L., *Larix decidua* Mill. e *Betula pendula* Roth. (PANAGIOTIDIS et al., 2017). Destaca-se que o erro obtido foi menor que o MAE de 0,68 metros registrado em mapeamentos realizados em parte das florestas do Cáspio, no Irã, que incluiu as espécies *Fagus orientalis* Lipsky, *Carpinus betulus* L., *Quercus castaneifolia* C.A.Mey., *Acer cappadocicum* Gled. Apesar disso, a correlação no estudo das florestas do Cáspio atingiu $r = 0,923$ (NASIRI et al., 2021). Estes resultados reforçam a precisão do modelo aplicado neste estudo, destacando seu potencial dentro do contexto específico de estimativas de diâmetro de copa de macaúba. Embora os estudos comparados envolvam espécies diferentes e condições ecológicas distintas, o menor erro médio observado sugere que o método adotado neste trabalho apresenta desempenho competitivo.

Figura 25 – Análises descritiva para o diâmetro da copa: a) Correção entre diâmetro real e estimado; b) Comparação entre diâmetro real e estimado; c) Erro absoluto médio (MAE)

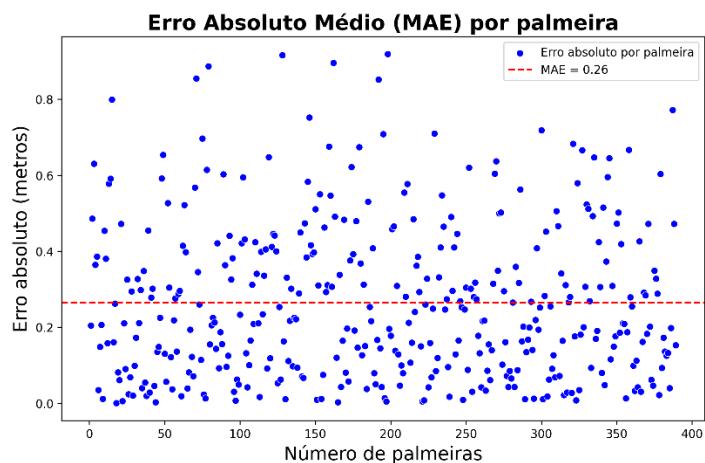
a)



b)



c)



Fonte: Elaborado pelo autor (2025)

4.3 Estimativa da altura das palmeiras de macaúba

A área de Unaí – MG também foi utilizada para comparação entre a medida altura das macaúbas no campo e a estimada pelos mapas obtidos pelo drone. A média das alturas reais é de 2,92 metros, enquanto a média das alturas calculadas pelo drone é de 2,33 metros, representando uma diferença média de aproximadamente 0,59 metros (Tabela 3). Essa diferença sugere que, de forma geral, as estimativas realizadas pelos drones são inferiores às medidas reais, principalmente as maiores alturas, quando são analisados os valores mínimos e máximos.

Tabela 3 – Resultados das alturas de plantas de macaúba, medidas no campo e o estimado (em metros), em Unaí – MG

Estatística	Altura Campo	Altura Estimada
Média por planta em metros	2,92	2,33
Desvio Padrão por (m)	0,61	0,64
Mínimo	0,53	0,41
1º Quartil (Q1)	2,65	1,97
Mediana (Q2)	2,90	2,35
3º Quartil (Q3)	3,25	2,72
Máximo	5,10	4,22

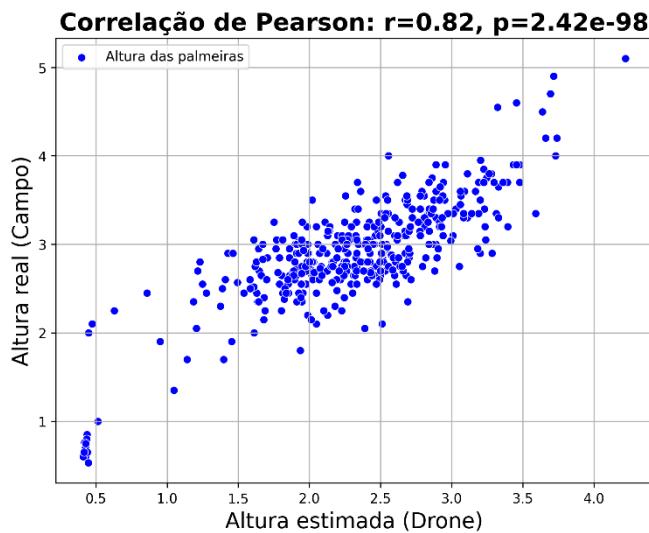
Obs.: Número de plantas medidas no campo e estimado = 406 plantas

O teste de correlação de Pearson indica uma correlação forte e estatisticamente significativa entre as alturas reais e as alturas calculadas pelo drone ($r = 0,82$, $p < 0,001$) (Figura 266a). Padrões semelhantes são observados nas medições reais e nos valores estimados, como evidenciado pelos gráficos de dispersão e boxplots (Figura 266b),

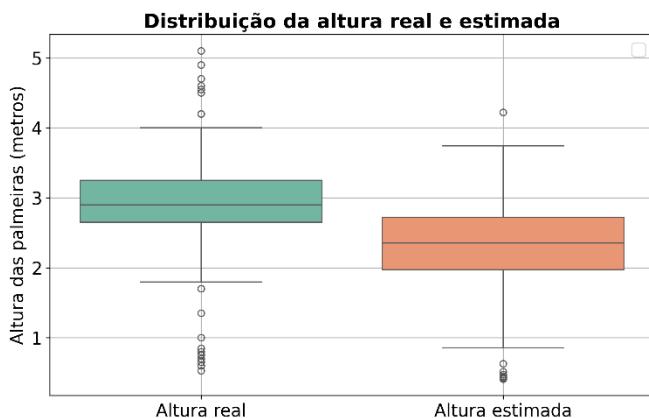
O MAE de 0,61 metros evidencia que o modelo apresenta bom desempenho para aplicações práticas, com erro menor do que estudos realizados em florestas do Cáspio, que reportaram um MAE de 2,95 metros (Figura 266c) (NASIRI et al., 2021). Além disso, esse valor é comparável aos resultados obtidos em plantações de oliveiras (*Olea europaea*), onde o erro médio ficou abaixo de 0,50 metros (KRAUSE et al., 2019).

Figura 26 – Análises descritiva para a altura da macaúba. a) Correção entre altura real e estimada; b) Comparação entre altura real e estimada; c) Erro absoluto médio (MAE)

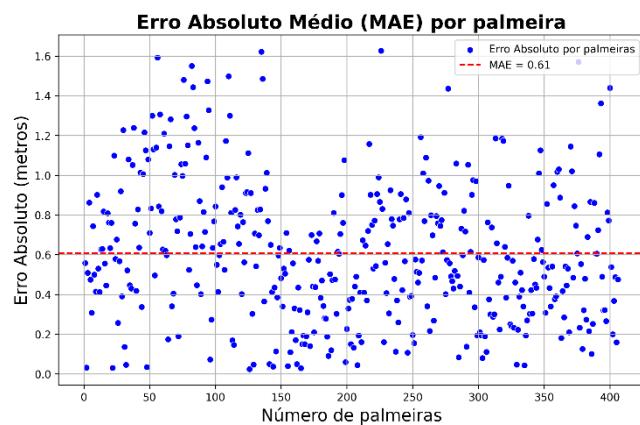
a)



b)



c)



Fonte: Elaborado pelo autor (2025)

4.4 Estimativa de acúmulo de carbono em plantas de macaúba

Na presente seção, estão apresentados os resultados do acúmulo de carbono da palmeira de macaúba utilizando de equações alométricas (MOREIRA et al., 2025), com base nas medições da copa, seguidos dos resultados obtidos utilizando a altura como variável.

Em seguida, apresenta-se uma comparação entre as duas metodologias adotadas para a estimativa de carbono.

4.4.1 Estimativa de acúmulo de carbono a partir do diâmetro da copa

A área de estudo de Unaí – MG foi escolhida para validar o método devido ao acesso aos dados de campo coletados em setembro de 2024, no mesmo mês em que as imagens aéreas foram obtidas.

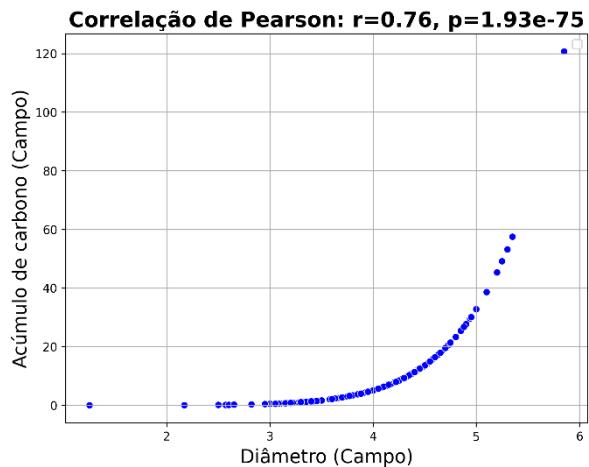
A correlação entre o diâmetro da copa e o acúmulo de carbono apresentou valores elevados, tanto para os dados coletados em campo ($r = 0,76$) (Figura 27a), quanto para os estimados a partir das imagens de drone ($r = 0,72$) (Figura 27b). Apesar do coeficiente de correlação de Pearson apresentar valor elevado, o gráfico de dispersão sugere que a relação entre o diâmetro da copa e o acúmulo de carbono indica a presença de uma tendência não linear nos dados, tanto para dados de campo quanto para dados estimados pelo drone.

A análise de correlação entre o acúmulo de carbono, calculado a partir dos dados reais e estimados baseadas no diâmetro obtido por drone, revelou uma correlação positiva forte de $R = 0,74$ (Figura 27c). Além disso, o valor-p baixo ($p < 0,001$) indica que essa correlação é altamente significativa, sugerindo que o diâmetro estimado pelo drone é uma variável confiável para prever o acúmulo de carbono na área estudada. A correlação ligeiramente menor nos dados estimados por drone pode ser atribuída a variações na precisão da segmentação da copa e às limitações na estimativa do diâmetro a partir das imagens aéreas.

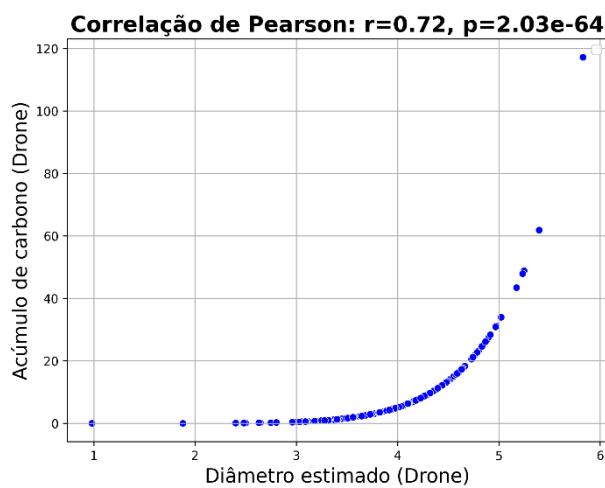
Pequenas distorções geométricas, sombras e diferenças na resolução espacial podem influenciar as medidas extraídas, impactando a correlação com os valores reais. No entanto, o valor de $r = 0,74$ demonstra que, mesmo com essas limitações, a abordagem baseada em imagens de drone mantém uma capacidade preditiva.

Figura 27 – Análises descritivas para a acúmulo de carbono (AC) por diâmetro de copa. a) Correlação entre AC e diâmetro no campo; b) Correlação entre AC e diâmetro estimado; e c) Correlação entre AC no campo e estimado

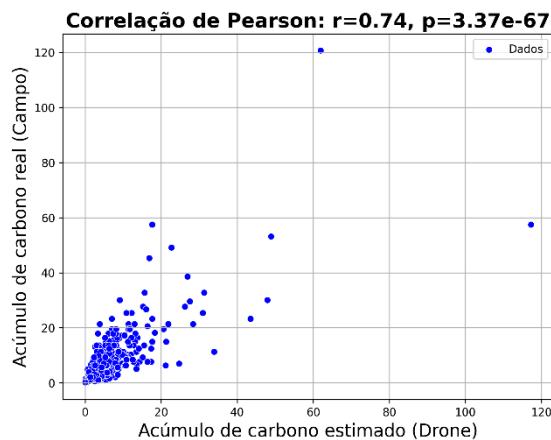
a)



b)



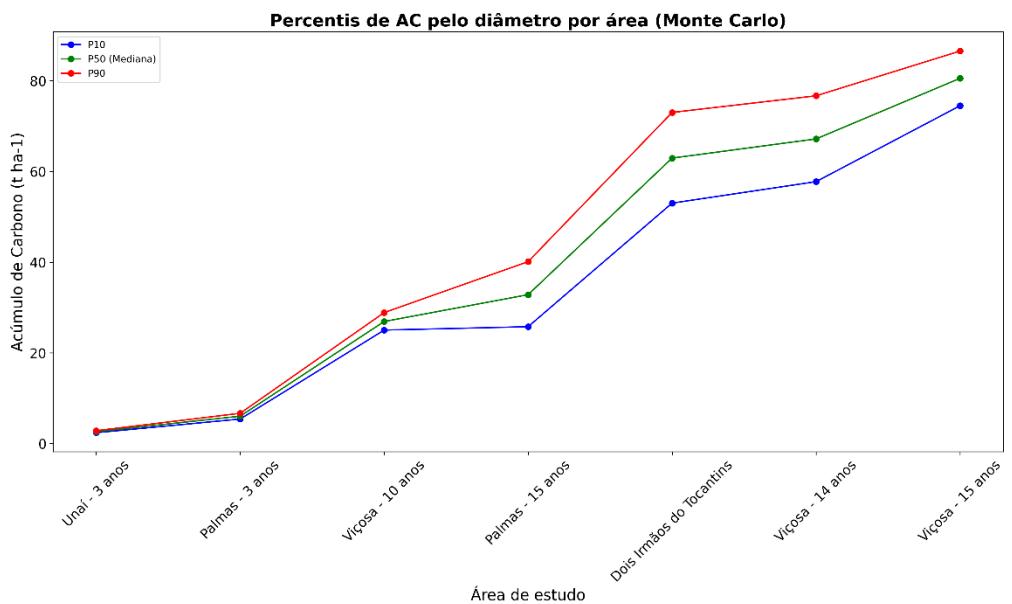
c)



Fonte: Elaborado pelo autor (2025)

Para a estimativa do carbono nas áreas em que não foi possível obter dados de campo, utilizou-se o método de Monte Carlo para modelar a incerteza associada às estimativas, considerando a variabilidade individual das árvores (média e desvio padrão em kg) e gerando distribuições probabilísticas (percentis P10, P50 e P90). Para este fim, consideramos uma estimativa para 400 plantas por hectare em sistema monocultivo. A Figura 28 apresenta o acúmulo de carbono nas diferentes áreas pelos percentis P10, P50, P90. As áreas que apresentaram maiores valores de P90 de carbono acumulado por hectare foram: Viçosa (15 e 14 anos), com 86,48 e 76,72 t ha⁻¹, respectivamente e a área de ocorrência natural em Dois Irmãos do Tocantins com 72,84 t ha⁻¹. Esta última apresentou a maior amplitude (P90 – P10) no estoque de carbono, o que pode ser atribuído à presença de plantas com diferentes idades e à heterogeneidade no diâmetro das copas, características esperadas em áreas de ocorrência natural de macaúbas.

Figura 28 – Percentis de carbono acumulado em palmeira macaúba utilizando visão computacional a partir do diâmetro da copa e por área, utilizando simulações Monte Carlo



Fonte: Elaborado pelo autor (2025)

Uma das áreas de Palmas que apresenta 15 anos de idade, teve um P90 (40,00 t ha⁻¹) inferior ao observado em outras regiões com idades semelhantes ou até menores. Por exemplo, Viçosa, com 14 anos, apresentou um acúmulo de 76,72 t ha⁻¹ (Figura 28).

Mesmo com esta exceção, no geral, os resultados evidenciam que o acúmulo de carbono está diretamente relacionado à idade das plantas, com incrementos significativos nas áreas mais antigas. Por exemplo, áreas com apenas 3 anos, como Unaí e Palmas, apresentam médias

de acúmulo de carbono por hectare entre 2,61 e 6,05 t ha⁻¹, respectivamente, enquanto áreas com 14 e 15 anos, como Viçosa, atingem valores de até 80,47 t ha⁻¹.

Tabela 4 – Acúmulo de carbono em palmeira macaúba obtido pelo diâmetro da copa definido por segmentação de imagem coletada por drone e simulado por Monte Carlo

Área	Idade (anos)	Média por planta (kg)	Desvio Padrão por planta (kg)	Estimativa para 400 plantas por hectare em sistema monocultivo			
				P10 (t ha ⁻¹)	P50 (t ha ⁻¹)	P90 (t ha ⁻¹)	Acúmulo de carbono (t ha ⁻¹)
Palmas	3	15,12	12,77	5,42	6,04	6,68	6,05
Palmas	15	82,12	88,75	25,63	32,88	40,00	32,85
Unaí	3	6,53	8,92	2,39	2,61	2,84	2,61
Viçosa	10	67,25	93,46	24,97	26,90	28,78	26,43
Viçosa	14	168,03	396,49	57,68	67,08	76,72	67,21
Viçosa	15	201,18	263,56	74,23	80,45	86,48	80,47
Dois Irmãos do Tocantins	-	157,57	198,91	53,25	63,23	72,84	63,03

4.4.2 Estimativa de acúmulo de carbono a partir da altura da palmeira

A área de estudo de Unaí – MG também foi utilizada para validar o método devido ao acesso aos dados de campo. Os resultados obtidos demonstram uma forte correlação entre as variáveis analisadas, evidenciando o potencial da altura das árvores como um preditor confiável do acúmulo de carbono para a palmeira macaúba na área estudada.

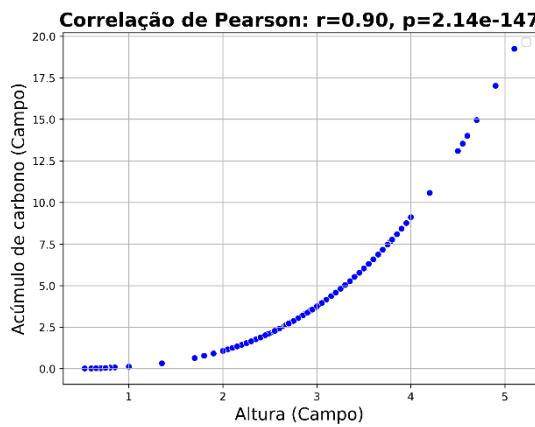
A correlação entre a altura das árvores e o acúmulo de carbono apresentou valores elevados, tanto para os dados coletados em campo ($r = 0,90$) (Figura 29a) quanto para aqueles estimados por drone ($r = 0,91$) (Figura 29b).

A correlação de 0,80 entre o acúmulo de carbono medido em campo e o estimado a partir da altura das macaúbas indica que a abordagem baseada em sensoriamento remoto apresenta boa precisão na predição dos estoques de carbono (Figura 29c).

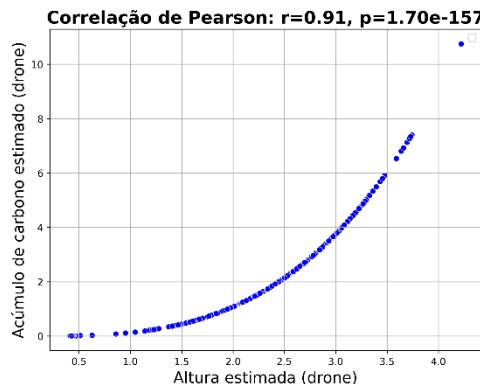
Isso reforça a premissa de que a altura é uma variável altamente representativa do estoque de biomassa e carbono em espécies como a macaúba, corroborando estudos prévios sobre alometria de palmeiras (MOREIRA et al., 2025).

Figura 29 – Análises descritivas acúmulo de carbono (AC) determinado pela altura das palmeiras. a) Correlação entre altura real e AC; b) Correlação entre altura estimada e AC; c) Correlação entre AC real e estimado com base na altura da planta

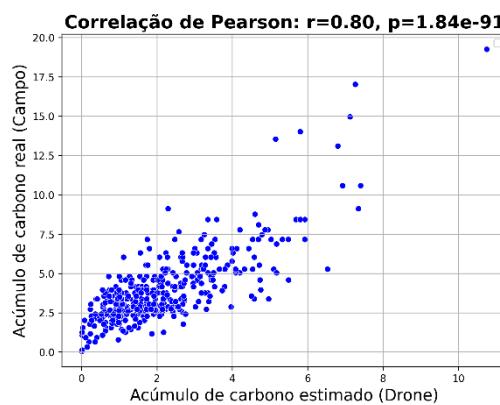
a)



b)



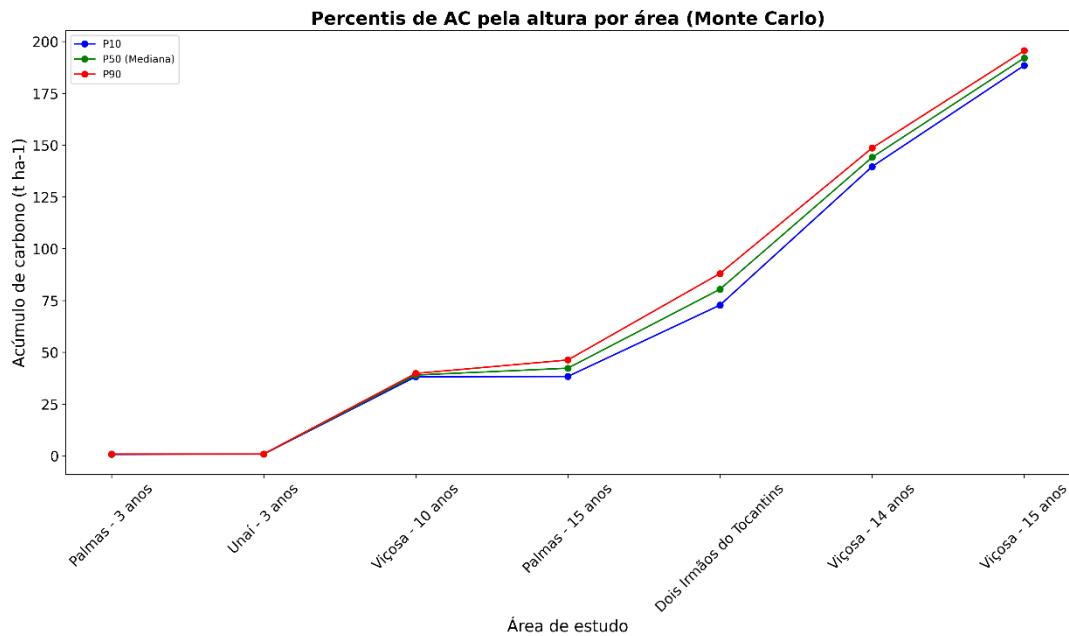
c)



Fonte: Elaborado pelo autor (2025)

A Figura 30 apresenta o acúmulo de carbono nas demais áreas do estudo usando as simulações de Monte Carlo.

Figura 30 – Percentis de carbono acumulado a partir da altura e por área usando simulações Monte Carlo



Fonte: Elaborado pelo autor (2025)

Os valores médios de carbono acumulado variam significativamente entre as áreas, oscilando entre $0,88 \text{ t ha}^{-1}$ em Palmas – 3 anos e $195,57 \text{ t ha}^{-1}$ em Viçosa – 15 anos. Viçosa (15 e 14 anos) apresentam valores altos de desvio (165,90 e 162,21 kg), indicando grande variabilidade entre indivíduos, assim como na área de ocorrência natural em Dois Irmão do Tocantins com desvio padrão de 156,86 kg (Tabela 5). A relação entre a idade da vegetação e o acúmulo de carbono é percebido. Áreas com plantios mais jovens, como Palmas e Unaí (3 anos), apresentam estoques menores, enquanto regiões com vegetação mais desenvolvida, como Viçosa (14 e 15 anos), registram valores significativamente mais altos. Esse padrão reforça a ideia de que a biomassa e o carbono aumentam ao longo do tempo, atingindo um pico antes de estabilizar, conforme demonstrado em estudos sobre o crescimento de palmeiras macaúba e outras espécies nativas (BARLETO, 2011, DÍAZ et al., 2021).

Tabela 5 – Acúmulo de carbono em palmeira macaúba estimada pela altura da planta obtida por ferramentas computacionais e simulado por Monte Carlo

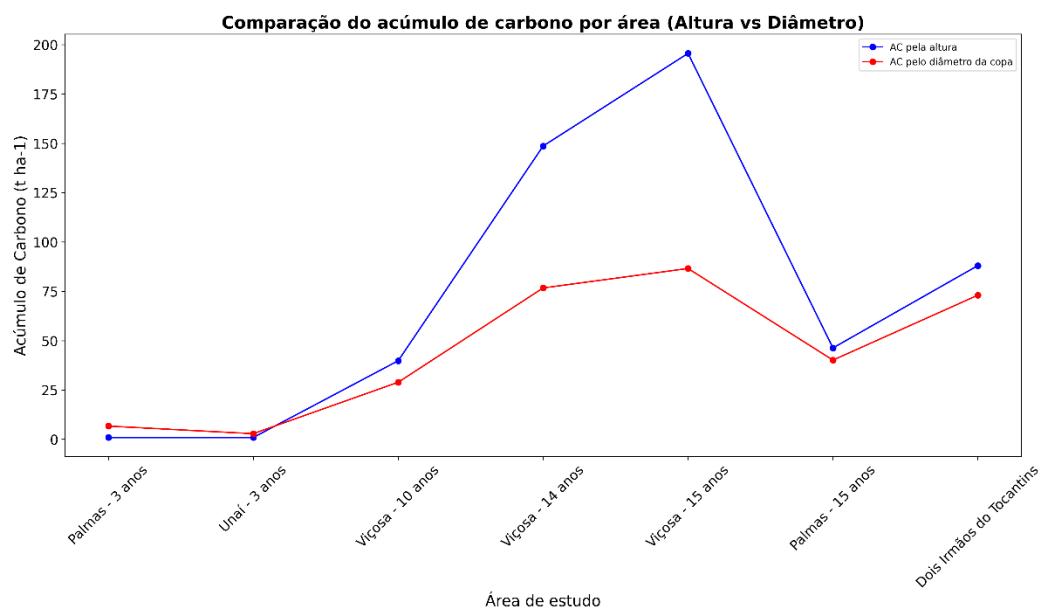
Área	Idade (anos)	Média por planta (kg)	Desvio Padrão por planta (kg)	Estimativa para 400 plantas por hectare em sistema monocultivo			
				P10 (t ha ⁻¹)	P50 (t ha ⁻¹)	P90 (t ha ⁻¹)	Acúmulo de carbono (t ha ⁻¹)
Palmas	3	1,96	2,48	0,69	0,79	0,88	0,79
Palmas	15	105,64	55,56	38,28	42,27	46,22	42,26
Unaí	3	2,11	1,52	0,81	0,85	0,88	0,85
Viçosa	10	97,48	34,96	38,20	38,99	39,77	38,99
Viçosa	14	360,31	162,21	139,64	144,19	148,56	144,12
Viçosa	15	480,04	165,90	188,44	192,02	195,57	192,02
Dois Irmãos do Tocantins	-	201,03	156,86	72,84	80,50	88,22	80,41

4.5 Comparação entre o acúmulo de carbono pelo diâmetro da copa e altura da palmeira macaúba

O gráfico de linha compara o acúmulo de carbono nas diferentes áreas de estudo, considerando duas abordagens distintas para estimar o carbono: por diâmetro de copa e por altura (Figura 31). Cada linha do gráfico representa uma área específica, e os valores de acúmulo de carbono foram calculados utilizando os dados obtidos por cada metodologia. Os resultados obtidos sugerem que, em plantas mais jovens até oito anos (Palmas e Unaí), o diâmetro da copa apresentou um maior valor na estimativa do acúmulo de carbono (AC), enquanto, em plantas mais maduras (>10 anos), a altura foi um indicador mais robusto, em concordância com os achados de MOREIRA, (2019) e MOREIRA et al., (2025). Uma possível explicação para essa diferença está na precisão das estimativas de altura a partir de Modelos Digitais de Superfície (DSM) e Modelos Digitais de Terreno (DTM), que podem apresentar maior margem de erro em vegetação mais baixa dependendo do GSD e altura do voo. Como mencionado no estudo de VACCA; VECCHI, (2024), a precisão melhorou à medida que a altitude de voo diminuía (menor GSD), com a menor altitude (30 m de voo) apresentando resultados mais promissores. Além disso, outras medidas podem ser adotadas para melhorar a precisão das estimativas, como o aumento da resolução dos mapas de relevo, a calibração rigorosa do sistema de georreferenciamento por meio do uso de pontos de controle no solo (GCPs) e RTK (*Real-Time Kinematic*), realização de múltiplos voos sobre a

mesma área, o que possibilita a obtenção de medidas adicionais e contribui para a redução de erros e maior confiabilidade nas estimativas e adoção de outros sensores LiDAR (*Light Detection and Ranging*). Também, deve ser levada em consideração o próprio desenvolvimento da planta de macaúba, que aparentemente estabiliza o diâmetro da copa após um determinado tempo de desenvolvimento, contudo segue aumentando em altura ao longo dos anos.

Figura 31 – Comparação entre acúmulo de carbono em macaúba por altura e diâmetro da copa por área, obtidos por ferramentas computacionais



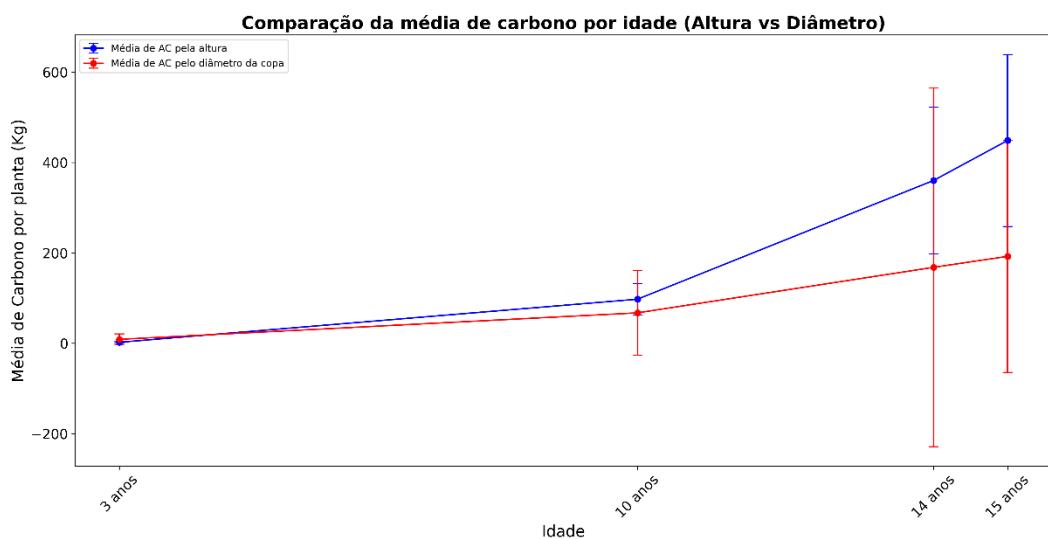
Fonte: Elaborado pelo autor (2025)

A Figura 32 demonstra o acúmulo de carbono em macaúbas ao longo do tempo, utilizando como variáveis de estimativa o diâmetro da copa e a altura. Este tipo de análise permite compreender o crescimento da planta e sua contribuição para o sequestro de carbono em diferentes estágios de desenvolvimento. Pelo diâmetro da copa, observa-se um aumento progressivo na média do acúmulo de carbono (AC) conforme a idade da planta. Aos 3 anos, a média do AC por planta baseada no diâmetro da copa é de $8,54 \text{ t ha}^{-1}$, enquanto aos 15 anos atinge $192,30 \text{ t ha}^{-1}$, evidenciando um aumento significativo com a idade. O desvio padrão também cresce, indicando maior variabilidade no acúmulo de carbono à medida que as plantas se avançam no seu crescimento vegetativo, provavelmente devido a diferenças individuais no crescimento e na capacidade de armazenamento de biomassa (BARLETO, 2011). Entretanto, aos três anos, o aumento no AC ocorre de forma relativamente moderada, com um crescimento mais expressivo a partir dos 10 anos, quando a média ultrapassa $67,24 \text{ t}$

ha⁻¹. Aos 14 e 15 anos, o AC médio continua crescendo, mas o aumento no desvio padrão é considerável, possivelmente refletindo variações no porte e na arquitetura das copas entre diferentes indivíduos.

Quando o acúmulo de carbono é estimado pela altura das macaúbas, o crescimento contínuo ao longo do tempo também é percebido. Aos 3 anos, a média do AC baseada na altura é de 2,07 t ha⁻¹, enquanto aos 15 anos chega a 448,90 t ha⁻¹, um valor significativamente maior do que o registrado pelo diâmetro da copa. Isso reforça, novamente, que a altura se coloca como um indicativo mais sensível para estimar o acúmulo de carbono, principalmente em idades mais avançadas. A variação no desvio padrão da altura segue um comportamento semelhante ao observado no diâmetro da copa. Aos 14 anos, o desvio padrão sobe para 162,44 t ha⁻¹, e aos 15 anos chega a 190,37 t ha⁻¹, indicando grande heterogeneidade nas alturas das plantas nessa fase de desenvolvimento.

Figura 32 – Comparação da média por planta de carbono acumulado em plantas de macaúba por idade, obtido por imagens de drones e ferramentas computacionais



Fonte: Elaborado pelo autor (2025)

Os resultados indicam que tanto a altura quanto o diâmetro da copa são bons preditores do acúmulo de carbono em macaúbas, sendo a altura o parâmetro mais aderente em estágios mais avançados do desenvolvimento da planta. Portanto, a variável altura da planta parece ser a variável mais indicada para a estimativa de AC ao longo de todo o ciclo da palmeira macaúba. Por outro lado, dependendo da aplicação, a estimativa do acúmulo de carbono a partir do diâmetro de copa pode ser uma alternativa quando não houver possibilidade de obtenção dos mapas de MDT e MDS, necessários para obtenção da altura.

5 CONCLUSÃO

O presente estudo demonstrou a viabilidade do uso de imagens de drones e inteligência artificial para estimar o acúmulo de carbono em palmeiras macaúba a partir de variáveis dendrométricas, com destaque para a altura das árvores como preditor primário. A abordagem proposta gerou estimativas de carbono consistentes com os dados de campo, indicando potencial para reduzir a necessidade de medições manuais e aumentar a eficiência na coleta de dados em campo.

Os resultados indicaram que a correlação entre a altura estimada por drone e o acúmulo de carbono foi ligeiramente superior à correlação observada para o diâmetro da copa, tendo a altura da planta um indicador mais robusto para modelagem da biomassa. No entanto, desafios técnicos, como variações na estimativa da altura em plantas jovens devido às limitações do Modelo Digital de Superfície (DSM) e do Modelo Digital de Terreno (DTM), foram identificados como possíveis fontes de erro.

Futuras melhorias na segmentação e na modelagem da relação entre o diâmetro e o carbono, como a incorporação de variáveis adicionais (área da copa, densidade da vegetação, entre outras), podem aumentar ainda mais a precisão das estimativas. Estratégias para mitigar essas imprecisões incluem o uso de sensores LiDAR, câmeras de maior resolução, correção por RTK e a realização de múltiplos voos sobre a mesma área.

Importante destacar que um diferencial deste estudo é a capacidade de realizar a análise do acúmulo de carbono de forma individualizada, planta a planta, em contraste com métodos tradicionais baseados em amostragem. Essa abordagem proporciona uma medida mais realista e precisa, capturando a variabilidade espacial da vegetação e permitindo uma gestão mais eficiente e detalhada dos recursos naturais. Tais avanços têm potencial para subsidiar políticas públicas voltadas à conservação, ao uso sustentável da macaúba e ao monitoramento de créditos de carbono em sistemas produtivos.

Dessa forma, a metodologia empregada apresenta potencial para aprimorar inventários florestais, monitoramento de carbono e práticas sustentáveis de manejo da macaúba. Estudos futuros podem explorar a integração de múltiplos sensores e técnicas avançadas de aprendizado de máquina para refinar ainda mais as estimativas e expandir a aplicabilidade da abordagem para diferentes ecossistemas e espécies florestais.

REFERÊNCIAS

AGISOFT. **Agisoft PhotoScan Professional**, jun. 2019. Disponível em: <https://www.agisoftmetashape.com/>. Acesso em: 10 abr. 2025.

BALLARD, D. H.; BROWN, C. M. **Computer vision**. 1. Ed. Prentice Hall Professional Technical Reference, Memphis. jan. 1982. 544p.

BALESTRA, M. et al. UAV-Spherical data fusion approach to estimate individual tree carbon stock for urban green planning and management. **Remote Sensing**, Besel, v. 16, n. 12, jun. 2024. DOI 10.3390/rs16122110.

BARLETO, E. A. **Respostas Ecofisiológicas de Acrocomia aculeata (Jacquin) Loddies ex Martius ao déficit hídrico sazonal e à disponibilidade de nutrientes**. 2011. 135f. Dissertação (Mestrado) – Universidade de Brasília, Brasília, DF.

BASYUNI, M. et al. Aboveground biomass and carbon stock estimation using UAV photogrammetry in Indonesian mangroves and other competing land uses. **Ecological Informatics**, Amsterdã, v. 77, nov. 2023. DOI 10.1016/j.ecoinf.2023.102227.

BEJANI, M. M.; GHATEE, M. A systematic review on overfitting control in shallow and deep neural networks. **Artificial Intelligence Review**, Berlim, v. 54, n. 8, p. 6391–6438, dez. 2021. DOI 10.1007/s10462-021-09975-1.

BRIANEZI, D. et al. Equações alométricas para estimativa de carbono em árvores de uma área urbana em Viçosa-MG. **Revista Árvore**, Viçosa, v 37, p. 1073-1081, dez. 2013. DOI <https://doi.org/10.1590/S0100-67622013000600009>.

CARDOSO, A. et al. Opportunities and challenges for sustainable production of *A. aculeata* through agroforestry systems. **Industrial Crops and Products**, Amsterdã, v. 107, n. p. 573–580, abr. 2017. DOI /10.1016/j.indcrop.2017.04.023.

CARDOSO, A. N. et al. Extrativismo da macaúba na região do Cariri Cearense: comercialização e oportunidades. **Brazilian Journal of Development**, São José dos Pinhais, v. 6, n. 5, p. 25261–25279, jul. 2020. DOI 10.34117/bjdv6n5-108.

CARRERA, R. A. B. **Caracterização de co-produtos e subprodutos protéicos da indústria do biodiesel para alimentação de ruminantes**. 2010. 30 f. Dissertação (Mestrado em Zootecnia) - Faculdade de Zootecnia. Universidade Federal de Viçosa, Viçosa. 2010.

CARVALHO, K. J.; SOUZA, A. L.; MACHADO, C. C. Macaúba - *Acrocomia aculeata* (Jacq.) Lodd. ex Mart.: ecologia, manejo, silvicultura e tecnologia da macaúba. **Pólo de Excelência em Florestas**, p. 38, set. 2011.

CARVALHO, P. E. R. **Espécies Arbóreas Brasileiras**. 2.ed. Colombo: Embrapa Florestas - Circular Técnica, 2008. 637 p.

CASTRO JORGE, L. A.; INAMASU, R. Y. Uso de veículos aéreos não tripulados (VANT) em agricultura de precisão. **Agricultura de precisão: resultados de um novo olhar.**, p. 109–134, 2014.

COLOMBO, C. A. et al. Macauba: a promising tropical palm for the production of vegetable oil. **OCL - Oilseeds and fats, Crops and Lipids**, Les Ulis, v. 25, n. 1, fev. 2018. DOI 10.1051/ocl/2017038.

COSTA, C. F. DA. **Solos e outros fatores ambientais associados à diversidade fenotípica de macaúbas no estado de São Paulo.** 2009. 54 f. Dissertação (Mestrado em Gestão dos Recursos Agroambientais). Instituto Agronômico de Campinas, Campinas. 2009.

CROCOMO, O. J.; MELO, M. *Acrocomia* species (Macauba Palm). Em: Bajaj, Y.P.S. (eds) **Trees IV. Biotechnology in Agriculture and Forestry**. Berlin: Springer, Berlin, Heidelberg, 1996. v. 35p. 3–17.

DAHY, B.; ISSA, S.; SALEOUS, N. Geo-spatial modelling of carbon stock assessment of date palm at different age stages: An integrated approach of fieldwork, remote sensing and GIS. **Ecological Modelling**, [S.I.], v. 481, jul. 2023. DOI 10.1016/j.ecolmodel.2023.110377.

DÍAZ, B.G. et al. Genome-wide SNP analysis to assess the genetic population structure and diversity of *Acrocomia* species. **PLoS One**, v. 16, n. 7, p. e0241025, 2021. DOI 10.1371/journal.pone.0241025.

DRAEYER, B; STRECHA, C. White paper: How accurate are UAV surveying methods. **Pix4D White Paper**, v. 4, 2014.

DRONEDEPLOY. **DroneDeploy**. Disponível em: <https://www.dronedeploy.com/>. Acesso em: 27 abr. 2025.

EMBRAPA. **Macaúba conta agora com Zoneamento Agrícola de Risco Climático.** 2024. Disponível em: <<https://www.embrapa.br/busca-de-noticias/-/noticia/86749208/macauba-conta-agora-com-zoneamento-agricola-de-risco-climatico>>. Acesso em: 15 abr. 2025

FADIL, S. et al. An Integrating Framework for Biomass and Carbon Stock Spatialization and Dynamics Assessment Using Unmanned Aerial Vehicle LiDAR (LiDAR UAV) Data, Landsat Imagery, and Forest Survey Data in the Mediterranean Cork Oak Forest of Maamora. **Land**, [S.I.], v. 13, n. 5, mai. 2024. DOI 10.3390/land13050688.

FADIL, S. et al. Modeling and spatialization of biomass and carbon stock using unmanned Aerial Vehicle Lidar (Lidar-UAV) metrics and forest inventory in cork oak forest of Maamora. **Regional Science Policy and Practice**, Azores, v. 16, n. 11, nov. 2024. DOI 10.1016/j.rspp.2024.100127.

FÁVARO, S. P.; ROCHA, J. D. A nova cadeia produtiva da macaúba para bioproductos e descarbonização. **Série Documentos Embrapa Agroenergia**, p. 31, dez. 2022.

FERNANDO, C. et al. Sensoriamento remoto. Em: **Coleção 500 Perguntas, 500 Respostas**, Embrapa Territorial, 2014. p. 61–79.

FERREIRA, E. A. B. et al. **Estimativa de sequestro de carbono numa população espontânea de palmeiras macaúba.** 8º Congresso internacional de bioenergia São Paulo – SP, 2013. Disponível em: <<https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1001917/1/189EloisaFerreira137.pdf>>. Acesso em: 15 mar. 2025

FERREIRA, M. P. et al. Individual tree detection and species classification of Amazonian palms using UAV images and deep learning. **Forest Ecology and Management**, [S.I.], v. 475, n. July, p. 118397, jul. 2020. DOI 10.1016/j.foreco.2020.118397.

FONSECA, C. K. L. et al. Use of RGB drone sensors to estimate vegetation biomass in a semiarid region: uso de sensores RGB em drones para estimar biomassa vegetal em uma região semiárida. **Geosciences**, Rio Claro, n. 4, p. 527–536, dez. 2024. DOI 10.5016/geociencias. v43i4.18383.

FORSYTH, D. A.; PONCE, J. **Computer vision: a modern approach**. 2. Ed. Prentice Hall Professional Technical Reference, 2002. 800p.

GAMON, J. A. et al. Remote sensing of the xanthophyll cycle and chlorophyll fluorescence in sunflower leaves and canopies. **Oecologia**, [S.I.], v. 85, p. 1–7, nov. 1990.

GARCIA-GARCIA, A. et al. A review on deep learning techniques applied to semantic segmentation. **arXiv preprint arXiv:1704.06857**, abr. 2017, DOI 10.48550/arXiv.1704.06857.

GEOSENSORI. **O que é ortofoto?** jun. 2019. Disponível em: <<https://www.geosensori.com.br/2019/06/10/o-que-e-ortofoto>>. Acesso em: 10 abr. 2025.

GONZÁLEZ-JORGE, H. et al. Unmanned aerial systems for civil applications: A review. **Drones**, v. 1, n. 1, p. 1–19, 2017.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning** English version. p. 800, 2017.

GUTH, P. L. et al. Digital elevation models: Terminology and definitions. **Remote Sensing**, v. 13, n. 18, 1 set. 2021.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, [S.I.], v. 25, n. 3, p. 295–309, ago. 1988. DOI 10.1016/0034-4257(88)90106-X.

HUSSAIN, M. YOLO. v1 to v8: unveiling each variant-A comprehensive review of YOLO. **IEEE Access**, Ontario, v. 12, p. 42816–42833, jan. 2024. DOI 10.1109/ACCESS.2024.3378568.

IDOETA, I. V. **Metodologia de elaboração automatizada de modelo digital de elevação e ortofoto em média e pequena escala.** 2007. 211 f. Tese (Doutorado em Engenharia), Escola Politécnica da Universidade de São Paulo, São Paulo, 2007.

IMAFLORA, I. Carbon sequestration of inocos macauba plantations in brazil. p. 1–54, 2020.

IZBICKI, R.; SANTOS, T. M. **Aprendizado de máquina: uma abordagem estatística.** 1 ed. Editora UICLAP. 270 f. 2020.

JENSEN, John R. **Sensoriamento remoto do ambiente:** uma perspectiva em recursos terrestres. 2. ed. Parêntese Editora, São José dos Campos, SP, 598 f. 2009.

KRAUSE, S. et al. UAV-based photogrammetric tree height measurement for intensive forest monitoring. **Remote Sensing**, Basel, v. 11, n. 7, 1 abr. 2019. DOI 10.3390/rs11070758.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. ImageNet classification with deep convolutional neural networks. **Advances in neural information processing systems**, v. 5, p. 9, 2017.

KWONG, Q. B. et al. Enhancing oil palm segmentation model with GAN-based augmentation. **Journal of Big Data**, [S.I.], v. 11, n. 1, set. 2024. DOI 10.1186/s40537-024-00990-x.

LAREKENG, S. H. et al. Estimation of mangrove carbon stocks using unmanned aerial vehicle over coastal vegetation. **Global Journal of Environmental Science and Management**, v. 10, n. 3, p. 1133–1150, 1 jun. 2024.

LIU, Y. et al. Advances and challenges of carbon storage estimation in tea plantation. **Ecological Informatics**, [S.I.], v. 81, 1 jul. 2024. DOI 10.1016/j.ecoinf.2024.102616.

MA, Y. et al. Background augmentation generative adversarial networks (BAGANs): Effective data generation based on GAN-augmented 3D synthesizing. **Symmetry**, v. 10, n. 12, 2018.

MATSUSHITA, B. et al. Sensitivity of the Enhanced Vegetation Index (EVI) and Normalized Difference Vegetation Index (NDVI) to topographic effects: a case study in high-density cypress forest. **Sensors**, Basel, v. 7, n. 11, p. 2636–2651, ago. 2007. DOI 10.3390/s7112636.

MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre Aprendizado de Máquina. **Sistemas inteligentes: fundamentos e aplicações**, p. 89–114, 2003.

MORAES, E. C. DE. Capítulo 1 fundamentos de sensoriamento remoto. Em: São José dos campos: 2002. p. 1–7.

MOREIRA, M. A. **Sensoriamento remoto e metodologia de aplicação.** 1. ed. Editora INPE, São José dos Campos, SP, 250 f. 2001.

MOREIRA, S. L. S. **Acúmulo de biomassa e carbono em cultivo de macaúba (Acrocomia aculeata).** 2019. 57 f. Tese (Doutorado em Meteorologia Aplicada), Universidade Federal de Viçosa, 2019.

MOREIRA, S. L. S. et al. Carbon accumulation in the soil and biomass of macauba palm commercial plantations. **Biomass and Bioenergy**, [S.I.], v. 190, nov. 2024. DOI 10.1016/j.biombioe.2024.107384.

MOREIRA, S. L. S. et al. Carbon accumulation in cultivated macauba trees can be estimated and projected using allometric equations. **Industrial Crops and Products**, Amsterdã, v. 226, abr. 2025. DOI 10.1016/j.indcrop.2025.120682.

MOTOIKE, S. Y. et al. **A cultura da macaúba:** implantação e manejo de cultivos racionais. 1. ed. Editora UFV, Viçosa, MG, 61 f. 2013.

MUTHUKRISHNAN, N. et al. Brief History of Artificial Intelligence. **Neuroimaging Clinics of North America**, v. 30, n. 4, p. 393–399, 2020.

NASCETTI, A. et al. BioMassters: a benchmark dataset for forest biomass estimation using multi-modal satellite time series. **Advances in Neural Information Processing Systems**, v. 36, p. 20409–20420, set. 2023.

NASIRI, V. et al. Unmanned aerial vehicles (Uav)-based canopy height modeling under leaf-on and leaf-off conditions for determining tree height and crown diameter (case study: Hyrcanian mixed forest). **Canadian Journal of Forest Research**, Ottawa, v. 51, n. 7, p. 962–971, jun. 2021. DOI 10.1139/cjfr-2020-0125.

NAVARRO-DÍAZ, H. J. et al. Macauba oil as an alternative feedstock for biodiesel: Characterization and ester conversion by the supercritical method. **Journal of Supercritical Fluids**, v. 93, p. 130–137, 2014.

NÓBREGA, D. G.; MOURA, S. R. **Mapeamento planialtimétrico para estudo de viabilidade na implantação de reservatórios de água na zona sul de Porto Alegre utilizando métodos fotogramétricos**. 2013. 100 p. Trabalho de Conclusão de Curso (Engenharia Cartográfica) - Departamento de Geodésia do Instituto de Geociências, Porto Alegre: Universidade Federal do Rio Grande do Sul, 2023.

NUÑEZ, C. X. L. et al. Calculation of carbon sequestered through remote sensing in a metropolitan park in the city of Quito, Ecuador. **Sapienza**, v. 5, n. 1, 15 jan. 2024.

OLIVEIRA, J. R. **Sistemas de aeronaves remotamente pilotadas para estimar estoque de carbono em florestas regeneradas:** estudo de caso do litoral do Espírito Santo. 2023. 87 p. Trabalho de Conclusão de Curso (Engenharia Sanitária e Ambiental) - Instituto Federal do Espírito Santo, Vitória: Instituto Federal do Espírito Santo, 2023.

OPENDRONEMAP. OpenDroneMap. Disponível em: <https://www.opendronemap.org/>. Acesso em: 17 abr. 2025.

PANAGIOTIDIS, D. et al. Determining tree height and crown diameter from high-resolution UAV imagery. **International Journal of Remote Sensing**, [S.l.], v. 38, n. 8–10, p. 2392–2410, mai. 2017. DOI 10.1080/01431161.2016.1264028.

PENG, A. S. et al. Design of a Ground Sampling Distance Graphical User Interface for an Unmanned Aerial Vehicle System. **2019 53rd Annual Conference on Information Sciences and Systems, CISS 2019**, p. 1–6, 2019.

PETTORELLI, N. et al. Using the satellite-derived NDVI to assess ecological responses to environmental change. **Trends in Ecology and Evolution**, [S.I.], v. 20, n. 9, p. 503–510, set. 2005. DOI 10.1016/j.tree.2005.05.011.

PIX4D. **Pix4Dmapper**. jun. 2024. Disponível em: <https://www.pix4d.com/product/pix4dmapper>. Acesso em: 10 abr. 2025.

PLATH, M. et al. A novel bioenergy feedstock in Latin America? Cultivation potential of *Acrocomia aculeata* under current and future climate conditions. **Biomass and Bioenergy**, Kidlington, v. 91, p. 186–195, abr. 2016. DOI 10.1016/j.biombioe.2016.04.009.

PONTI, M. A. et al. Everything You Wanted to Know about Deep Learning for Computer Vision but Were Afraid to Ask. **Proceedings - 2017 30th SIBGRAPI Conference on Graphics, Patterns and Images Tutorials SIBGRAPI-T 2017**, v. 2018- Janua, p. 17–41, 2017.

PROUSALIDIS, K. et al. Olive tree segmentation from UAV imagery. **Drones**, [S.I.], v. 8, n. 8, ago. 2024. DOI 10.3390/drones8080408.

REDWEIK, P. **Fotogrametria aérea**. Faculdade de Ciências da Universidade de Lisboa, 2007.

RIBEIRO, R. J. DA C. et al. Beyond climate villains: estimating carbon storage in urban parks using high-resolution imagery combined with field sampling. **preprint Research Square: PPR781828**, jan. 2024. DOI 10.21203/rs.3.rs-3817014/v1.

ROSENFIELD, A. Computer Vision: Basic Principles. **Proceedings of the IEEE**, v. 76, n. 8, p. 863–868, 1988.

RUSSAKOVSKY, O. et al. ImageNet Large Scale Visual Recognition Challenge. **International Journal of Computer Vision**, v. 115, n. 3, p. 211–252, set. 2015.

RUSSELL, S. J.; NORVIG, P. **Artificial intelligence a modern approach**. 3. ed. Editora Prentice Hall Series In Artificial Intelligence, New Jersey, 1154 f. 2010.

SANTOS, A. C; COLLICCHIO, E; SIQUEIRA, G. B. de. Bioenergetic potential of natural populations of macaúba in the central region of the state of Tocantins. **Aracê**, [S. I.], v. 6, n. 4, p. 19433–19458, 2024. DOI: 10.56238/arev6n4-495.

SHAPIRO, L. G.; STOCKMAN, G. C. **Computer Vision**. 1. Ed. Prentice Hall, Memphis. fev. 2001. 608p.

SHARMA, S. et al. Drones and machine learning for estimating forest carbon storage. **Carbon Research**, [S.I.], v. 1, n. 1, dez. 2022. DOI 10.1007/s44246-022-00021-5.

SINGH, P. **Photogrammetry knowledge ground sampling distance (GSD) in photogrammetry**. Disponível em: <<https://support.pix4d.com/hc/en-us/articles/202559809-Ground-sampling-distance-GSD-in-photogrammetry>>. Acesso em: 16 ago. 2023.

SLAVSKIY, V. et al. Assessment of phytomass and carbon stock in the ecosystems of the central forest steppe of the east european plain: integrated approach of terrestrial

environmental monitoring and remote sensing with unmanned aerial vehicles. **Life**, [S.I.], v. 14, n. 5, maio 2024. DOI 10.3390/life14050632.

SOUSA, J. M. R. de. Modelagem da biomassa de plantações florestais a partir da tecnologia LiDAR embarcada em drone. 2023. 57 f. Dissertação (Mestrado em Engenharia Agrícola) - Faculdade de Ciências Agronômicas. Botucatu: Unesp, 2023.

STANGARLIN, M. P. Utilização de inteligência artificial e sensoriamento remoto para estimativa de biomassa, carbono e CO₂ equivalente acima do solo em sistema agroflorestal. 2023. 72 f. Dissertação (Mestrado em Engenharia Florestal) -. Santa Maria: Universidade Federal de Santa Maria, 2023.

SU, R. et al. Aboveground carbon stock estimation based on backpack LiDAR and UAV multispectral imagery at the forest sample plot scale. **Remote Sensing**, [S.I.], v. 16, n. 21, nov. 2024. DOI 10.3390/rs16213927.

TONELI, C. A. Z. et al. Aerial biomass estimation in the Cerrado biome using canopy height data. **Forests**, [S.I.], v. 15, n. 3, mar. 2024. DOI 10.3390/f15030507.'

TOLEDO, D. DE P. análise técnica, econômica e ambiental de macaúba e de pinhão-manso como alternativas de agregação de renda na cadeia produtiva de biodiesel. 2010. 92 f. Dissertação (Mestrado em Ciência Florestal) -. Viçosa: Universidade Federal de Viçosa, 2010.

UFV, Rede Macaúba de Pesquisa - REMAPE. **Sistema de cultivo.** Disponível em: <<https://macauba.ufv.br/sistemas-de-cultivo/>>. Acesso em: 12 abr. 2025.

VACCA, G.; VECCHI, E. UAV photogrammetric surveys for tree height estimation. **Drones**, [S.I.], v. 8, n. 3, mar. 2024. DOI 10.3390/drones8030106.

VAN VEEN, F.; LEIJNEN, S. **The neural network zoo.** Disponível em: <<https://www.asimovinstitute.org/neural-network-zoo>>. Acesso em: 10 ago. 2023.

VARGAS-CARPINTERO, R. et al. *Acrocomia spp.*: neglected crop, ballyhooed multipurpose palm or fit for the bioeconomy? A review. **Agronomy for Sustainable Development**, [S.I.], v. 41, n. 6, p. 1–35, nov. 2021. DOI 10.1007/s13593-021-00729-5.

WUNGSHAP, H. et al. Carbon stock assessment in natural forests and plantations using geoinformatics in Manipur, Northeast India. **Agronomy**, [S.I.], v. 13, n. 8, ago. 2023. DOI 10.3390/agronomy13082023.

ZHANG, J. et al. HR-YOLOv8: a crop growth status object detection method based on YOLOv8. **Electronics**, Switzerland, v. 13, n. 9, mai. 2024. DOI 10.3390/electronics13091620.