



UNIVERSIDADE FEDERAL DE SERGIPE
PRÓ-REITORIA DE PÓS-GRADUAÇÃO E PESQUISA



PROGRAMA DE PÓS-GRADUAÇÃO EM DESENVOLVIMENTO E MEIO
AMBIENTE

ALLANA KARLA COSTA ALVES

ESTIMAÇÃO DA BIOMASSA EM UM MANGUEZAL RESTAURADO
PASSIVAMENTE COM USO DE GEOTECNOLOGIAS

SÃO CRISTÓVÃO/SE
FEVEREIRO/2025

ALLANA KARLA COSTA ALVES

**ESTIMAÇÃO DA BIOMASSA EM UM MANGUEZAL RESTAURADO
PASSIVAMENTE COM USO DE GEOTECNOLOGIAS**

Dissertação apresentada ao Programa de Pós-Graduação em Desenvolvimento e Meio Ambiente, da Universidade Federal de Sergipe, como parte dos requisitos para obtenção do título de Mestra em Desenvolvimento e Meio Ambiente, na área de Planejamento e Gestão Ambiental.

Orientador: Prof. Dr. Adauto de Souza
Ribeiro

Coorientador: Prof. Dr. Milton Marques
Fernandes

**SÃO CRISTÓVÃO/SE
FEVEREIRO/2025**

ALLANA KARLA COSTA ALVES

Dissertação apresentada ao Programa de Pós-Graduação em Desenvolvimento e Meio Ambiente, da Universidade Federal de Sergipe, como parte dos requisitos para obtenção do título de Mestra em Desenvolvimento e Meio Ambiente, na área de Planejamento e Gestão Ambiental.

Prof. Dr. Aduino de Souza Ribeiro – Presidente/Orientador
Universidade Federal de Sergipe

Prof. Dr. Ticiano Rodrigo de Almeida Oliveira - Examinador Interno
Universidade Federal de Sergipe

Prof. Dr. Márcia Rodrigues de Moura Fernandes- Examinadora Externa
Universidade Federal de Sergipe

SÃO CRISTÓVÃO/SE
FEVEREIRO/2025

DECLARAÇÃO DE VERSÃO FINAL

Este exemplar corresponde à versão final da Dissertação de Mestrado em Desenvolvimento e Meio Ambiente concluída no Programa de Pós-Graduação em Desenvolvimento e Meio Ambiente (PRODEMA) da Universidade Federal de Sergipe.

Documento assinado digitalmente



ADAUTO DE SOUZA RIBEIRO

Data: 16/04/2025 15:55:59-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. Adauto de Souza Ribeiro – Orientador

Programa de Pós-Graduação em Desenvolvimento e Meio Ambiente (PRODEMA)

Universidade Federal de Sergipe (UFS)

Documento assinado digitalmente



MILTON MARQUES FERNANDES

Data: 24/04/2025 10:58:48-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. Milton Marques Fernandes - Coorientador

Programa de Pós-Graduação em Desenvolvimento e Meio Ambiente Universidade Federal
de Sergipe

É concedido ao Programa de Pós-Graduação em Desenvolvimento e Meio Ambiente (PRODEMA) da Universidade Federal de Sergipe (UFS) responsável pelo Mestrado em Desenvolvimento e meio Ambiente permissão para disponibilizar, reproduzir cópia desta Dissertação e emprestar ou vender tais cópias.

Allana Karla Costa Alves

Programa de Pós-Graduação em Desenvolvimento e Meio Ambiente (PRODEMA)
Universidade Federal de Sergipe (UFS)

Documento assinado digitalmente
 ADAUTO DE SOUZA RIBEIRO
Data: 16/04/2025 15:55:59-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Adauto de Souza Ribeiro – Orientador

Programa de Pós-Graduação em Desenvolvimento e Meio Ambiente (PRODEMA)
Universidade Federal de Sergipe (UFS)

Documento assinado digitalmente
 MILTON MARQUES FERNANDES
Data: 24/04/2025 10:58:48-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Milton Marques Fernandes - Coorientador

Programa de Pós-Graduação em Desenvolvimento e Meio Ambiente Universidade Federal
de Sergipe

DEDICATÓRIA

Dedico este trabalho à minha família, pelo apoio incondicional e amor constante e à Brenda, por acreditar em mim e me apoiar nos momentos de desafios e conquistas.

AGRADECIMENTOS

A conclusão desta dissertação representa o encerramento de uma importante etapa da minha vida acadêmica e profissional, que só foi possível graças ao apoio de diversas pessoas e instituições.

Agradeço primeiramente a Deus, por me guiar e fortalecer em cada momento desta jornada.

Ao meu coorientador, Prof. Dr. Milton Marques Fernandes, e ao meu orientador, Prof. Dr. Aduino de Souza Ribeiro, pela paciência, dedicação e incentivo contínuo durante toda a realização deste trabalho, proporcionando direcionamento e inspiração ao longo do caminho.

Aos professores Márcia Rodrigues e Ticiano Rodrigo, que participaram da banca de defesa como membros examinadores, oferecendo sugestões que enriqueceram ainda mais este trabalho.

Ao Lucas Berenger e ao Prof. Dr. André Quintão, pela valiosa contribuição e apoio na construção desta dissertação.

À minha família por todo o amor, suporte incondicional e compreensão durante os momentos de ausência e dedicação ao estudo. Vocês são minha base e motivação.

Aos colegas e amigos que compartilharam comigo as alegrias e os desafios deste percurso, seja por meio de discussões enriquecedoras, apoio emocional ou companheirismo nos dias difíceis.

Ao CNPq, por disponibilizar os recursos que viabilizaram esta pesquisa, e à Universidade Federal de Sergipe, pelo espaço e suporte técnico e acadêmico indispensáveis ao desenvolvimento deste trabalho.

Por fim, deixo um agradecimento especial a todas as pessoas que, direta ou indiretamente, contribuíram para o crescimento deste projeto e para o meu aprendizado. Cada contribuição foi essencial para que este trabalho se tornasse realidade.

Viva a ciência! Não ao negacionismo! Viva a democracia! Viva a liberdade religiosa! Não à intolerância religiosa e sexual!

Muito obrigada(o)!

A crise climática é a maior ameaça à existência da humanidade e precisamos tratá-la como tal".

Greta Thunberg

RESUMO

A avaliação e quantificação da biomassa em manguezais são fundamentais para a valoração de créditos de carbono e para o cumprimento das metas globais de mitigação das mudanças climáticas, conforme os Objetivos de Desenvolvimento Sustentável (ODS) 13 (Ação contra a mudança global do clima), 14 (Vida na água) e 15 (Vida terrestre). Este estudo teve como objetivo estimar a biomassa acima do solo (AGB) em uma área de manguezal em processo de restauração passiva, localizada no município de Nossa Senhora do Socorro, em Sergipe, previamente degradada pela atividade de carcinicultura. Para isso, foi utilizada a nuvem de pontos gerada por duas tecnologias de sensoriamento remoto: a Fotogrametria Aérea Digital com o uso de Aeronaves Remotamente Pilotadas (FAD-ARP) e o LiDAR Terrestre Portátil (LiDAR-PLS). Foi realizado um inventário florestal em 22 parcelas de 0,025 hectare para validação dos dados, e a estimativa da biomassa foi feita por meio da equação corrigida de Chave et al. (2014), com valores variando de 2 a 246 Mg.ha⁻¹. As variáveis extraídas das nuvens de pontos foram utilizadas como preditoras em modelos de regressão linear múltipla (RLM) e os resultados foram comparados ao método tradicional de campo (inventário florestal com medições diretas de DAP e altura). O modelo baseado na FAD-RPA apresentou um coeficiente de determinação (R²) de 0,86 e um erro quadrático médio (EQM) de 24,03 Mg.ha⁻¹ (33,60%), enquanto o modelo baseado no LiDAR-PLS obteve um R² de 0,62, com EQM de 40,42 Mg.ha⁻¹ (56,54%). Os resultados evidenciam o potencial das tecnologias de sensoriamento remoto na estimativa acurada da biomassa em ecossistemas de manguezais, especialmente da FAD-RPA, que apresentou maior desempenho estatístico. Essas ferramentas oferecem maior precisão na quantificação do carbono estocado e podem contribuir de forma significativa para iniciativas de conservação, restauração ambiental e geração de créditos de carbono, alinhando-se aos compromissos climáticos globais.

Palavras-Chaves: Biomassa acima do solo; mangues; aeronaves remotamente pilotadas; LiDAR; créditos de carbono.

ABSTRACT

The evaluation and quantification of biomass in mangroves are fundamental for valuing carbon credits and meeting global climate change mitigation goals, as outlined in the Sustainable Development Goals (SDGs) 13 (Climate Action), 14 (Life Below Water), and 15 (Life on Land). This study aimed to estimate above-ground biomass (AGB) in a passive restoration mangrove area located in the municipality of Nossa Senhora do Socorro, Sergipe, previously degraded by shrimp farming activities. To achieve this, a point cloud was generated using two remote sensing technologies: Digital Aerial Photogrammetry with the use of Remotely Piloted Aircraft (DAP-RPA) and Portable Terrestrial LiDAR (LiDAR-PLS). A forest inventory was conducted in 22 plots of 0.025 hectares for data validation, and biomass estimation was performed using the corrected equation by Chave et al. (2014), with values ranging from 2 to 246 Mg.ha⁻¹. Variables extracted from the point clouds were used as predictors in multiple linear regression (MLR) models, and the results were compared to the traditional field method (forest inventory with direct measurements of DBH and height). The model based on DAP-RPA presented a coefficient of determination (R²) of 0.86 and a root mean squared error (RMSE) of 24.03 Mg.ha⁻¹ (33.60%), while the model based on LiDAR-PLS obtained an R² of 0.62, with an RMSE of 40.42 Mg.ha⁻¹ (56.54%). The results highlight the potential of remote sensing technologies for accurately estimating biomass in mangrove ecosystems, particularly DAP-RPA, which showed greater statistical performance. These tools offer greater precision in carbon stock quantification and can significantly contribute to conservation initiatives, environmental restoration, and carbon credit generation, aligning with global climate commitments.

Keywords: Above-ground biomass; mangroves; remotely piloted aircraft; LiDAR; carbon credits

LISTA DE ILUSTRAÇÕES

Figura 1. Distribuição dos Manguezais do Brasil.	5
Figura 2. Espectro eletromagnético.	13
Figura 3. Curva espectral da vegetação, da água e do solo.	14
Figura 4. Ilustração do OLS, ALS, o UAV-LiDAR, TLS, MLS e o PLS.	16
Figura 5. Localização da Área de Estudo.	25
Figura 6. Equipamentos utilizados para a obtenção dos dados de sensoriamento remoto via ARP: (A) ARP DJI Mavic 3 Multispectral; (B e C) receptor Emlid RTK GNSS Reach RS2 para coleta de coordenadas em tempo real.	26
Figura 7. Mapa de localização dos pontos de check e pontos de controle alocados na área de estudo.	28
Figura 8. Fases do mapeamento aerofotogramétrico.	29
Figura 9. Equipamentos utilizados para a obtenção dos dados de sensoriamento remoto via LiDAR (PLS): (A) GeoSLAM ZEB-HORIZON 3D; (B) receptor Emlid RTK GNSS Reach RS2 para coleta de coordenadas em tempo real.	30
Figura 10. Mapa de localização das parcelas alocadas na área de estudo.	32
Figura 11. Medição das alturas totais das árvores nas 22 parcelas inventariadas.	33
Figura 12. Modelo Digital do Terreno (MDT) obtido pela FAD-ARP nas 22 parcelas inventariadas.	39
Figura 13. Gráfico de dispersão entre os valores de elevação do terreno coletados em campo com o RTK e os valores de elevação do MDT derivado da FAD-ARP.	40
Figura 14. Gráficos de dispersão entre a métrica H _{máx} obtida por (a) FAD-ARP (b) LiDAR comparadas com a altura máxima observada.	41
Figura 15. Gráficos de dispersão entre a métrica H _{méd} obtida por (a) FAD-ARP (b) LiDAR comparadas com a altura média observada em campo.	43
Figura 16. Os gráficos dos valores de AGB observados e AGB estimadas obtidas por RLM pelo (a) FAD-ARP (b) LiDAR.	46

LISTA DE TABELAS

Tabela 1. Parâmetros de aquisição das imagens.	27
Tabela 2. Parâmetros do LiDAR (PLS).	30
Tabela 3. Estatísticas descritivas do DAP e Ht do inventário florestal das 22 parcelas amostradas no manguezal localizado nas margens do Rio do Sal, no município de Nossa Senhora do Socorro/SE.	33
Tabela 4. Descrição das métricas derivadas de nuvens de pontos do LiDAR e da FAD-ARP.	34
Tabela 5. Estimativa de Biomassa Acima do Solo (AGB) (Mg. ha ⁻¹) das parcelas amostradas no manguezal localizado nas margens do Rio do Sal, no município de Nossa Senhora do Socorro/SE.	38
Tabela 6. Estatística dos valores estimados pela FAD-ARP.	40
Tabela 7. Estatística da comparação entre a métrica H _{máx} obtida por (a) FAD-ARP (b) LiDAR comparadas com a altura máxima observada.	41
Tabela 8. Estatística da comparação entre a métrica H _{méd} obtida por (a) FAD-ARP (b) LiDAR comparadas com a altura média observada.	43
Tabela 9. Corresponde ao modelo de regressão da biomassa estimado pelas métricas da FAD-ARP.	44
Tabela 10. Corresponde ao modelo de regressão da biomassa estimado pelas métricas do LiDAR.	44
Tabela 11. Estatísticas utilizadas para avaliar o desempenho dos modelos na estimação da biomassa acima do solo da vegetação de mangue, obtidas por análise de RLM, para os dados de ajuste.	45

LISTA DE QUADROS

Quadro 1. Síntese dos Serviços Ambientais e Atributos Pagos.	7
Quadro 2. Critérios, Classificações e Descrições da Fotogrametria.	19
Quadro 3. Diferenças entre os dois Modelos De Aeronaves (Asa Fixa e Multirotor).	22

LISTA DE ABREVIATURAS E SIGLAS

TIN	<i>Adaptive Triangulated Irregular Network</i>
ARP	Aeronave Remotamente Pilotada
RPA	<i>Remotely Piloted Aircraft</i>
HT	Altura
ISPRS	<i>American Society of Photogrammetry</i>
AB	Área Basal
BGB	Biomassa Abaixo do Solo
AGB	Biomassa Acima do Solo
RE	Borda Vermelha
CNPISA	Cadastro Nacional de Pagamento por Serviços Ambientais
CAP	Circunferência à altura do peito
COP-26	Conferência das Nações Unidas sobre Mudanças Climáticas
COP21	Conferência das Partes da Convenção-Quadro das Nações Unidas Sobre Mudança do Clima
DAP	Diâmetro à altura do peito
CO ₂	Dióxido de Carbono
EFT	Estrutura de Transparência Aprimorada
FAD	Fotogrametria Aérea Digital
g cm ⁻³	Grama por Centímetro Cúbico
GEE	Gases de Efeito Estufa
GPS	<i>Global Positioning System</i>
GNSS	<i>Global Navigation Satellite System</i>
GSD	<i>Ground Sample Distance</i>
GIECO	Grupo Executivo Interinstitucional de Estudos sobre Instrumentos Econômicos para a Proteção Ambiental
IMU	<i>Inertial Measurement Unit</i>
NIR	Infravermelho Próximo
IUCN	<i>International Union for Conservation of Nature</i>
ITMOs	<i>Internationally Transferred Mitigation Outcomes</i>
LiDAR	<i>Light Detection and Ranging</i>
MDL	Mecanismo de Desenvolvimento Limpo

MDS	Mecanismo de Desenvolvimento Sustentável
Mg ha ⁻¹	Megagrama por hectare
MLS	<i>Mobile Laser Scanner</i>
MDS	Modelos Digitais de Superfície
MDT	Modelo Digital do Terreno
MODIS	<i>Moderate Resolution Imaging Spectroradiometer</i>
NDCs	<i>Nationally Determined Contributions</i>
UAV-LiDAR	<i>Unmanned Aerial Vehicle-Light Detection and Ranging</i>
ODS	Objetivos de Desenvolvimento Sustentável
OLI	<i>Operational Land Imager</i>
PSA	Pagamentos por Serviços Ambientais
PSE	Pagamentos por Serviços Ecológicos
PEMC	Política Estadual sobre Mudanças Climáticas
PNSA	Política Nacional de Pagamentos por Serviços Ambientais
PLS	<i>Portable Laser Scanning</i>
PFPSA	Programa Federal de Pagamento por Serviços Ambientais
RADAR	<i>Radio Detection and Ranging</i>
RGB	<i>Red, Green, Blue</i>
CER	Redução Certificada de Emissões
RBAC-E	Regulamento Brasileiro da Aviação Civil
RCE	Redução Certificada de Emissões
REDD+	<i>Reducing Emissions from Deforestation</i>
RMU	Unidade de Remoção
RPAS	<i>Remotely-Piloted Aircraft System</i>
RTK	Real Time Kinematic
SBCE	Sistema Brasileiro de Comércio de Emissões de Gases de Efeito Estufa
SE	Serviços Ecológicos
SEMACE	Secretaria de Estado do Meio Ambiente e dos Recursos Hídricos
SLAM	<i>Simultaneous Localization and Mapping</i>
SONAR	<i>Sound Navigation Ranging</i>
SR	Sensoriamento Remoto
SfM	<i>Structure from Motion</i>
TLS	<i>Terrestrial Laser Scanning</i>

UTM	Universal Transversa de Mercator
G	Verde
R	Vermelho
VCS	<i>Voluntary Carbon Standard</i>

SUMÁRIO

1. INTRODUÇÃO	1
2. OBJETIVOS ESPECIFICOS	3
3. FUNDAMENTAÇÃO TEÓRICA.....	4
3.1. Ecologia e importância dos manguezais	4
3.2. Pagamentos por serviços ecossistêmicos ou ambientais	6
3.3. Mercado de carbono	8
3.4. Tecnologias de sensoriamento para aquisição de dados ambientais	12
3.4.1. Light Detection and Ranging (LiDAR)	14
3.4.2. Fotogrametria	18
3.4.3. Aerofotogrametria	19
3.4.4. Estimativa de Biomassa Acima do Solo (AGB) com dados obtidos por LiDAR e por FDA-ARPs	23
4. MATERIAL E MÉTODOS	25
4.1. Localização e caracterização da área de estudo	25
4.2. Fotogrametria aérea digital (FAD).....	26
4.2.1. Aquisição das Fotografias Aéreas Digital	26
4.2.2. Processamento Fotográfico do FAD	27
4.3. Instrumentação e coleta de dados do light detection and ranging (LiDAR)....	29
4.4. Inventário florestal das variáveis dendrométricas	31
4.5. Estimativa de biomassa acima do solo	33
4.6. Métricas da nuvem de pontos do LiDAR e FAD-ARP	34
4.7. Análise dos dados.....	35
4.8. Estimação da biomassa acima do solo por RLM	36
4.9. Critérios de avaliação das estimativas obtidas por RLM	36
5. RESULTADOS E DISCUSSÃO	37
5.1. Caracterização de AGB por parcela	37
5.2. Validação da FAD-ARP	39
5.3. Altura Máxima Observada x Altura Máxima FDA-ARP e LiDAR.....	40
5.4. Altura Média Observada x Altura média FDA-ARP e LiDAR.....	43
5.5. Ajuste e validação do modelo de biomassa acima do solo	44
6. CONCLUSÃO	48
7. REFERÊNCIAS BIBLIOGRÁFICAS	49
8. ANEXOS	56

8.1. RELATÓRIO DE PROCESSAMENTO	56
--	-----------

1. INTRODUÇÃO

Os manguezais são ecossistemas de suma importância ecológica, econômica e social, encontrados em regiões tropicais e subtropicais (Souza et al., 2018). O Brasil, com o seu extenso litoral, abriga a segunda maior área de manguezal do mundo, ficando atrás apenas da Indonésia (Jia et al., 2023). Entre os anos de 2000 e 2023, a área total desse ecossistema se manteve estável, passando de 1.033.154 hectares para 1.045.481 hectares (Mapbiomas, 2023). Dentre os 16 estados brasileiros que abrigam esse ecossistema, o Maranhão, localizado na região Nordeste, e os estados do Pará e Amapá, na região Norte, concentram juntos a maior área contínua de manguezais do país (ICMBio, 2018; Mapbiomas, 2023).

Em Sergipe, embora a área de manguezal seja menor em comparação ao estado do Maranhão, com uma extensão de 26.543,63 hectares, esse ecossistema desempenha papel vital na dinâmica costeira e no sustento das populações locais. As áreas de mangue em Sergipe estão distribuídas nas fozes dos rios Real, Piauí, Vaza-Barris, Sergipe, Japarutuba e São Francisco, atuando como habitats essenciais para a biodiversidade, além de fornecerem recursos como peixes e crustáceos (ICMBio, 2018; SERhidro Geo, 2024).

Além de sua importância ecológica, os manguezais oferecem diversos serviços ecossistêmicos, como por exemplo, a proteção da zona costeira contra erosão, tempestades e tsunamis, o sequestro e armazenamento de carbono na Biomassa Acima do Solo (AGB) quanto no solo, manutenção dos estoques pesqueiros, e sendo suporte para atividades culturais e tradicionais (ICMBio, 2018; Friess *et al.*, 2021; Estrada; Soares, 2017; Kandasamy *et al.*, 2021); Spalding; Parrett, 2019). A manutenção deste ecossistema garante a execução desses serviços, que estão diretamente alinhados com os Objetivos de Desenvolvimento Sustentável (ODS), particularmente o ODS 13 (Ação contra a mudança global do clima), ODS 14 (Vida na água) e ODS 15 (Vida terrestre). A proteção e restauração desses ecossistemas são essenciais para mitigar os impactos das mudanças climáticas, conservar a biodiversidade e garantir a resiliência das comunidades costeiras que dependem de seus serviços.

No entanto, essa riqueza de serviços ecossistêmicos enfrenta uma grande ameaça devido à pressão antrópica, especialmente pela conversão de áreas para aquicultura, com destaque para a carcinicultura. Essa atividade, que desempenha um papel crucial na economia do Nordeste, é responsável por 99,6% do volume de camarão produzido no Brasil (IBGE, 2022). Apesar disso, sua expansão tem impactos significante nos manguezais, com a conversão de áreas naturais em viveiros de camarão, comprometendo a biodiversidade local e a qualidade desses serviços.

Em Sergipe, a carcinicultura é uma atividade econômica de grande relevância econômica e socioambiental, com destaque para o município de Nossa Senhora do Socorro, que abriga a maior área destinada ao cultivo de camarões no estado, totalizando 434,94 hectares de viveiros distribuídos em 825 tanques (De Souza *et al.*, 2022). Em 2023, o estado ficou em sexto lugar na produção de camarão, com uma produção de 72.616 Mil Reais (IBGE, 2023). No entanto, uma parte dessa atividade ocorre de forma ilegal. No Povoado Aratu, situado próximo ao Riacho Várzea, afluente do Rio do Sal, em Nossa Senhora do Socorro, foram identificados 33 viveiros de carcinicultura em áreas de manguezais, operando de forma irregular, sem licença ambiental ou qualquer processo de regulamentação, representando uma grave ameaça à integridade desse ecossistema (Góes; Ellen, 2024).

A continuidade dessa pressão pode ter consequências drásticas para os manguezais. Um estudo recente da International Union for Conservation of Nature (IUCN), realizado em 2024, alerta para o risco de extinção de 50% dos manguezais do mundo, se as atividades destrutivas não forem controladas. As áreas mais vulneráveis a essa extinção estão localizadas no litoral sul da Índia, Sri Lanka, Maldivas, Golfo do México, Mar Vermelho, partes de Papua-Nova Guiné, Ilhas Salomão e no litoral sul da China. Esse cenário global reforça a necessidade urgente de política eficaz de preservação e restauração dos manguezais, para garantir a mitigação dos impactos das mudanças climáticas e a conservação da biodiversidade, que são essenciais não só para os ecossistemas locais, mas para o equilíbrio ambiental do planeta.

Diante dessas ameaças, torna-se ainda mais urgente a necessidade de monitorar e avaliar a biomassa dos mangues, pois essa prática é essencial para quantificar o carbono estocado e, assim, calcular o potencial de geração de créditos de carbono. Visto que, em um hectare de mangue pode-se armazenar de duas a quatro vezes mais carbono do que o mesmo tamanho de área de outro bioma, como a Floresta Amazônica (Rovai *et al.*, 2022). Esses créditos podem ser comercializados em um mercado regulado ou voluntário, proporcionando recursos financeiros que podem ser reinvestidos na conservação e restauração dos manguezais, além de servir como fonte de renda para as comunidades tradicionais, criando um ciclo positivo de preservação ambiental e desenvolvimento sustentável.

Em dezembro de 2024, foi sancionada a Lei nº 15.042, que estabelece o Sistema Brasileiro de Comércio de Emissões de Gases de Efeito Estufa (SBCE). Esse mercado regulado de carbono permite que as emissões de gases poluentes sejam convertidas em ativos financeiros negociáveis, promovendo a redução das emissões de Dióxido de Carbono (CO₂) e incentivando práticas sustentáveis, como a conservação dos manguezais. Projetos de preservação e

restauração desses ecossistemas podem gerar créditos de carbono, que serão comercializados, garantindo recursos financeiros para a recuperação ambiental e oferecendo novas oportunidades de geração de renda para as comunidades locais, alinhando a proteção ambiental com o desenvolvimento econômico.

Nesse sentido, o Sensoriamento Remoto (SR) vem surgindo como uma ferramenta promissora para realizar essa estimativa de maneira eficaz, abrangente e de baixo custo. Estudos anteriores de Vinh *et al.*, 2019; Salum *et al.*, 2020; Wang *et al.*, 2020; Wong *et al.*, 2024, têm explorado diversas metodologias para estimar a biomassa em mangues, desde abordagens de campo tradicionais até técnicas avançadas de sensoriamento remoto.

O problema central desta pesquisa é a necessidade de avaliar como o sensoriamento remoto pode ser utilizado para estimar com precisão a biomassa dos mangues no nordeste brasileiro e superar as limitações dos métodos tradicionais. Visto que, atualmente, os métodos tradicionais de estimativa biomassa dependem de medições no solo, que são relativamente caros, trabalhosos, demandam tempo e cobrem pequenas escalas espaciais (Navarro *et al.*, 2020).

Nesse sentido, formulou-se as seguintes hipóteses:

- O sensoriamento remoto pode ser aplicado de forma eficaz e acurada na estimativa da biomassa em manguezais do Nordeste brasileiro.
- As tecnologias de *Remotely Piloted Aircraft* (RPA) e do *Light Detection and Ranging* (LiDAR), apresenta limitações na estimativa da Biomassa Acima do solo (AGB) em ecossistemas de manguezais

Este trabalho tem como objetivo estimar a Biomassa Acima do Solo (AGB) em uma área de mangue em restauração passiva, anteriormente degradada pela carcinicultura, com dados FAD-ARP e LiDAR-PLS.

2. OBJETIVOS ESPECIFICOS

- Estimar a Biomassa Acima do Solo (AGB) em uma área de regeneração natural passiva, localizada em uma antiga área de carcinicultura abandonada, utilizando dados obtidos a partir da nuvem de pontos gerada por LiDAR e FAD-ARP.
- Comparar as métricas derivadas da nuvem de pontos obtidas por LiDAR e FAD-ARP com as métricas obtidas em campo, aplicando modelos estatísticos e algoritmos de

regressão para avaliar a precisão, acurácia e consistência das estimativas de Biomassa Acima do Solo (AGB).

3. FUNDAMENTAÇÃO TEÓRICA

3.1. Ecologia e importância dos manguezais

Na literatura o termo mangue é utilizado para descrever um conjunto de árvores tropicais que, apesar de pertencerem a famílias botânicas sem qualquer relação taxonômica entre si, compartilham características fisiológicas semelhantes. Já o termo "manguezal" é empregado para descrever as comunidades florestais ou o ecossistema em si, onde ocorre a interação entre populações de plantas, animais e micro-organismos, ocupando tanto a área do manguezal quanto o seu ambiente físico, conhecido como o componente abiótico desse ecossistema (Schaeffer-Novelli, 2018a).

Dessa forma, o manguezal é um ecossistema que serve como zona de transição entre os ambientes terrestres e marinhos, comumente encontrado em regiões tropicais e subtropicais e influenciado pelo regime de marés. Este ecossistema é composto por uma variedade de espécies vegetais lenhosas, principalmente angiospermas, juntamente com microalgas e macroalgas adaptadas às variações de salinidade. Caracterizando-se como uma zona úmida que representa a transição entre o continente e o oceano (Schaeffer-Novelli, 1995b).

Essa definição é corroborada por estudiosos como Odum e Barrett (2007), que destaca a capacidade dos manguezais em tolerar a salinidade do mar aberto, em que uma sucessão de espécies forma uma zona de transição entre o mar aberto até a região das marés máximas. As extensas raízes aéreas penetram fundo na lama anaeróbica, trazendo oxigênio para suas profundezas e fornecendo superfície para a fixação de moluscos, ostras, cracas e outros animais marinhos.

Os manguezais são frequentemente encontrados em regiões tropicais e subtropicais em todo o mundo, ocupando uma área considerável de aproximadamente 145.068 km². Em termos de extensão, os países que se destacam são a Indonésia, o Brasil e a Austrália, nessa ordem (Jia *et al.*, 2023). No Brasil, o manguezal se estende do Amapá até Santa Catarina, abrangendo uma área de aproximadamente 1.398.966,13 hectares (ICMBio, 2018) (Figura 1).

Figura 1. Distribuição dos Manguezais do Brasil.



Fonte: ICMBio,2018.

Nos manguezais brasileiros predominam seis espécies de mangues: *Avicennia germinans*, *Avicennia schaueriana*, *Laguncularia racemosa*, *Rhizophora mangle*, *Rhizophora racemosa* e *Rhizophora harrisonii* (Schaeffer-Novelli, 1987c). Esses ecossistemas não apenas abrigam uma grande diversidade de espécies vegetais, mas também fornecem uma ampla gama de Serviços Ecossistêmicos (SE).

De acordo com o ICMBio (2018), os SE são os benefícios que os ecossistemas proporcionam as pessoas e podem ser classificados em quatro categorias:

- Serviços de provisão – incluem o fornecimento de recursos como madeira, frutos, moluscos, crustáceos e peixes.
- Serviços de suporte – fundamentais para a manutenção da vida, abrangem a ciclagem de nutrientes, a renovação da fertilidade do solo, a polinização e a conservação da biodiversidade.
- Serviços de regulação – envolvem o sequestro e armazenamento de carbono, a proteção da linha costeira contra erosão e tempestades, a regulação do microclima e a purificação da água por meio da retenção de sedimentos e filtragem de poluentes.

- Serviços culturais – englobam valores culturais e espirituais, recreação, turismo ecológico, pesquisa científica e a preservação do conhecimento tradicional das comunidades que vivem em áreas de manguezal.

3.2. Pagamentos por serviços ecossistêmicos ou ambientais

Uma estratégia para implementar medidas conservacionistas consiste em recompensar economicamente iniciativas que contribuam para a proteção ambiental. Uma abordagem emergente nesse contexto são os Pagamentos por Serviços Ecossistêmicos (PSE), também conhecidos como Pagamentos por Serviços Ambientais (PSA). Esse conceito é definido como transações voluntárias entre usuários e prestadores de serviços, condicionadas ao cumprimento de regras acordadas para a gestão sustentável dos recursos naturais, visando à geração de benefícios ambientais externos (Wunder, 2015).

O PSA é um instrumento econômico fundamentado no princípio do protetor-recebedor. Segundo Thomé e Garcia (2021), a ideia central desse princípio é oferecer compensação financeira àqueles que adotam práticas voltadas à preservação do meio ambiente, incentivando ações de conservação por meio de recompensas econômicas. Diante disso, o PSA tem despertado crescente interesse de diversos atores sociais, como governos, proprietários privados, cientistas e entidades da sociedade civil. Esse mecanismo busca conciliar a promoção da conservação dos SE com os interesses econômicos dos envolvidos (Guerra; Ranieri, 2023)

No Brasil, o PSA é reconhecido como um dos instrumentos econômicos mais contemporâneos de proteção ambiental, instituído pela Lei nº 14.119 de 13 de janeiro de 2021. Seu objetivo é reconhecer iniciativas individuais ou coletivas que contribuam para a manutenção, recuperação ou melhoria dos serviços, mediante retribuições monetárias ou não monetárias. A legislação também prevê a criação do Programa Federal de Pagamento por Serviços Ambientais (PFPSA), do Cadastro Nacional de Pagamento por Serviços Ambientais (CNPSA) e regula os Contratos de Pagamento por Serviços Ambientais.

Além disso, destaca-se a Lei nº 15.042, de 11 de dezembro de 2024, que institui o SBCE. Essa legislação busca fomentar a redução de emissões de gases de efeito estufa por meio de um mercado regulado de comércio de créditos de carbono, promovendo a adoção de práticas sustentáveis e a transição para uma economia de baixo carbono no Brasil.

Globalmente, quatro categorias principais de serviços ambientais são comercializadas: carbono, água, biodiversidade e beleza cênica (Guedes; Seehusen, 2011). Nos sistemas de PSA-

Carbono, geralmente paga-se por tonelada de CO₂ não emitido ou sequestrado da atmosfera. Nos sistemas de PSA-Água, a compensação ocorre pela manutenção ou melhoria da quantidade e qualidade da água. Já nos sistemas de PSA-Biodiversidade, paga-se pela proteção de espécies ou de hectares de habitat conservado. Por fim, nos sistemas de PSA-Beleza Cênica, a remuneração está associada a serviços relacionados ao turismo e às permissões para fotografia (Quadro 1).

Quadro 1. Síntese dos Serviços Ambientais e Atributos Pagos.

Serviço Ambiental	Paga-se por
Proteção dos recursos hídricos: redução da sedimentação em áreas a jusante; melhora na qualidade da água, redução de enchentes, aumento de fluxos em épocas secas, manutenção de habitat aquático, controle de contaminação de solos.	Reflorestamento em matas ciliares, manejo de bacias hidrográficas, áreas protegidas, qualidade da água, direitos pela água, aquisição de terras, créditos de salinidade, servidões de conservação, etc.
Proteção da biodiversidade: proteção das funções de manter os ecossistemas em funcionamento, manutenção da polinização, manutenção de opções de uso futuro, seguros contra choques, valores de existência	Áreas protegidas, direitos de bioprospecção, produtos amigos da biodiversidade, créditos de biodiversidade, concessões de conservação, aquisição de terras, servidões de conservação, etc.
Sequestro ou armazenamento de carbono: absorção e armazenamento de carbono na vegetação e em solos.	Tonelada de carbono não emitido ou sequestrado através de Reduções Certificadas de Emissões (ERU), créditos de offsets de carbono, servidões de conservação, etc.
Beleza cênica: proteção da beleza visual para recreação.	Entradas, permissões de acesso de longo prazo, pacotes de serviços turísticos, acordos de uso sustentável de recursos naturais, concessões para ecoturismo, aquisição e arrendamento de terras, etc.

Fonte: Guedes; Seehusen, 2011

Os projetos de PSA devem atender a cinco critérios essenciais: serem voluntários, terem um serviço ambiental bem definido, envolverem compradores e fornecedores do serviço, e garantirem a condicionalidade, ou seja, o cumprimento das obrigações ambientais (Wunder, 2005). No Brasil, diversos programas têm sido desenvolvidos ao longo dos anos, como o Proambiente, Programa Produtor de Água, Programa PSA Guardiões das Florestas, PSA/RPPN e o ICMS Ecológico.

No estado de Sergipe, entretanto, os avanços na implementação de políticas voltadas aos PSA têm sido tímidos. A temática foi discutida pioneiramente em 2009, com a criação do Grupo Executivo Interinstitucional de Estudos sobre Instrumentos Econômicos para a Proteção Ambiental (GIECO), vinculado à Secretaria de Estado do Meio Ambiente e dos Recursos Hídricos (SEMAC). Contudo, o grupo não teve continuidade, e as discussões não foram traduzidas em ações concretas.

Em 2017, Franca analisou a capacidade institucional dos municípios sergipanos para atender aos pré-requisitos necessários ao recebimento do ICMS Ecológico. O estudo destacou a importância de considerar as peculiaridades ecossistêmicas de Sergipe na definição de critérios ambientais para a repartição do imposto. Já em 2019, Lima propôs a implantação do ICMS Ecológico no estado, utilizando critérios como a preservação de áreas de conservação e a gestão de resíduos sólidos, com vistas a promover uma redistribuição mais sustentável do imposto estadual.

Com a promulgação da Lei nº 9.364 em 2024, que institui a Política Estadual sobre Mudanças Climáticas (PEMC), Sergipe abriu a possibilidade para a criação de mecanismos de PSA mais estruturados, porém, a prática ainda carece de regulamentações claras e da implementação de ações concretas. Nesse contexto, o Projeto Produtor de Água em Canindé do São Francisco é um exemplo positivo, pois se concentra na transformação do produtor rural em um agente ativo na conservação, com a expectativa de que ele perceba valor por suas práticas ambientais e se torne um "fiscal" da preservação.

3.3. Mercado de carbono

Historicamente, a criação do mercado de carbono foi impulsionada por acordos internacionais, como o Protocolo de Kyoto (1997) e o Acordo de Paris (2015). O Protocolo de Kyoto foi o primeiro tratado internacional a estabelecer metas obrigatórias para a redução das emissões de Gases de Efeito Estufa (GEE). Ele determinou que 38 países industrializados reduzissem suas emissões em uma média de 5% em relação aos níveis de 1990, durante o primeiro período de compromisso, entre 2008 e 2012. Para alcançar essas metas, o tratado introduziu mecanismos de flexibilização, como Implementação Conjunta, o Comércio de Emissões e o Mecanismo de Desenvolvimento Limpo (MDL), permitindo maior eficiência na mitigação global de emissões (Trennepohl, 2022).

A Implementação Conjunta permitia que países do Anexo I - incluindo nações industrializadas e economias em transição, como os Estados Unidos, Canadá, Japão, Austrália, Nova Zelândia e países da ex-União Soviética (como Rússia, Ucrânia, Estônia, Letônia e Lituânia), colaborassem em projetos voltados à redução de emissões de gases de efeito estufa. Por meio desse mecanismo, os países podiam desenvolver projetos conjuntos dentro do próprio grupo, e, para cada tonelada de CO₂ equivalente evitada ou removida, era gerada uma Unidade

de Redução de Emissões (ERU), que podia ser contabilizada para o cumprimento das metas nacionais de mitigação. A Implementação Conjunta era, portanto, um instrumento voltado exclusivamente à cooperação entre países do Anexo I, reforçando a integração intrabloco no enfrentamento das mudanças climáticas (Kyoto Protocol, 1997).

O Mecanismo de Desenvolvimento Limpo (MDL) viabilizava projetos financiados por países do Anexo I em países em desenvolvimento, que não integravam essa categoria. Essa iniciativa promovia a transferência de tecnologia, investimentos em infraestrutura sustentável e preservação ambiental. Cada redução certificada obtida por meio desses projetos era registrada como uma Redução Certificada de Emissões (RCE), enquanto atividades relacionadas ao Uso da Terra, Mudança de Uso da Terra e Florestas resultavam em Unidades de Remoção (RMU). Projetos de florestamento ou reflorestamento geravam CER temporárias ou de longo prazo, conforme o tipo de intervenção (Kyoto Protocol, 1997).

O Comércio de Emissões, por sua vez, foi estabelecido para que países do Anexo I pudessem adquirir créditos de emissão de outros países ou instituições, caso enfrentassem dificuldades para cumprir suas metas nacionais. Embora o tratado não detalhasse critérios específicos para a operacionalização desse mecanismo, sua implementação fomentou um mercado global de créditos de carbono, consolidando o conceito contemporâneo de Mercado de Carbono e ampliando as oportunidades para negociações internacionais (Kyoto Protocol, 1997).

É importante salientar que os mecanismos da Implementação Conjunta e do Comércio de Emissões previstos pelo Protocolo de Kyoto aplicam-se exclusivamente a países desenvolvidos. Já o MDL pode ser implementado em colaboração com países em desenvolvimento, promovendo uma integração mais abrangente entre as economias globais na luta contra as mudanças climáticas (Belchior; Matias, 2008).

No entanto, o Protocolo de Kyoto enfrentou diversos desafios que limitaram seu sucesso na redução das emissões globais de GEE. Entre os principais obstáculos, destacam-se a ausência de países-chave, como os Estados Unidos, que não ratificaram o tratado, e a saída de países como o Canadá e a China (Oliveira, 2024). Além disso, os mecanismos de flexibilização, como o Comércio de Emissões e o MDL, apresentaram complexidades operacionais e burocráticas, o que dificultou sua implementação eficaz. A ausência de sanções rigorosas para os países que não cumprissem suas metas, bem como as mudanças no cenário político e econômico global, também enfraqueceram a eficácia do Protocolo.

Em resposta às limitações do Protocolo de Quioto, a Conferência das Partes da Convenção-Quadro das Nações Unidas sobre Mudança do Clima (COP21), realizada em 2015 em Paris, resultou na adoção do Acordo de Paris. Este tratado trouxe uma abordagem mais inclusiva e ambiciosa, envolvendo todos os países e estabelecendo metas globais para limitar o aumento da temperatura global a bem abaixo de 2°C, com esforços adicionais para restringi-lo a 1,5°C (Paris Agreement, 2015).

Com isso, os países passaram a definir suas próprias metas de redução de emissões, levando em consideração suas condições nacionais, o que proporcionou maior autonomia em relação ao que foi estipulado no Protocolo de Kyoto. Essas metas passaram a ser formalizadas por meio dos *Nationally Determined Contributions* (NDCs). O Acordo de Paris também manteve os mecanismos do Protocolo de Kyoto, com ajustes no Mecanismo de Desenvolvimento Limpo (MDL), que passou a ser denominado Mecanismo de Desenvolvimento Sustentável (MDS). Além disso, o Acordo introduziu um novo mecanismo, os *Internationally Transferred Mitigation Outcomes* (ITMOs), permitindo a comercialização internacional de créditos de carbono excedentes entre os países (De Oliveira, 2022). Contudo, assim como o Protocolo de Kyoto, o Acordo de Paris não regulamentou ou estabeleceu regras específicas para o mercado de carbono, o que gerou debates e impediu a ratificação do tratado em Paris. A formalização do Acordo de Paris ocorreu apenas em 2021, durante a Conferência das Nações Unidas sobre Mudanças Climáticas (COP26) no Reino Unido.

Em 2021, os países ratificantes do Acordo de Paris introduziram novos instrumentos para regulamentar a comercialização de créditos de carbono, como a Estrutura de Transparência Aprimorada (EFT), que estabelece diretrizes de transparência e divulgação para as nações que desejam negociar ou adquirir créditos de carbono. Com exceção dos créditos originados pelos ITMOs, todas as demais unidades de carbono creditadas estarão sujeitas a uma taxa de 5%, cujo valor será destinado a um fundo para apoiar e financiar países em desenvolvimento nos seus esforços para a transição energética e a mitigação das mudanças climáticas (Horst; Júnior, 2020)

Dessa forma, os países que ratificam o Acordo de Paris definem suas próprias metas de redução de emissões, conhecidas como Contribuições Nacionalmente Determinadas (iNDC, na sigla em inglês), adotando uma abordagem bottom-up (de baixo para cima). Isso significa que cada país tem autonomia para estabelecer seus compromissos, comprometendo-se apenas a enviar, revisar e garantir a transparência das ações realizadas por meio do mecanismo denominado *pledge and review* (Oliveira, 2024). As revisões das metas e compromissos acontecem a cada cinco anos, conforme as condições globais. Embora o Acordo de Paris não

preveja sanções para o descumprimento das metas, ele conta com a pressão internacional e com o alinhamento desses compromissos a outros esforços para assegurar a eficácia das ações climáticas (Nardi de Araujo; Abbade, 2021).

Assim, o mercado de carbono é um sistema de comércio de créditos de carbono que visa reduzir as emissões dos GEE. Nesse mercado, empresas, governos e organizações podem comprar e vender créditos de carbono para compensar suas emissões. Um crédito de carbono equivale a uma tonelada de CO₂ ou seu equivalente em outros GEE evitados, reduzidos ou removidos da atmosfera.

O mercado de carbono pode ser dividido em duas categorias principais: o mercado regulado e o mercado voluntário. O mercado regulado é estabelecido por políticas públicas e regulamentações governamentais que incentivam empresas a limitarem suas emissões de GEE. Nessa abordagem, quem ultrapassa os limites compra créditos de quem emite menos. Esse sistema obrigatório promove uma redução significativa das emissões, geração de investimentos e novas tecnologias (Oliveira, 2024). Já no mercado voluntário empresas ou indivíduos voluntariamente compensam suas emissões de carbono sem exigência legal. Ambos os mercados desempenham um papel crucial na mitigação das mudanças climáticas e no incentivo à transição para uma economia de baixo carbono (Neiva, 2023).

Conforme destacado por Arbeche et al. (2022), após a implementação do Protocolo de Kyoto, o mercado voluntário de carbono movimentava anualmente mais de 500 milhões de dólares. Esse mercado pode ser estruturado por meio de negociações diretas entre as partes interessadas ou operado por intermédio de bolsas de valores convencionais. No âmbito do mercado voluntário, três mecanismos principais se destacam: *Reducing Emissions from Deforestation (REDD+)*, *Voluntary Carbon Standard (VCS)* e *KFA Global Carbon ETF*.

O REDD + é um conjunto de incentivos econômicos que tem por objetivo reduzir as emissões de gases de efeito estufa resultantes do desmatamento e da degradação florestal. Ou seja, é um mecanismo projetado para utilizar incentivos de mercado e financeiro visando à redução das emissões dos gases de efeito estufa oriundos da degradação das florestas e do desmatamento (Marcovich; Pinsky, 2019).

O VCS, por sua vez, é um programa internacionalmente reconhecido, criado por uma organização sem fins lucrativos, que estabelece padrões rigorosos para a certificação e verificação de projetos no mercado de carbono. Sua principal função é assegurar transparência, credibilidade e confiança nas transações de créditos de carbono, sendo amplamente adotado no

mercado voluntário (ICROA, 2023). Já o KFA Global Carbon ETF é um fundo de investimento de grande relevância voltado para créditos de carbono, operando na Bolsa de Valores de Nova York. Este mecanismo permite que investidores participem ativamente do mercado de carbono, contribuindo para a mitigação das mudanças climáticas, enquanto buscam retorno financeiro sustentável (Trennepohl, 2022). Esses mecanismos fortalecem o mercado voluntário de carbono, incentivando práticas sustentáveis e a participação de diversos agentes no combate às mudanças climáticas.

O Brasil possui o potencial de se posicionar como protagonista no mercado de carbono global devido às suas vantagens naturais, como a vasta cobertura florestal, a matriz energética predominantemente renovável e a capacidade de desenvolver projetos inovadores de mitigação de emissões de GEE. A implementação de mecanismos como o REDD+ e a expansão de iniciativas de reflorestamento e conservação florestal consolidam o país como um dos principais fornecedores de créditos de carbono no mercado voluntário. Além disso, o compromisso com metas climáticas por meio das NDCs e a regulamentação de um mercado interno de carbono fortalecem a posição brasileira nas negociações globais. Ao atrair investimentos e promover o desenvolvimento sustentável, o Brasil não apenas contribui para a mitigação das mudanças climáticas, mas também gera benefícios socioeconômicos significativos, reforçando seu papel de liderança na transição para uma economia de baixo carbono.

3.4. Tecnologias de sensoriamento para aquisição de dados ambientais

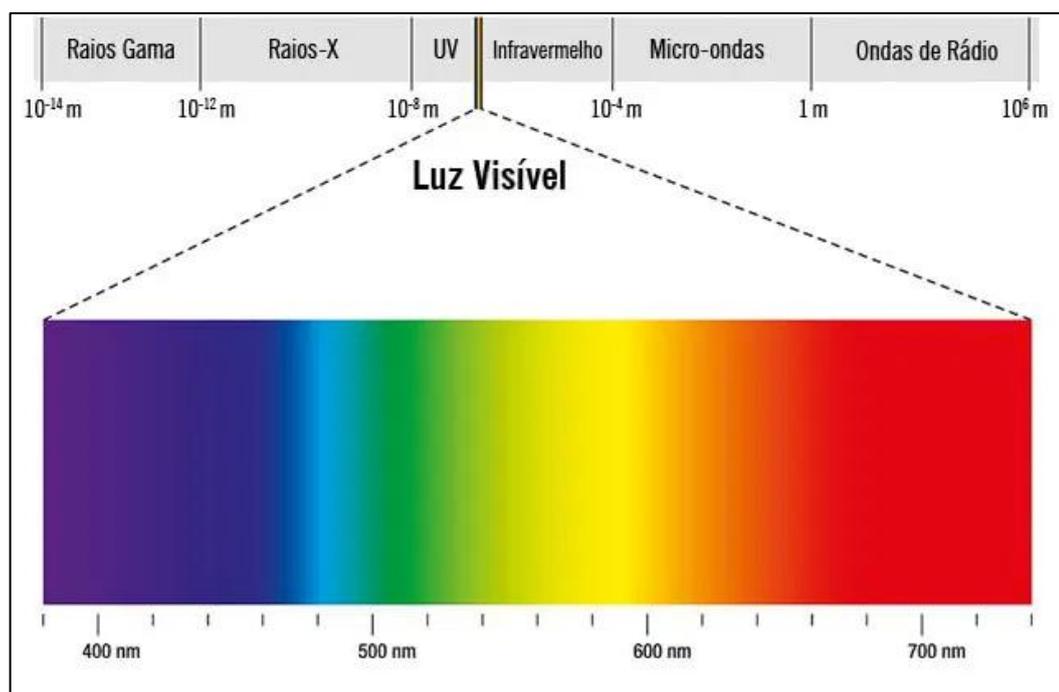
O SR é uma tecnologia que possibilita a aquisição de imagens e outros tipos de dados da superfície terrestre por meio da detecção e registro da energia refletida ou emitida por ela. Esse processo envolve o uso de sensores instalados em diferentes plataformas, como terrestres, aéreas (balões e aeronaves) e orbitais (satélites artificiais). A expressão “remoto” indica que a coleta é realizada à distância, ou seja, sem contato físico direto entre o sensor e os objetos na superfície terrestre. Além da coleta de dados, o sensoriamento remoto também envolve o processamento, análise e interpretação dessas informações (Florenzano, 2011).

Os sensores utilizados no SR podem ser classificados como ativos ou passivos, de acordo com a fonte de energia necessária para a operação. Sensores passivos dependem de fontes externas de radiação, como a energia solar, para a coleta de dados. Esses sensores captam a radiação refletida ou emitida pela superfície terrestre, como ocorre nos sensores

multiespectrais a bordo de satélites, como o *Operational Land Imager* (OLI), presente no Landsat 8, e o *Moderate Resolution Imaging Spectroradiometer* (MODIS), presente nos satélites TERRA e AQUA (Shiratsuchi *et al.*, 2014; Horning, 2018; Oliveira, 2019). Por outro lado, os sensores ativos possuem uma fonte própria de energia, emitindo pulsos de radiação que interagem com a superfície e retornam ao sensor. Exemplos de sensores ativos incluem o *Radio Detection and Ranging* (RADAR), o *Sound Navigation Ranging* (SONAR) e o *Light Detection and Ranging* (LiDAR).

A energia que possibilita a obtenção de dados no SR está intrinsecamente relacionada ao espectro eletromagnético, que representa a distribuição da radiação eletromagnética em diferentes regiões, organizadas de acordo com seus comprimentos de onda e frequências. Esse espectro cobre uma ampla faixa de radiação, que varia desde as ondas de rádio, com comprimentos de onda mais longos, até os raios gama, com comprimentos de onda extremamente curtos (Figura 2).

Figura 2. Espectro eletromagnético.

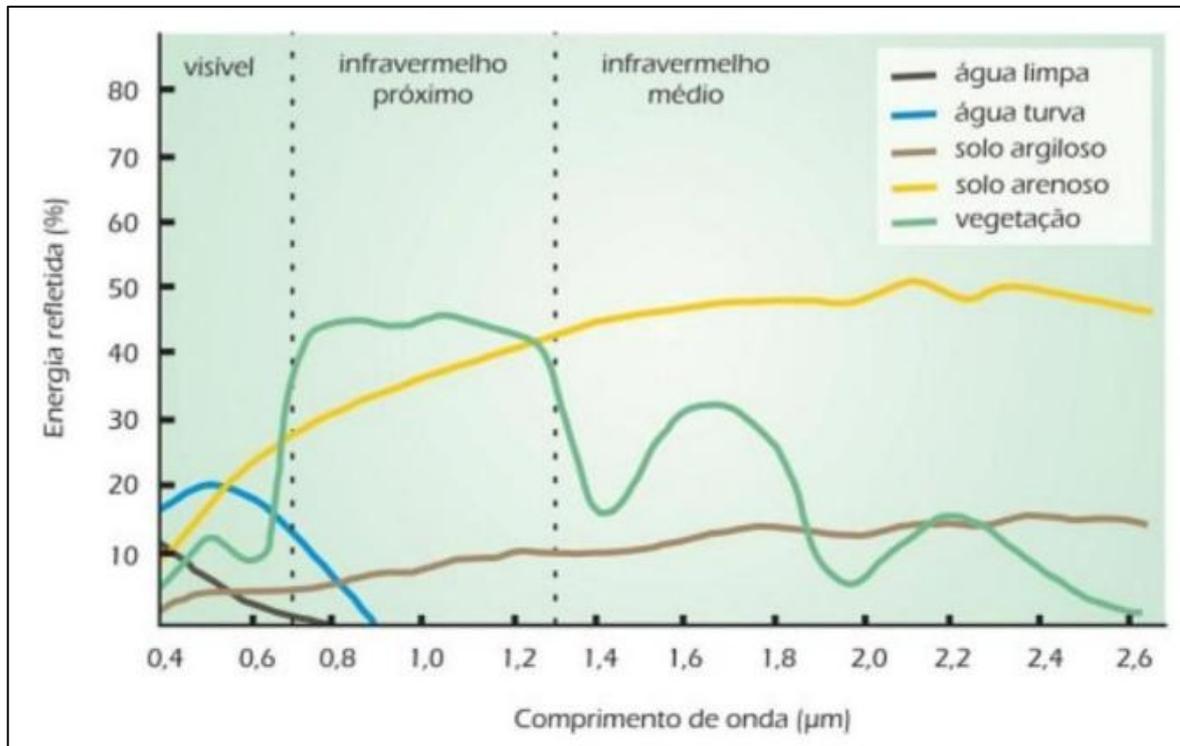


Fonte: Adaptado de Novo; Ponzoni, 2001.

A radiação refletida ou emitida pelos objetos na superfície terrestre é registrada em diferentes faixas espectrais, como o visível, infravermelho próximo e infravermelho médio, dependendo do tipo de sensor (Figura 3). Essas faixas são escolhidas com base na interação da radiação com os materiais terrestres, que pode resultar em reflexão, absorção ou transmissão,

formando assinaturas espectrais específicas. Por exemplo, vegetação saudável reflete fortemente no infravermelho próximo, enquanto corpos d'água absorvem a maior parte da radiação nas faixas do visível e infravermelho (Florenzano, 2011).

Figura 3. Curva espectral da vegetação, da água e do solo.



Fonte: Florenzano, 2011.

3.4.1. Light Detection and Ranging (LiDAR)

O sistema *Light Detection and Ranging* (LiDAR) é uma tecnologia de SR que utiliza sensores ativos para criar modelos tridimensionais de objetos e superfícies. Essa funcionalidade é alcançada por meio da emissão de pulsos laser em alta frequência direcionados aos alvos, possibilitando a medição de distâncias e ângulos com base no tempo de retorno dos pulsos (Wu *et al.*, 2019). Trata-se de um método direto de aquisição de dados, pois utiliza sua própria fonte de luz, o laser, que emite radiação eletromagnética em comprimentos de onda curtos, variando de 1 a 10 µm (Giongo *et al.*, 2010).

Para obter essas informações, o sistema LiDAR requer a integração de componentes essenciais que, em conjunto com os sensores laser, asseguram o funcionamento adequado do equipamento. Entre esses componentes, destacam-se o GPS (*Global Positioning System*) ou GNSS (*Global Navigation Satellite System*) e a IMU (*Inertial Measurement Unit*). O GPS e o

GNSS, são responsáveis por determinar a posição e a localização de objetos na superfície terrestre, com algumas diferenças importantes entre si. O GNSS fornece posicionamento geoespacial com cobertura global, enquanto o GPS determina a localização de um receptor móvel em particular (Delazari, 2023; CPE Tecnologia, 2023). Contudo, uma limitação desses sistemas é a possibilidade de atraso ou perda de sinal em áreas cobertas por florestas densas, o que pode comprometer a precisão da localização dos dispositivos (Oliveira *et al.*, 2015; Watzlawick; Sanquetta; Kirchner, 2002). Já a IMU é um dispositivo que combina acelerômetros e giroscópios para medir e relatar dados como taxa angular, aceleração, orientação e forças gravitacionais, contribuindo para a estabilização da posição de objetos (VectorNav, 2023).

Para superar as limitações do GNSS e do GPS, o sistema *Simultaneous Localization and Mapping* - SLAM vem sendo integrado ao LiDAR. Diferentemente do GNSS, o SLAM não depende de navegação por satélite para determinar a posição e localização de objetos. Em vez disso, ele realiza o mapeamento de uma área enquanto identifica sua própria localização no ambiente, estimando continuamente sua posição (GeoSLAM, 2023b). De forma simplificada, o SLAM permite que o equipamento se desloque em locais desconhecidos, identificando marcadores e sinais presentes no ambiente. Paralelamente, os pulsos de laser medem a distância entre o dispositivo e esses marcadores. O processamento integrado desses dados gera uma nuvem de pontos tridimensional do ambiente escaneado, com um nível de precisão considerado satisfatório (Flyability, 2022; Araújo, 2018).

O LiDAR pode ser utilizado em diversas plataformas, dependendo da extensão da área a ser mapeada e do nível de detalhamento exigido. Entre as opções mais utilizadas, destacam-se o *Orbital Laser Scanner* (OLS), o *Airborne Laser Scanning* (ALS), o *Unmanned Aerial Vehicle-Light Detection and Ranging* (UAV-LiDAR), o *Terrestrial Laser Scanning* (TLS), o *Mobile Laser Scanner* (MLS) e o *Portable Laser Scanning* (PLS) (Soilán *et al.*, 2019; Levick *et al.*, 2021) (Figura 4). Cada uma dessas plataformas oferece versatilidade e precisão, atendendo a diferentes necessidades de levantamento e análise espacial, desde grandes áreas até detalhes mais específicos, com a flexibilidade de se adaptar ao ambiente e à escala de mapeamento desejados.

Figura 4. Ilustração do OLS, ALS, o UAV-LiDAR, TLS, MLS e o PLS.



Fonte: Autora, 2024.

Atualmente, os estudos têm se concentrado principalmente na utilização do LiDAR nas plataformas UAV-LiDAR e TLS (Corte *et al.*, 2022; Hu *et al.*, 2021; Cabo *et al.*, 2018). Essas tecnologias têm se destacado por sua capacidade de fornecer dados precisos e detalhados, adaptando-se a diferentes escalas e necessidades de mapeamento, o que tem ampliado as possibilidades de aplicação em diversas áreas da pesquisa e da prática profissional. Ambas as plataformas fornecem dados precisos devido à alta densidade de pontos nas nuvens, mas apresentam algumas limitações dependendo do tipo de análise desejada. A plataforma UAV-LiDAR geralmente utiliza equipamentos com densidades de pontos inferiores às do TLS, o que pode dificultar a análise detalhada de sub-bosques e a identificação de elementos a nível de

indivíduo. No entanto, a plataforma UAV-LiDAR oferece a vantagem de cobrir áreas maiores em um período mais curto, mantendo uma boa acurácia dos dados coletados.

Em contrapartida, o TLS oferece nuvens de pontos com alta densidade, permitindo a coleta de informações detalhadas do sub-bosque e análises a nível de indivíduo, com boa acurácia. No entanto, sua aplicação em grandes áreas é onerosa, especialmente em florestas nativas, onde o deslocamento do equipamento no interior da vegetação pode ser dificultado, tornando o processo mais desafiador e demorado (Gollob *et al.*, 2019).

Diante dessas limitações, surgiu o PLS como uma versão aprimorada do MLS do tipo mochila, no qual os sensores eram posicionados nas costas do operador. Esses sistemas, no entanto, pesavam cerca de 30 kg, o que dificultava sua utilização prática (Liang *et al.*, 2014). Para superar essa dificuldade, estudos foram conduzidos e, em 2013, o Instituto Geodésico Finlandês (FGI) lançou um novo sistema PLS com peso reduzido para aproximadamente 10 kg, tornando-o mais acessível e eficiente para o uso em campo (Gollob; Ritter; Nothdurft, 2020). Atualmente, os equipamentos disponíveis no mercado são ainda mais leves, o que proporciona maior facilidade e mobilidade durante a operação (GEOSLAM, 2023a).

O PLS, assim como outras plataformas LiDAR, é utilizado para obter dados precisos e detalhados sobre a estrutura da floresta em tempo real. No entanto, ele se destaca em relação às demais plataformas e ao inventário tradicional por diversas vantagens. A principal vantagem do PLS é a capacidade de coletar dados de alta precisão em curtos períodos. Em um estudo de Kankare *et al.* (2013), observou-se uma melhoria significativa na precisão e eficiência do inventário florestal ao utilizar o PLS.

Outra vantagem importante é a sua habilidade de operar em áreas de difícil acesso, de forma eficiente e segura. O PLS pode ser utilizado em terrenos variados, como florestas densas ou regiões montanhosas (Giongo *et al.*, 2010), condições que muitas vezes limitam os inventários tradicionais e o uso de outras plataformas LiDAR. Além disso, em comparação com o TLS e o MLS, o PLS oferece uma varredura em campo mais rápida e simples, devido ao seu design portátil e leve, facilitando a movimentação dentro da floresta e permitindo que um único operador consiga escanear uma ampla área em um curto período (Balenović *et al.*, 2020; Bauwens *et al.*, 2016). A agilidade na coleta e análise de dados é essencial para a tomada de decisões rápidas e precisas, especialmente em emergências, como desastres naturais ou incêndios florestais. Outra vantagem significativa do PLS é sua relação custo-benefício. Embora o equipamento tenha um custo inicial relativamente alto, os dados obtidos podem ser processados rapidamente, economizando tempo e dinheiro em comparação com os métodos tradicionais de inventário florestal. Em um estudo realizado por Ryding *et al.* (2015), observou-

se uma redução considerável de custos e tempo com o uso do PLS, em comparação ao TLS e aos métodos tradicionais, tornando o PLS uma opção mais viável para inventariar florestas de grande escala.

Contudo, apesar das vantagens associadas ao uso do LiDAR, como alta precisão e capacidade de detalhamento, essa tecnologia ainda está associada a altos custos de aquisição e operação. Como alternativa, nos últimos anos, observa-se um aumento significativo no uso da aerofotogrametria, principalmente em inventários florestais, por meio de *Remotely Piloted Aircraft* (RPA). Essa tecnologia tem se destacado devido à sua capacidade de fornecer dados precisos com menor custo, tanto na aquisição e manutenção dos equipamentos quanto na operação em campo. Além disso, o uso de RPAs permite acessar áreas remotas ou de difícil acesso, oferecendo soluções eficientes e econômicas para o monitoramento de florestas, análise de biomassa e avaliação de cobertura vegetal. Os avanços em softwares de processamento fotogramétrico também têm ampliado as aplicações, possibilitando a geração de modelos tridimensionais, ortomosaicos e outras representações úteis para estudos ambientais (Neves, 2021; Almeida, 2023, Maciel, 2022).

3.4.2. Fotogrametria

A definição fornecida pela *American Society of Photogrammetry* (ISPRS) descreve a fotogrametria como “ A arte, ciência, e tecnologia de obtenção de informações confiáveis a partir de sistemas de imageamento ou outros sensores, sobre a Terra e seu meio ambiente, e outros objetos físicos, e processos por meio da gravação, medição, análise e representação”. Segundo Coelho e Brito (2009), o principal objetivo da fotogrametria é a reconstrução de um espaço tridimensional, chamando de espaço-objetivo, a partir de um conjunto não-vazio de imagens bidimensionais, chamando de espaço-imagem. Nesse contexto, Coelho e Brito (2007) definem a fotogrametria como “a ciência e tecnologia de se reconstruir o espaço tridimensional, ou parte mesmo (espaço-objeto), a partir de imagens bidimensionais, advindas da gravação de padrões de ondas eletromagnéticas (espaço-imagem), sem contato físico direto entre o sensor e o objeto ou alvo de interesse”.

Como descrito por Luhmann *et al.* (2006), a fotogrametria é classificada por diferentes critérios. Entre esses critérios, destacam-se:

Quadro 2. Critérios, Classificações e Descrições da Fotogrametria.

Critério	Classificações	Descrição
Pela posição da câmera e distância do objeto	Fotogrametria de satélite	Processamento de imagens de satélites (altura>200km);
	Fotogrametria aérea	Processamento de fotografia áreas (altura>300m);
	Fotogrametria terrestre	Medições de pontos fixos terrestres;
	Fotogrametria de curta distância	Distância menores que 300m;
	Fotogrametria microscópica	Escala da imagem > 1;
Por número de imagens de medição	Fotogrametria por uma única imagem	Processamento de uma única imagem ou retificação;
	Fotogrametria estereoscópica	Processamento de duas imagens;
	Fotogrametria por várias imagens	Processamento de mais de duas imagens;
Por método de gravação e processamento	Fotogrametria analógica	Câmeras analógicas e sistema de medição ótico-mecânico;
	Fotogrametria analítica	Imagens analógicas e medição realizada por computador;
	Fotogrametria digital	Imagens digitais e medição realizada por computador;
	Videogrametria	Aquisição e medição de imagens digitais;
	Fotogrametria panorâmica	Gravação e processamento de panoramas;
Pela disponibilidade de resultados de medição	Fotogrametria em tempo real	Gravação e medição concluída dentro de um determinado período de tempo específico para a aplicação;
	Fotogrametria off-line	Sequencial, gravação de imagem digital, separados no tempo ou local de medição;
	Fotogrametria on-line	Simultâneo, múltiplo, gravação de imagem digital, medição imediata;
Por aplicação ou área especialização	Fotogrametria arquitetônica	Arquitetura, conservação, patrimônio;
	Fotogrametria de engenharia	Aplicações de engenharia do geral;
	Fotogrametria industrial	Aplicações industriais;
	Fotogrametria Forense	Aplicações para diversos problemas legais;
	Fotogrametria biomédica	Aplicações médicas;

Fonte: Adaptado de Luhmann *et al.*, (2006)

3.4.3. Aerofotogrametria

Segundo Gonçalves (2020), a aerofotogrametria, também conhecida como fotogrametria aérea, consiste no uso de registros fotográficos aéreos para a obtenção de informações sobre um determinado local no espaço geográfico. De acordo com Tomasselli (2009), na fotogrametria aérea, as fotografias do terreno são adquiridas por meio de uma câmera de precisão instalada em uma aeronave. No entanto, essa abordagem se torna bastante onerosa devido aos custos dos equipamentos e à alta despesa operacional. Nesse contexto, uma

alternativa que tem sido amplamente adotada para realizar mapeamentos aéreos de baixo custo é a utilização de *Remotely-Piloted Aircraft* (RPA). As RPAs são equipamentos não tripulados, comandados a partir de uma estação de pilotagem remota (Bolognez *et al.*, 2021).

No Brasil, a legislação atual, representada pelo Regulamento Brasileiro da Aviação Civil – (RBAC-E) nº 94, define Aeronave Remotamente Pilotada (ARP) como aeronave não tripulada pilotada a partir de uma estação de pilotagem remota com finalidade diversa de recreação. O sistema de aeronaves remotamente pilotadas é conhecido como *Remotely-Piloted Aircraft System* (RPAS), que engloba todos os elementos, incluído a aeronave, o sistema correspondente, os dispositivos de comando e controle, e quaisquer outros componentes envolvidos na operação. Dentre as tecnologias predominantes em ARP, destacam-se os sensores *Red, Green, Blue* (RGB) e multiespectrais (Zhang *et al.*, 2019).

O funcionamento de uma ARP envolve a elaboração detalhada de um plano de voo para a área a ser mapeada. Nesse planejamento, são definidos parâmetros essenciais como a altitude, a velocidade de voo, a resolução do levantamento (*Ground Sample Distance* - GSD) e o índice de sobreposição de imagens. Este último representa a porcentagem de sobreposição entre imagens consecutivas, garantindo que pontos em comum sejam reconhecidos para o processamento e alinhamento das fotografias (Silva, 2019).

Na aerofotogrametria, o GSD é uma das variáveis mais importantes a ser definida, pois determina a resolução espacial do mapeamento e, conseqüentemente, o nível de detalhamento da área analisada (Hórus, 2018). Em termos práticos, quanto menor for o GSD, menor será a porção de terreno representada por cada pixel, resultando em imagens de maior qualidade e detalhamento (Gonçalves, 2020). Por outro lado, GSDs maiores são indicados para estudos em larga escala ou onde não se requer alta resolução.

De acordo com He, Li, Zhang (2012), o GSD pode ser calculado utilizando a seguinte fórmula:

$$GSD = \frac{Hv * Tp}{f} \quad (1)$$

Onde:

GSD: Distância da amostra do solo na imagem (cm/pixel);

Hv: Altura de voo em relação ao terreno (m);

Tp: Tamanho do pixel do sensor da câmera (mm);

f: Distância focal da câmera (mm).

Essa fórmula evidencia que o GSD é diretamente proporcional à altura de voo e ao tamanho do pixel do sensor, e inversamente proporcional à distância focal da câmera. Assim, para atingir um GSD menor e uma resolução mais alta, é necessário reduzir a altitude, utilizar sensores com pixels menores ou aumentar a distância focal da câmera. A definição precisa do GSD é um passo crítico no planejamento de voos de ARP, pois impacta diretamente a qualidade dos dados gerados e sua adequação aos objetivos do levantamento. Uma escolha criteriosa desse parâmetro garante eficiência operacional e resultados que atendam às expectativas do projeto.

A aeronave segue rigorosamente o plano de voo, seguindo todas as especificações predefinidas. Este processo é repetido várias vezes até que toda a área seja completamente mapeada. Durante essas operações, os sensores RGB e/ou multiespectrais capturam imagens. Essas imagens contêm informações de coordenadas geográficas, bem como ângulos de rotação nos eixos x, y e z (conhecidos como Parâmetros de Orientação Externa da Imagem). Além disso, são registradas a distância focal, coeficientes de distorção, coordenada principal e dimensões da placa geradora de imagens (os chamados Parâmetros de Orientação Interna da Imagem). Essas informações são essenciais para realizar o alinhamento preciso das fotografias posteriormente (Ahmad *et al.*, 2020).

Além disso, os Parâmetros de Orientação Interna da Imagem também são registrados, incluindo a distância focal, os coeficientes de distorção, as coordenadas principais e as dimensões da placa geradora de imagens. Esses parâmetros são cruciais para corrigir eventuais distorções da imagem e realizar o alinhamento preciso das fotografias capturadas, garantindo a qualidade e a acuracidade do mapeamento final. Essas informações técnicas, tanto de orientação interna quanto externa, são essenciais para o processamento e integração das imagens, permitindo a criação de modelos tridimensionais e ortomosaicos de alta precisão. A correta utilização desses dados assegura a fidelidade do mapeamento, além de facilitar a análise detalhada da área mapeada (Ahmad *et al.*, 2020).

Após a coleta dos dados com a ARP, inicia-se a fase de processamento de imagens, essencial para transformar as imagens capturadas em produtos úteis e interpretáveis. Esse processo é realizado com o auxílio de softwares especializados de fotogrametria, como o *Pix4D*, *Agisoft Metashape*, entre outros, que permitem a reconstrução da área mapeada a partir das imagens coletadas. Esses programas são capazes de processar as imagens para gerar modelos digitais de alta precisão, viabilizando uma análise detalhada do terreno. Durante o processamento, as imagens são alinhadas, corrigidas e combinadas, resultando na criação de

modelos tridimensionais e ortomosaicos. O produto final é uma representação fidedigna da área mapeada, que possibilita a realização de medições precisas de áreas, ângulos e distâncias diretamente no *software*, eliminando a necessidade de trabalho de campo adicional. Os principais produtos gerados incluem ortomosaicos, Modelos Digitais de Superfície (MDS), Modelos Digitais de Terreno (MDT), curvas de nível e índices de vegetação (Magalhães; Moura, 2021).

Conforme estipulado no RBAC-E nº 94, as ARPs são categorizadas com base em seu peso máximo de decolagem em três classes distintas: Classe 1: Compreendendo RPAs cujo peso máximo de decolagem excede 150 kg; Classe 2: Englobando ARPs cujo peso máximo de decolagem está acima de 25 kg, porém igual ou inferior a 150 kg; Classe 3: Incluindo ARPs com peso máximo de decolagem igual ou inferior a 25 kg. Conforme Angelov, (2012), as aeronaves ainda podem ser classificadas de acordo com as características aerodinâmicas, asa fixa, asa rotativa, dirigíveis, asas batedoras (*flapping-wing*) e híbridos. Entretanto, as que possuem maior representatividade no mercado são os de asa fixa e os multirrotores (Albuquerque, 2021). Cujas principais características estão elencadas no quadro abaixo.

Quadro 3. Diferenças entre os dois Modelos De Aeronaves (Asa Fixa e Multirotor).

Diferença quanto a	ARP de asa fixa	ARP multirrotores
Modo de decolagem e pouso	Horizontal	Vertical
Área de decolagem e pouso	Maior	Menor
Velocidade de voo	Maior	Menor
Autonomia da bateria	Maior	Menor
Pilotagem manual	Mais difícil	Mais fácil
Cobertura de área por voo	Maior	Menor
Aplicações mais comuns	Agricultura, mineração, topografia, monitoramento de perímetro (fronteiras), monitoramento da vida selvagem, engenharia, entre outros.	Agricultura, inspeção e fiscalização ambiental, mercado imobiliário, videografia, topografia, emergência, entre outros.
Projeto	Mais voltado para mapeamento e monitoramento de médias e grandes áreas.	Mapeamento e monitoramento de pequenas áreas, além de inspeção de obras e recursos naturais.

Fonte: SENAR, (2018).

Devido à sua variedade, as ARPs têm demonstrado ser uma ferramenta de ampla utilidade, preenchendo uma lacuna significativa no mercado e contribuindo para o avanço de diversas áreas que necessitavam de recursos tecnológicos inovadores. No âmbito da gestão territorial, elas desempenham um papel crucial no diagnóstico e monitoramento de questões como desmatamento, erosão, incêndios florestais e áreas de preservação permanente (Cândido,

2021). No que diz respeito ao monitoramento de estoques de carbono, estudos recentes indicam que o uso de sensoriamento remoto por meio de ARPs é uma abordagem válida e eficiente (Nakai, 2016; Verly, 2021; Casari, 2018; Ochoa, 2021; Almeida, 2023). Além disso, conforme destacado por Alonzo *et al.* (2020) e Cunliffe *et al.* (2021), a aplicação da fotogrametria com ARPSs, aliada a dados provenientes de inventários florestais, é capaz de fornecer estimativas precisas da biomassa acima do solo (AGB).

3.4.4. Estimativa de Biomassa Acima do Solo (AGB) com dados obtidos por LiDAR e por FDA-ARPs

A biomassa florestal é geralmente dividida em dois principais componentes: Biomassa Acima do Solo (AGB) e Biomassa Abaixo do Solo (BGB). A AGB inclui as partes visíveis das plantas, como troncos, galhos, folhas e frutos, que compõem a estrutura superficial da floresta. Por outro lado, a BGB compreende as raízes e outras estruturas subterrâneas, desempenhando um papel crucial no ciclo do carbono e na sustentação do ecossistema (Badin, 2018).

A AGB pode ser estimada de diferentes formas, sendo as mais comuns os métodos diretos e indiretos. No método direto, as árvores são abatidas e seus componentes, como troncos, galhos e folhas, são segregados e pesados para quantificar a biomassa (Silveira *et al.*, 2008). Por outro lado, o método indireto utiliza equações alométricas que convertem variáveis estruturais, como diâmetro, altura e densidade da madeira, em valores estimados de biomassa (Chave *et al.*, 2005).

Nos últimos anos, técnicas de SR, como LiDAR e aerofotogrametria, têm sido cada vez mais utilizadas para estimativas indiretas de AGB em ambientes florestais. Estudos como os de Machado (2023), Andersen *et al.* (2014), Figueiredo *et al.* (2016), Cao (2019), D'Oliveira *et al.* (2020), Rex *et al.* (2020), Machado (2023), Costa (2023), Rocha *et al.* (2023) abordam a aplicação do LiDAR, enquanto a aerofotogrametria tem sido explorada por pesquisadores como Neves (2021), Trevisan (2023), Cabral *et al.* (2023). Esses estudos demonstram a eficácia da aerofotogrametria, frequentemente associada ao uso de ARPs, para capturar imagens de alta resolução e gerar Modelos Digitais de Superfície (MDS), que podem ser utilizados para estimar a biomassa florestal. A combinação dessas tecnologias tem se mostrado promissora, permitindo uma análise precisa da estrutura da vegetação e proporcionando estimativas de AGB em áreas amplas e de difícil acesso.

Embora os manguezais desempenhem um papel crucial no equilíbrio ecológico, sua biomassa e estrutura ainda são áreas de estudo em evolução, especialmente com o uso de tecnologias como LiDAR e aerofotogrametria. Ainda que existem diversos estudos sobre o uso dessas tecnologias em florestas tropicais e outros biomas, a aplicação para estimativas de biomassa em manguezais é relativamente recente e ainda pouco explorada na literatura. A combinação de LiDAR e ARPs para o mapeamento e análise da vegetação de manguezais tem mostrado grande potencial, mas poucos trabalhos abordam especificamente esse ecossistema.

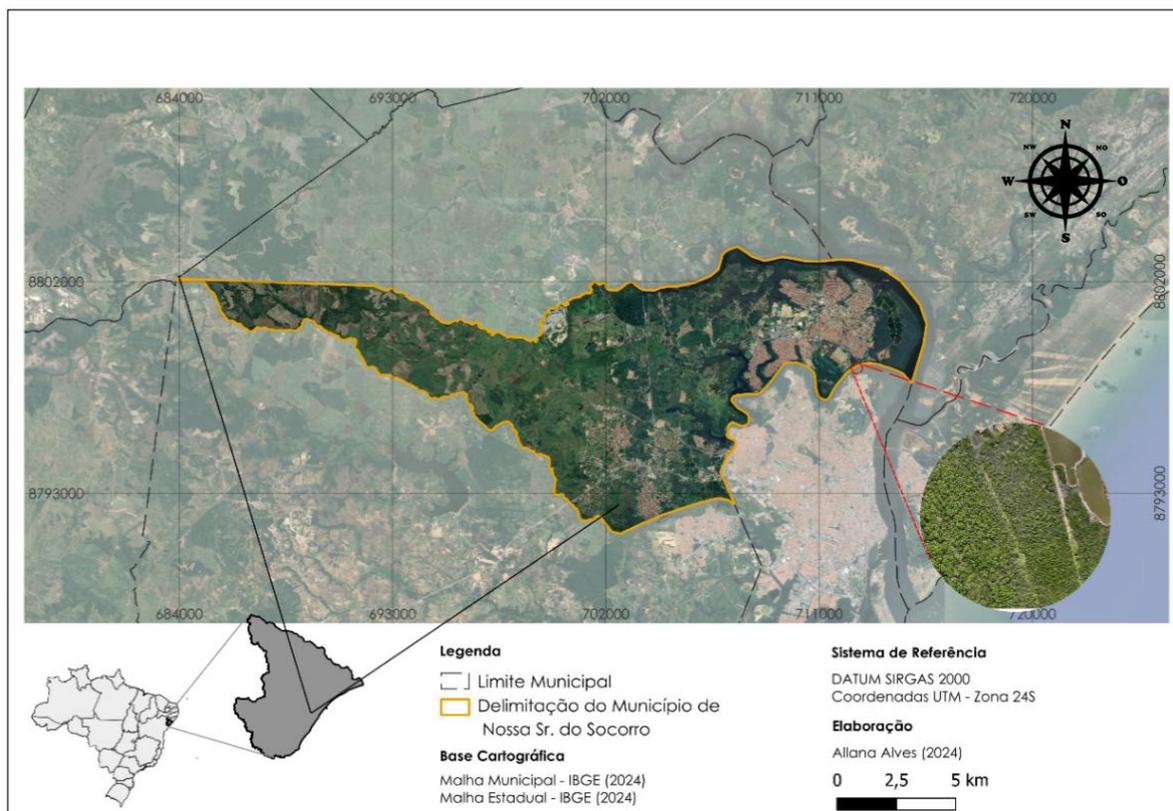
Exemplos de estudos recentes que começam a explorar essa temática incluem o trabalho de Wang *et al.* (2020), Salum *et al.* (2024), Wong *et al.* (2024) que aplicou o LiDAR para estimativa de biomassa. Já Navarro *et al.* (2020), Basyuni *et al.* (2023), Li *et al.* (2024), que utilizaram ARPs para estimar biomassa em manguezais. Esses estudos são importantes para ampliar o conhecimento sobre a biomassa de manguezais e o papel desses ecossistemas na mitigação das mudanças climáticas, permitindo uma análise mais detalhada e precisa, principalmente em regiões de difícil acesso.

4. MATERIAL E MÉTODOS

4.1. Localização e caracterização da área de estudo

O clima da região, segundo a classificação de Köppen, é do tipo As (tropical mesotérmico), caracterizado por uma temperatura média anual de 25,5°C e uma incidência média anual de 1.413 mm. Este estudo foi realizado em uma área de regeneração natural de manguezal situada às margens do Rio do Sal, no município de Nossa Senhora do Socorro/SE, com coordenadas centrais UTM X/Y: 712529,64/8798742,94 (Figura 5). Até o ano de 2013, a área era utilizada para a carcinicultura, atividade que impactou significativamente a vegetação original do manguezal devido à modificação do sedimento, salinização e remoção da cobertura vegetal.

Figura 5. Localização da Área de Estudo.



Fonte: Autora, 2024.

O Rio do Sal é um afluente de grande importância para o Rio Sergipe, situado na região Norte do estado de Sergipe, com uma extensão de 20,5 km e drenando uma bacia de aproximadamente 62 km², ele desempenha um papel vital no abastecimento público do

município de Nossa Senhora do Socorro e das áreas periféricas de Aracaju, como os bairros Lamarão, Bugio, Soledade e Porto Dantas (Alves, 2006; Araújo, 1969).

4.2. Fotogrametria aérea digital (FAD)

4.2.1. Aquisição das Fotografias Aéreas Digital

As fotografias aéreas de alta resolução espacial, foram capturadas por uma ARP DJI Mavic 3 Multispectral em 04 de junho de 2024 (Figura 6).

Figura 6. Equipamentos utilizados para a obtenção dos dados de sensoriamento remoto via ARP: (A) ARP DJI Mavic 3 Multispectral; (B e C) receptor Emlid RTK GNSS Reach RS2 para coleta de coordenadas em tempo real.



Fonte: Autora, 2024.

Esta aeronave é equipada com uma câmera digital RGB (Red-R, Green-G, Blue-B) de 20 megapixel (MP) e uma câmera multiespectral de quatro bandas: Vermelho (R), Verde (G), Borda Vermelha (RE) e Infravermelho Próximo (NIR). As condições climáticas durante a aquisição das imagens foram ideais, com céu limpo e ventos moderados (menos de 10 m/s). A operação foi realizada em um único voo, com duração de 12 minutos e 59 segundos, cobrindo uma área de 8,10 hectares. A altitude de voo foi estabelecida em 60 metros acima do nível do solo, com uma sobreposição frontal de 70% e lateral de 80%. Os parâmetros detalhados do voo são apresentados na Tabela 1.

Tabela 1. Parâmetros de aquisição das imagens.

Parâmetro	
Área de Cobertura (ha)	8,10
Altura do Voo (m)	60
Velocidade do Voo (m/s)	8
Tempo médio de Voo (min)	12''
Sobreposição Frontal (%)	70
Sobreposição Lateral (%)	80
GSD (cm/pixel)	2,77
Sensor	CMOS de 4/3: 20 MP
Bandas Espectrais	Red, Green e Blue
Números de Imagens	387
Formato de Imagem	JPG

Fonte: Autora, 2024.

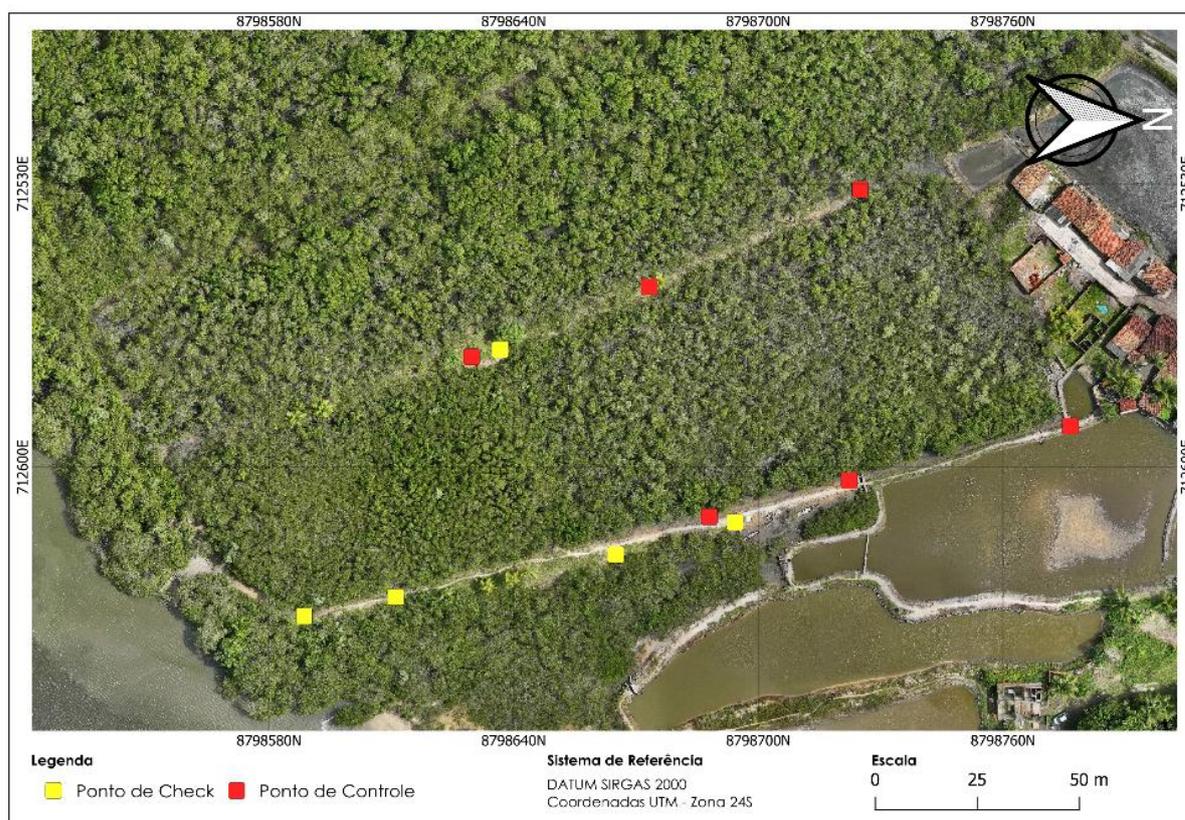
4.2.2. Processamento Fotográfico do FAD

No processamento fotográfico, o tratamento dos dados obtidos por imageamento aéreo teve a finalidade de georreferenciar as imagens, processo conhecido como *geotag*. O objetivo principal deste procedimento foi incorporar informações essenciais de latitude, longitude e altitude às fotografias capturadas pela Aeronave Remotamente Pilotada (ARP).

As imagens adquiridas foram processadas no software *Agisoft Metashape Professional Edition* versão 2.1.0 (AGISOFT, St. Petersburg, Russia), para gerar informações tridimensionais do terreno e sua superfície no formato de nuvem de pontos (x, y e z) (Almeida *et al.*, 2020). O Metashape é um *software* de fotogrametria que utiliza um conjunto de algoritmos de visão computacional *Structure from Motion* (SfM) e algoritmos de correspondência estéreo fotogramétrico para reconstrução 3D de imagens sobrepostas (Iglhaut *et al.*, 2019).

As imagens coletadas foram georreferenciadas com 5 pontos de checagem e 6 pontos de controle. Esses pontos foram distribuídos aleatoriamente na área de estudo (Figura 7).

Figura 7. Mapa de localização dos pontos de check e pontos de controle alocados na área de estudo.



Fonte: Autora, 2024.

Todos os 11 pontos foram coletados com o receptor *Emlid RTK GNSS Reach RS2* (Figuras 6B e 6C), disponível em <https://loja.emlid.com.br/product/reach-rs2-plus/>, resultando em um erro horizontal médio (X e Y) de 0,01 m. Importante destacar que todos os pontos foram marcados em áreas com ausência de vegetação, permitindo sua visualização durante o processo de alinhamento (Figura 6B). Ao final do processamento, os valores do EQM dos pontos de checagem foram de 0,02 m (horizontal) e 0,03 m (vertical) (Anexo 1).

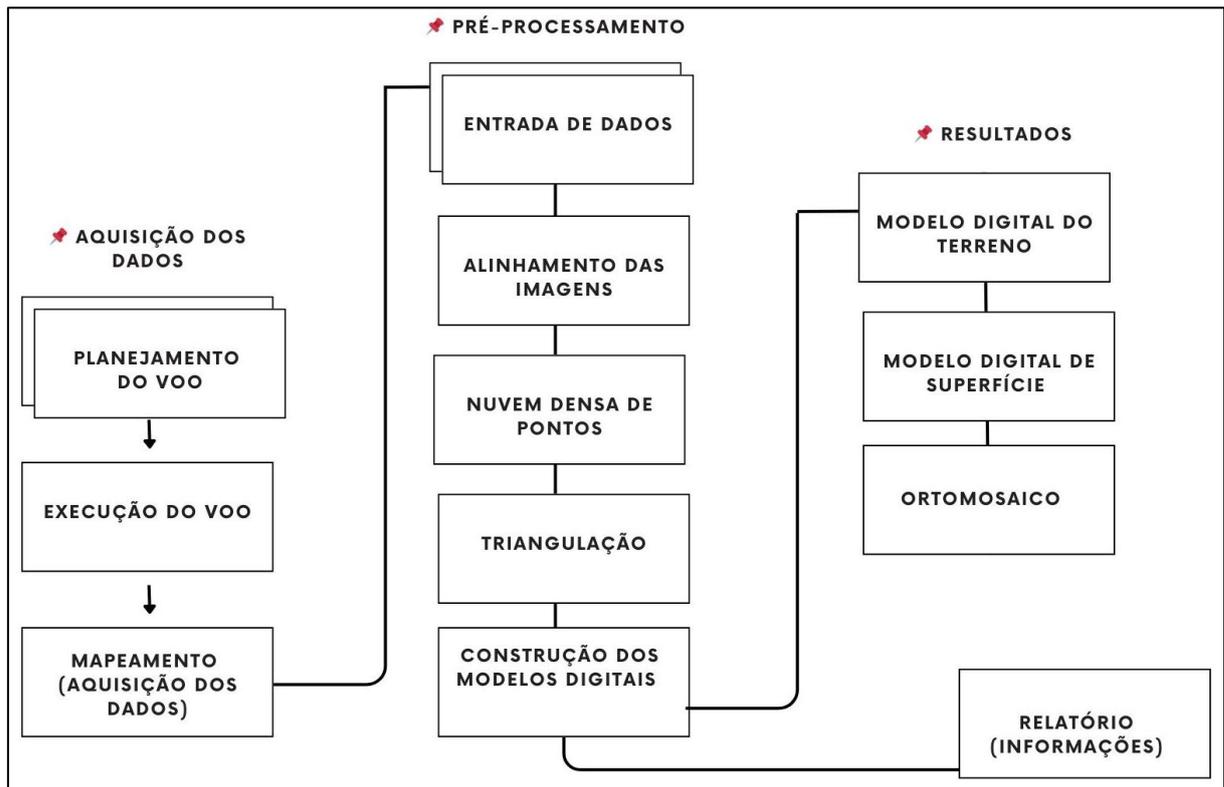
Para o alinhamento da imagem foram utilizados a acurácia alta (*accuracy high*), seleção de par referência, pontos principais (*key points*) igual a 40.000, pontos de amarração (*tie points*) igual a 4.000. No posicionamento guiado do marcador foram realocados manualmente 6 pontos de controle e 5 pontos de verificação. Para a construção de nuvens densa de pontos foram definidos qualidade média (*quality médium*) e modo de filtragem suave (*filtering mode mild*) (Almeida, 2023).

O Modelo Digital do Terreno (MDT) foi criado a partir da nuvem de pontos 3D da FAD utilizando o algoritmo *Adaptive Triangulated Irregular Network* (TIN) desenvolvido por Axelsson (2019), implementado no Agisoft Metashape. Nesta etapa, os pontos respresentativos

do terreno da nuvem de pontos 3D são classificados e posteriormente interpolados. Ao final do processo, a nuvem de pontos 3D FAD foi exportada no formato de arquivo (“.las”) e o MDT no formato raster (“.tif”) com resolução espacial de 20 cm.

As etapas que envolvem todo o fluxograma do mapeamento da aerofotogrametria estão apresentadas na Figura 8.

Figura 8. Fases do mapeamento aerofotogramétrico.



Fonte: Adaptado de Santos da Silva (2018).

4.3. Instrumentação e coleta de dados do light detection and ranging (LiDAR)

A área de estudo foi escaneada de forma terrestre utilizando o equipamento GeoSLAM ZEB-HORIZON 3D (Figura 9a), modelo GS_510254 (GEOSLAM, 2023a). Este equipamento de varredura laser portátil (PLS) é leve, pesando apenas 6,96 kg, e é composto por um scanner a laser 2D que opera a um comprimento de onda de 903 nm, acoplado a uma Unidade de Medida Inercial (IMU) motorizada. Além do IMU, o equipamento conta com o algoritmo *Simultaneous Localization and Mapping* (SLAM), que combina os dados de varredura a laser 2D com os dados da IMU para gerar nuvens de pontos 3D acuradas. O laser é equipado com 16 sensores e possui uma taxa de aquisição de 300.000 pontos por segundo, com um alcance aproximado de

100 metros. Outras especificações técnicas estão apresentadas na Tabela 2 (GEOSLAM, 2023a).

Figura 9. Equipamentos utilizados para a obtenção dos dados de sensoriamento remoto via LiDAR (PLS): (A) GeoSLAM ZEB-HORIZON 3D; (B) receptor Emlid RTK GNSS Reach RS2 para coleta de coordenadas em tempo real.



Fonte: Autora, 2024.

Tabela 2. Parâmetros do LiDAR (PLS).

Parâmetro	
Alcance máximo (m)	100
Pontos por linha de varredura	937 (intervalo de 0,38°)
Campo de Visão	360°x270°
Taxa de Varredura	300.00 pontos/s 160 linhas/s (16 linhas @10Hz)
Ruído de Alcance de Varredura	
Segurança do Laser	Classe 1 Seguro para os Olhos de Acordo com IEC 60825-1:2007 e 2014
Classificação	
Temperatura de Operação	0°C + 40°C
Índice de proteção	1P54
Fonte de Energia	14,8 VDC ~ 1.5 A
Peso	Cabeça de Digitalização com o Cabo: 1,49kg Registrador de Dados: 0,72 kg Bateria: 0,55kg Bolsa de Transporte e Conteúdo: 4,2kg
Dimensões	Cabeça de Digitação 216x108x266mm (153mm sem alça); Bolsa de Transporte e Conteúdo 470x220x180mm
Duração da Bateria	3h30 min.

Fonte: GEOSLAM, 2023a.

O escaneamento foi realizado manualmente por um único operador de campo em condições meteorológicas favoráveis, com céu claro, velocidade do vento de aproximadamente 1,4 m/s e temperatura média do ar em torno de 26°C. Para a aquisição dos dados, foi desenhado

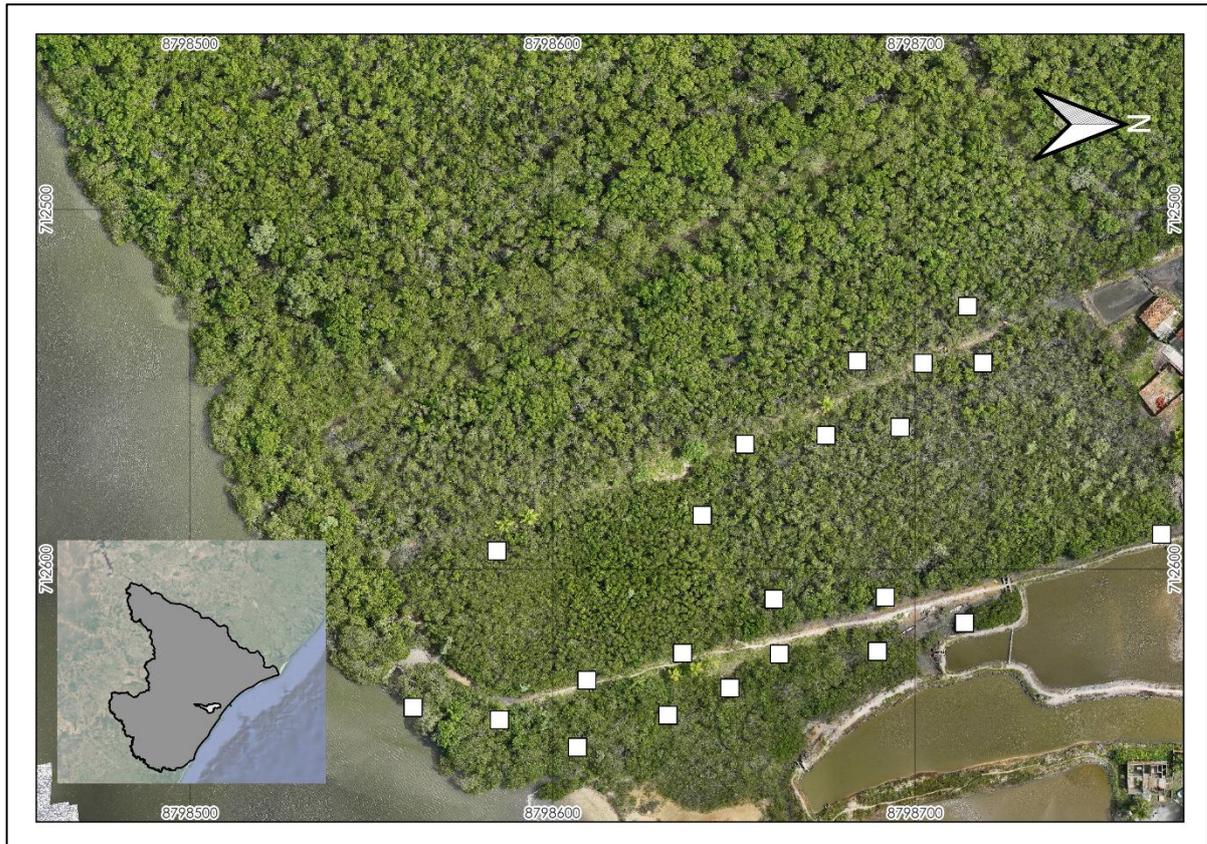
um percurso de caminhada em *loop* fechado, visando a aquisição de pontos de georreferenciamento e a redução de oclusões. O operador seguiu a rota planejada enquanto realizava o escaneamento, a uma altura aproximada de 1,4 m acima do solo. O período total de varredura foi de cerca de seis minutos e 24 segundos. Durante a coleta, os dados tridimensionais foram armazenados simultaneamente no disco do *data logger* em formato comprimido, sendo posteriormente transferidos e processados em *desktop* utilizando o *software GeoSLAM Hub*.

Para finalizar a extração da nuvem de pontos no *software GeoSLAM Hub*, foi necessário o *input* das coordenadas geográficas dos pontos de referência do caminhada. O ponto inicial do trajeto foi definido como a origem das coordenadas (x, y, z). Após este processo, as nuvens de pontos extraídas no *GeoSLAM Hub* foram convertidas para o formato LAZ, uma versão compactada do formato LAS, amplamente compatível com diversos *softwares* de processamento de nuvens de pontos. Todo o processamento subsequente foi realizado no *software CloudCompare*, com o uso da extensão *3DFin* para refinar e analisar os dados.

4.4. Inventário florestal das variáveis dendrométricas

O inventário florestal foi conduzido entre os meses de outubro a novembro de 2024. A amostragem das variáveis dendrométricas da vegetação de mangue foi obtida por meio do inventário florestal do fragmento estudado, utilizando-se o processo de amostragem aleatória com parcelas de área fixa. Foram alocadas 22 parcelas de 25 m² (5 x 5 m), correspondendo a uma amostra de 0,055 ha (Figura 10).

Figura 10. Mapa de localização das parcelas alocadas na área de estudo.



Fonte: Autora, 2024.

A distribuição espacial das parcelas foi planejada com base no mapeamento da área pelo sistema LiDAR, assegurando uma cobertura representativa e precisa do ecossistema estudado. Para o georreferenciamento dos quatro vértices de cada parcela, utilizou-se um receptor Emlid RTK GNSS Reach RS2, garantindo alta precisão nas coordenadas registradas.

Durante o levantamento de campo, foram mensuradas a Circunferência à 1,30 metros do nível do solo (CAP) em cm, e a altura total (Ht) em m, de cada indivíduo arbóreo cuja origem estivesse dentro dos limites das parcelas. Apenas os indivíduos com CAP maior ou igual a 15 cm foram mensurados. As alturas totais foram obtidas com o auxílio do clinômetro digital *haglof* (Figura 11). A CAP das árvores foram medidas com auxílio de uma fita métrica, posteriormente transformadas para DAP.

Figura 11. Medição das alturas totais das árvores nas 22 parcelas inventariadas.



Fonte: Autora, 2024.

Os dados do inventário foram utilizados para estimar a biomassa acima do solo (Mg. ha⁻¹). As estatísticas descritivas do inventário florestal realizado por amostragem aleatória com um total de 22 parcelas de área fixa no fragmento de mangue, são apresentadas na Tabela 3.

Tabela 3. Estatísticas descritivas do DAP e Ht do inventário florestal das 22 parcelas amostradas no manguezal localizado nas margens do Rio do Sal, no município de Nossa Senhora do Socorro/SE.

Variável	Sigla	Média	Altura Máxima	Amplitude	Desvio Padrão
Diâmetro (cm)	Dap	7,20	21,5	16,73	3,39
Altura (m)	Ht	5,47	9,00	7,00	1,41

4.5. Estimativa de biomassa acima do solo

A biomassa acima do solo dos indivíduos arbóreos foi calculada com o uso da equação alométrica pantropical desenvolvido por Chave *et al.* (2014) (Equação 2). A equação baseia-se nas medições do DAP, Ht e Densidade da Madeira (ρ) em g/cm³. A ρ foi obtida a partir dos valores experimentais médios tabelados por Chave *et al.* (2006).

$$AGB = 0.0673 \cdot (DAP^2 \cdot Ht \cdot \rho)^{0.976} \quad (2)$$

Onde:

AGB = Biomassa acima do solo (kg);

DAP = Diâmetro á Altura do Peito (cm);

H_t = Altura Total (m);

ρ = Densidade da madeira (g/cm^3).

Os valores de biomassa estimados pela equação foram posteriormente convertidos de quilogramas (kg) para megagramas por hectare (Mg. ha^{-1}), garantindo a padronização das unidades para a análise da distribuição espacial da biomassa no estudo.

4.6. Métricas da nuvem de pontos do LiDAR e FAD-ARP

Para comparar os dados LiDAR e FAD-ARP, foram calculados dois conjuntos de métricas a partir das nuvens de pontos LiDAR e UAV-DAP normalizadas, classificados como métricas padrões e métricas de dossel (Tabela 3). Esses conjuntos incluíram: Métricas baseadas em altura: $H_5, H_{10}, H_{15}, H_{20}, H_{25}, H_{30}, H_{35}, H_{40}, H_{45}, H_{50}, H_{55}, H_{60}, H_{65}, H_{70}, H_{75}, H_{80}, H_{85}, H_{90}$ e H_{95} , $H_{\text{média}}$, H_{cv} e $H_{\text{máx}}$; Métricas baseadas em densidade: $D_1, D_2, D_3, D_4, D_5, D_6, D_7, D_8, D_9$; Cobertura do dossel: $CC_{\text{média}}$; As descrições detalhadas das métricas LiDAR e UAV-DAP estão apresentadas na Tabela 4. Todas as métricas foram extraídas utilizando o ambiente R (R CORE TEAM, 2025), com o suporte do pacote lidR.

Tabela 4. Descrição das métricas derivadas de nuvens de pontos do LiDAR e da FAD-ARP.

	Métrica	Descrição	LiDAR	FAD-ARP
Baseado em altura	Percentis de altura ($H_5, H_{10}, \dots, H_{95}$)	Percentis das distribuições de altura do dossel	✓	✓
	$H_{\text{média}}$	Altura média	✓	✓
	H_{cv}	Coefficiente de variação de alturas	✓	✓
	$H_{\text{máx.}}$	Altura máxima	✓	✓
Baseado em densidade	Densidade de retorno do dossel ($D_1 - D_9$)	Proporção de pontos acima dos quantis (10%, 20%, ..., 90%)	✓	✓
Cobertura de dossel	Cobertura do dossel acima da altura média (CC 2m)	Porcentagem de altura de retorno acima de 2m	✓	✓
	Cobertura do dossel acima da altura média (média CC)	Porcentagens de altura de retorno acima da altura média da nuvem de pontos	✓	✓

Os valores das métricas extraídas do LiDAR e do FAD-ARP foram associados à biomassa acima do solo estimada para as 22 parcelas de vegetação de mangue no município de

Nossa Senhora do Socorro, Sergipe. Além disso, as métricas foram comparadas entre si para avaliar a representatividade de cada metodologia empregada na estimativa da biomassa.

4.7. Análise dos dados

Modelos de regressão múltipla, utilizando o método dos mínimos quadrados ordinários, foram empregados para estimar a biomassa. Como variáveis explicativas, foram consideradas métricas tradicionais derivadas das alturas da nuvem de pontos do LiDAR e FAD-ARP. A implementação foi realizada na linguagem R (R CORE TEAM, 2025), utilizando o pacote leaps (Miller, 2020).

Diversas combinações de variáveis foram testadas, aplicando transformações logarítmicas, raiz quadrada e mantendo os dados na forma original para a biomassa. Inicialmente, a seleção do número de variáveis do modelo foi baseada no critério de informação bayesiano (BIC) e no coeficiente de determinação (R^2).

Após essa etapa, foram escolhidos os cinco modelos candidatos mais promissores. O modelo final foi definido considerando a ausência de multicolinearidade entre as variáveis preditoras e a minimização do erro quadrático médio (EQM) tanto no ajuste quanto na validação cruzada (EQMVC). A capacidade preditiva dos modelos foi avaliada por meio de validação cruzada, dividindo os dados aleatoriamente em conjuntos de treinamento (80%) e validação (20%) ao longo de 1.000 iterações.

A análise de multicolinearidade foi conduzida por meio do fator de inflação de variância (VIF), descartando modelos em que as variáveis preditoras apresentaram valores superiores a 10. A validação cruzada foi aplicada independentemente, com 1.000 repetições em 20% da amostra.

Por fim, o modelo foi examinado considerando gráficos de diagnóstico, interpretação dos coeficientes e testes estatísticos, incluindo o teste de normalidade de Shapiro-Wilk e a verificação da homocedasticidade pelo teste de Bartlett. Durante o ajuste do modelo, foram levadas em conta as diferentes fontes de incerteza associadas à estimativa da biomassa de referência em cada parcela.

4.8. Estimação da biomassa acima do solo por RLM

A extração e seleção das variáveis independentes para a modelagem, pelas métricas LiDAR e FAD-ARP, foram realizadas com o auxílio do software R versão 2024.12.1+563 (R CORE TEAM, 2025), com o uso dos pacotes `car`, `leaps`, `randomForest`, `QuantPsyc`. Para a seleção das variáveis independentes do modelo, foi utilizado o pacote `leaps`. O método de seleção utilizado foi o de busca exaustiva (algoritmo *exhaustive*), que testa e compara todas as variáveis independentes, no qual busca encontrar o melhor subconjunto de variáveis em X para prever Y na regressão linear, utilizando o algoritmo *branch-and-bound* (ramificação e limitação) (MILLER, 2002).

Após a seleção das variáveis independentes, foi realizado o ajuste do modelo de RLM:

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_p X_{pi} + \varepsilon_i \quad (4)$$

Onde:

Y_i = Variável dependente (resposta), ou seja, o valor que se deseja estimar ou prever.

β_0 = Intercepto do modelo, que representa o valor de Y_i quando todas as variáveis independentes são zero;

$\beta_1, \beta_2, \dots, \beta_p$ = Coeficientes de regressão associados a cada variável independente, indicando a magnitude e direção do efeito de cada variável sobre Y_i ;

$X_{1i}, X_{2i}, \dots, X_{pi}$ = Variáveis independentes (preditoras), que explicam a variabilidade de Y_i ;

ε_i = Termo de erro aleatório, que captura a variação em Y_i não explicada pelo modelo, assumindo uma distribuição normal com média zero e variância constante σ^2 .

4.9. Critérios de avaliação das estimativas obtidas por RLM

Para avaliação das estimativas geradas pelos modelos, para ajuste e validação cruzada, foram obtidas as seguintes estatísticas: coeficiente de determinação (R^2), erro quadrático médio (EQM e EQM%) e o viés (V e V%) (Equações 4, 5, 6 e 7).

$$\text{EQM(absolute)} = \sqrt{\frac{(\sum_{i=1}^n Y_{\text{obs}} - \sum_{i=1}^n Y_{\text{est}})^2}{n}} * 100 \quad (5)$$

$$\text{EQM (\%)} = \frac{\text{RMSE}_{(\text{abs})}}{Y_{\text{med}}} * 100 \quad (6)$$

$$V (\text{absolute}) = \frac{\sum_{i=1}^n Y_{\text{obs}} - \sum_{i=1}^n Y_{\text{est}}}{n} \quad (7)$$

$$V (\%) = \frac{\text{Vies}_{(\text{abs})}}{Y_{\text{med}}} * 100 \quad (8)$$

Onde:

Y_{obs} = variável observada;

Y_{est} = variável estimada;

Y_{med} = valor médio da variável observada;

n = número de amostras.

5. RESULTADOS E DISCUSSÃO

5.1. Caracterização de AGB por parcela

A caracterização da Biomassa Acima do Solo (AGB) por parcela (Tabela 5) reflete a heterogeneidade estrutural do ecossistema estudado, a produtividade primária e fornece informações essenciais para a compreensão da distribuição da biomassa vegetal. Os valores de AGB obtidos nas parcelas analisadas variaram, com um mínimo de 2,00 Mg. ha⁻¹ (Parcela 6) e um máximo de 246,07 Mg.ha⁻¹ (Parcela 9). Essa variação pode ser explicada por diferenças nas condições ambientais, nos estágios sucessionais da vegetação e na densidade das espécies arbóreas. Parcelas com altos valores de biomassa, como a parcela 9, 15 e 12, com 246,07 Mg.ha⁻¹, 182,18 Mg.ha⁻¹ e 135,82 Mg.ha⁻¹, respectivamente, indicam a presença de vegetação mais desenvolvida e estruturada, possivelmente associada a maior densidade de indivíduos e à predominância de espécies arbóreas de maior porte.

Por outro lado, parcelas como a 6, 21 e 18, com 2,00 Mg.ha⁻¹, 5,02 Mg.ha⁻¹ e 6,29 Mg.ha⁻¹, apresentam valores mais baixos. Esse padrão demonstra que, apesar da área ser pequena e o processo de regeneração natural ter sido iniciado ao mesmo tempo, há uma variabilidade na regeneração. Adicionalmente, em algumas áreas, a coleta pontual de madeira para a construção de viveiros de carcinicultura, que envolve o corte de indivíduos de maior diâmetro, altura e biomassa, pode alterar significativamente a densidade de árvores e a biomassa por hectare, influenciando os valores de AGB nessas parcelas.

Tabela 5. Estimativa de Biomassa Acima do Solo (AGB) (Mg. ha⁻¹) das parcelas amostradas no manguezal localizado nas margens do Rio do Sal, no município de Nossa Senhora do Socorro/SE

Número da Parcela	Biomassa Acima do Solo (Mg. ha ⁻¹)
1	52,52
2	41,67
3	125,07
4	59,47
5	134,33
6	2,00
7	9,00
8	35,77
9	246,07
10	131,94
11	63,79
12	135,82
13	86,60
14	23,90
15	182,18
16	7,29
17	30,54
18	6,29
19	41,54
20	15,33
21	5,02
22	16,90

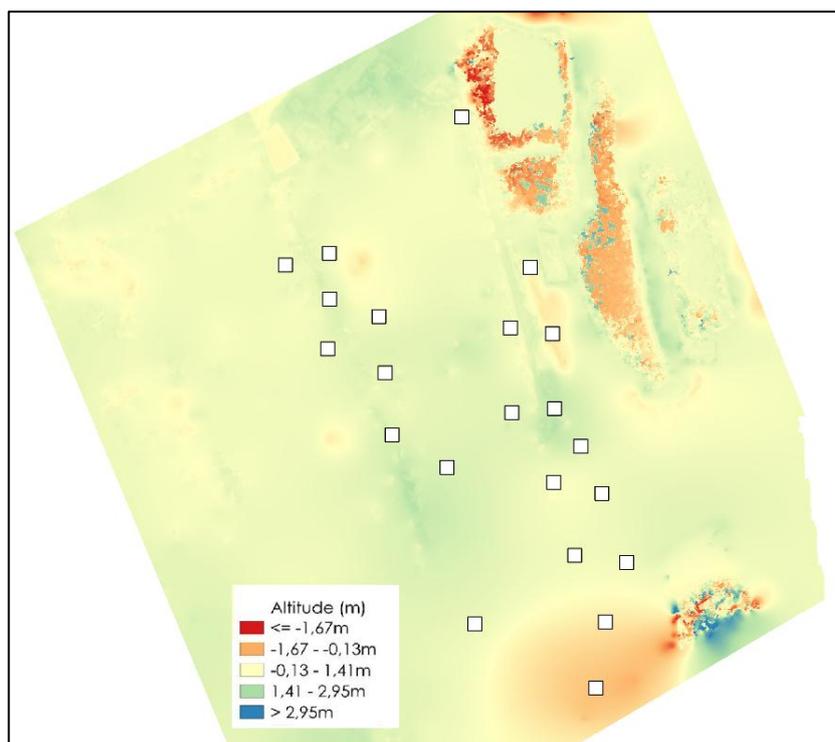
Em estudos similares, Kauffman *et al.* (2018a) registraram aproximadamente 145 Mg.ha⁻¹ na foz do Rio Amazonas. Nos manguezais do Pará, os valores registrados variaram de 38,98 Mg.ha⁻¹ a 159 Mg.ha⁻¹, conforme os estudos de Kauffman *et al.* (2018b) e Virgulino *et al.* (2020). Essa ampla variação pode ser atribuída a fatores como diferenças nas condições ambientais dos manguezais analisados, variações nos métodos de coleta de dados ou abordagens distintas na análise dos resultados. No Espírito Santo, Gomes *et al.* (2021) e Leite *et al.* (2021) estimaram 129 Mg.ha⁻¹ e 41,4 Mg C/ha, respectivamente. Já no Ceará, Kauffman *et al.* (2018) relataram valores de 70 Mg.ha⁻¹.

Essas variações nos valores de biomassa refletem as diferenças estruturais dos manguezais, que são influenciadas por fatores regionais, como latitude, compartimentação geológica e geomorfológica, bem como pelas condições ambientais locais (Schaeffer-Novelli *et al.*, 1990c).

5.2. Validação da FAD-ARP

Na Figura 12, pode-se verificar o Modelo Digital do Terreno (MDT) gerado por FAD- ARP, além das 22 parcelas de inventário. A área apresenta um relevo irregular e ondulado, com valores de altitude abaixo de 3 m.

Figura 12. Modelo Digital do Terreno (MDT) obtido pela FAD-ARP nas 22 parcelas inventariadas.



A Tabela 6 apresenta os valores estimados pela FAD-ARP, enquanto a Figura 13 ilustra o gráfico de dispersão entre os valores medidos e estimados. Observou-se uma correlação de entre os valores estimados pela FAD-ARP e os valores observados com o RTK.

Apesar disso, identificou-se uma tendência de superestimação nas altitudes (EQM de 0,30 m e 20,83%). Esse resultado é esperado, considerando que ecossistemas de manguezais tendem a acumular lama no solo, o que frequentemente resulta em pontos de solo mais

elevados em relação às áreas circundantes. Esse fenômeno pode levar à subestimação do Modelo Digital de Terreno (MDT) gerado pelo método ARP (Navaro *et al.*, 2020).

Figura 13. Gráfico de dispersão entre os valores de elevação do terreno coletados em campo com o RTK e os valores de elevação do MDT derivado da FAD-ARP.

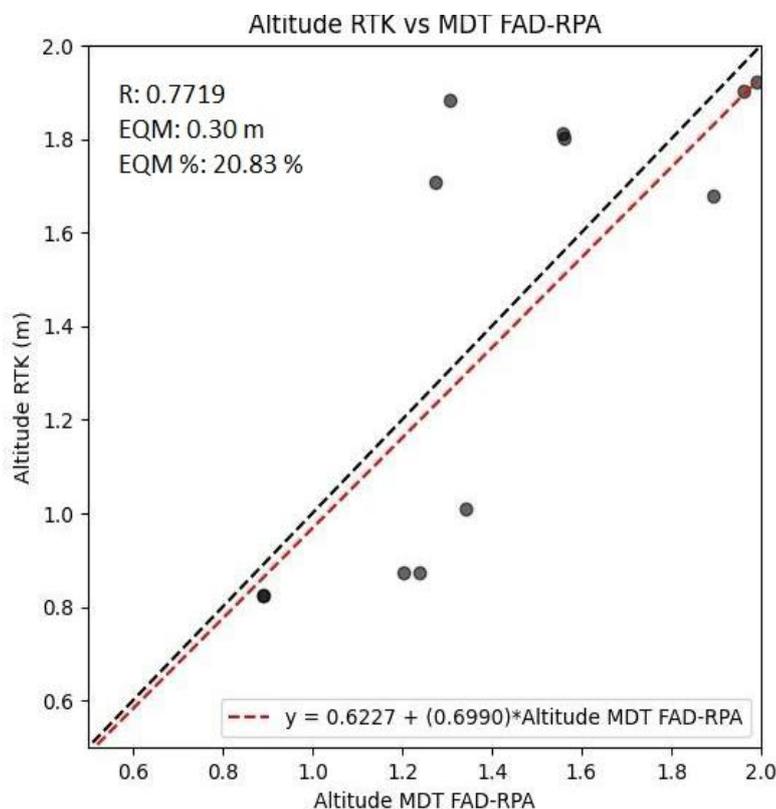


Tabela 6. Estatística dos valores estimados pela FAD-ARP.

	EQM	EQM (%)	Viés	Viés (%)	R ²
Resultado	0,30	20,83	2,683028e ⁻¹⁶	1,881638e ⁻¹⁴	0,60

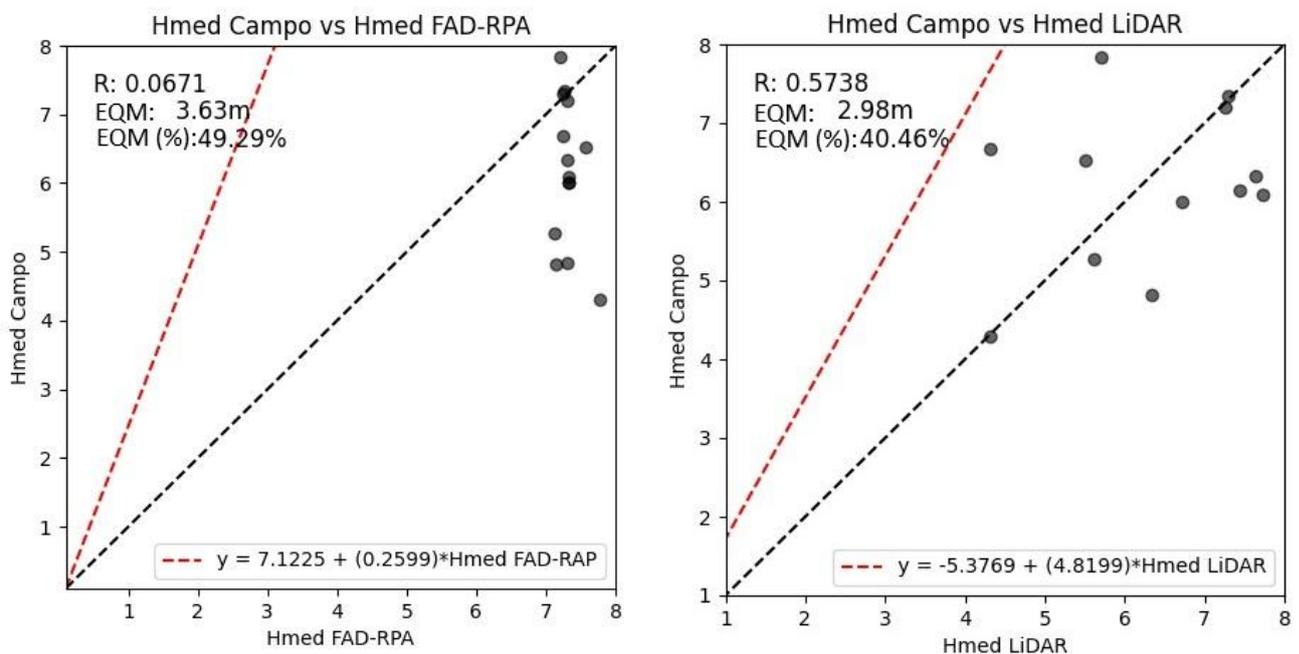
5.3. Altura Máxima Observada x Altura Máxima FDA-ARP e LiDAR

A Tabela 7 apresenta os resultados da análise de acurácia das estimativas de altura máxima das árvores por parcela, comparando as técnicas FAD-RAP e LiDAR. A Figura 14 exhibe os gráficos de dispersão que ilustram a comparação entre os valores de altura máxima observados em campo e os estimados (H_{máx}) a partir das nuvens de pontos 3D geradas pelas duas tecnologias. Observa-se uma discrepância considerável entre as estimativas de H_{máx} originadas do FAD-RAP e do LiDAR, refletindo diferenças nas precisões dessas metodologias. Tal variação pode ser atribuída às características intrínsecas de cada tecnologia e às condições ambientais que afetam sua performance.

Tabela 7. Estatística da comparação entre a métrica H_{máx} obtida por (a) FAD-ARP (b) LiDAR comparadas com a altura máxima observada.

	H _{máx} observada x H _{máx} FAD-ARP	H _{máx} observada x H _{máx} LiDAR
EQM	1,33	0,38
EQM (%)	21,31	6,08
Viés	-4,440892e ⁻¹⁶	4,037101e ⁻¹⁶
Viés (%)	-7,100264e ⁻¹⁵	4,037101e ⁻¹⁶
R ²	0,071	0,92

Figura 14. Gráficos de dispersão entre a métrica H_{máx} obtida por (a) FAD-ARP (b) LiDAR comparadas com a altura máxima observada.



A técnica FAD-ARP, que utiliza a radiação fotossinteticamente ativa refletida para estimar as características da vegetação, mostrou-se menos precisa na estimativa de altura máxima das árvores em comparação ao LiDAR. Essa diferença pode ser explicada pela resolução espacial limitada e pela dependência de condições ambientais que impactam a acurácia das medições, como nuvens e outras obstruções atmosféricas.

Além disso, a capacidade do FAD-ARP de distinguir entre as alturas das árvores em áreas com vegetação densa é reduzida, o que pode ter levado à subestimação das alturas em algumas parcelas. Esses resultados estão em consonância com o estudo de Navaro et al. (2020), realizado na costa sudeste da Austrália, onde o coeficiente de determinação R² foi de 0,3 utilizando o FAD-ARP, indicando uma relação fraca entre as estimativas de altura máxima e os valores medidos em campo. Essa baixa correlação pode sugerir limitações na capacidade do

FAD-ARP em captar a estrutura vertical das florestas de forma precisa, especialmente em ecossistemas complexos.

Em contraste, o LiDAR, que utiliza a tecnologia de laser para gerar modelos tridimensionais detalhados do terreno e da vegetação, apresentou um desempenho superior nas estimativas de altura máxima das árvores. O estudo de Kumar Adimoolam et al. (2025), realizado em Maharashtra, Índia, encontrou uma correlação moderada entre os dados de campo e as estimativas de altura máxima obtidas pelo LiDAR, com um r^2 de 0,53. Este valor é significativamente maior do que o observado com o FAD-ARP indicando que o LiDAR foi mais eficaz na captura da estrutura vertical das árvores. A alta resolução espacial e a capacidade do LiDAR em penetrar na vegetação e identificar as alturas das árvores, mesmo em áreas densas, contribuem para a sua precisão superior. Embora o LiDAR também esteja sujeito a limitações, como o custo elevado e a necessidade de maior processamento computacional, seus benefícios em termos de acurácia justificam sua escolha em muitos estudos de mapeamento florestal e estimativa de biomassa.

A discrepância entre os dois métodos também pode ser influenciada por fatores específicos do ambiente estudado. Em áreas de regeneração natural, como a estudada neste trabalho, a vegetação heterogênea e as condições de terreno irregulares podem dificultar as estimativas, especialmente para o FAD-ARP, que depende da intensidade da radiação solar refletida. Já o LiDAR, com sua capacidade de coletar dados em 3D, se mostra mais robusto em tais contextos.

Em síntese, as diferenças observadas entre as metodologias destacam a importância de se considerar as características específicas da área de estudo, a resolução dos dados e as limitações de cada tecnologia ao escolher o método mais apropriado para estimar a altura máxima das árvores. Enquanto o FAD-ARP pode ser útil em áreas extensas e de fácil acesso, o LiDAR se apresenta como a escolha preferencial quando a precisão e a capacidade de mapear florestas complexas são essenciais. Esses achados reforçam a necessidade de uma análise crítica das vantagens e limitações de cada técnica, considerando sempre os objetivos do estudo e as condições ambientais.

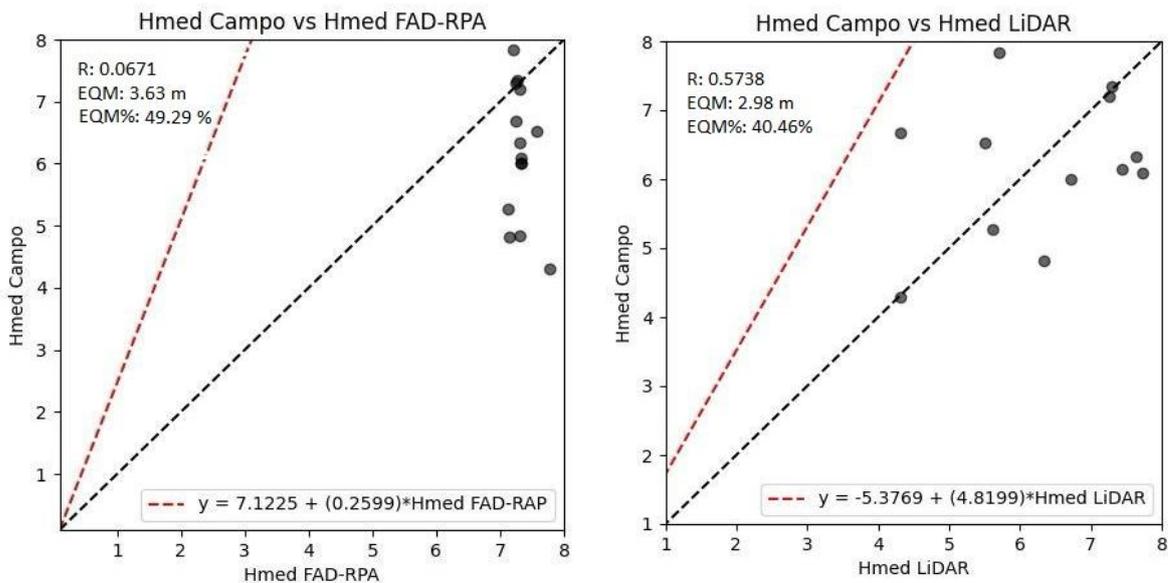
5.4. Altura Média Observada x Altura média FDA-ARP e LiDAR

A Tabela 8 apresenta os resultados da comparação entre a altura média observada em campo e as alturas médias estimadas pelo FAD-ARP e pelo LiDAR. De modo geral, ambas as técnicas demonstraram uma tendência à superestimação das alturas médias das árvores, conforme evidenciado pelo EQM (3,63 m e 2,98 m, respectivamente). No entanto, a acurácia das estimativas diferiu entre as metodologias, como indicado pelos valores de R^2 (0,004 para FAD-ARP e 0,33 para LiDAR), sugerindo que o LiDAR apresentou melhor desempenho na predição da altura média das árvores (Figura 15).

Tabela 8. Estatística da comparação entre a métrica Hmed obtida por (a) FAD-ARP (b) LiDAR comparadas com a altura média observada.

	FAD-ARP	LiDAR
EQM	3,63	2,98
EQM (%)	49,29	40,46
Viés	$4,440892e^{-16}$	$4,68759e^{-15}$
Viés (%)	$6,015205e^{-15}$	$6,349358e^{-14}$
R^2	0,004	0,33

Figura 15. Gráficos de dispersão entre a métrica Hmed obtida por (a) FAD-ARP (b) LiDAR comparadas com a altura média observada em campo.



A superestimação das alturas médias das árvores pelo FAD-ARP foi documentada em alguns estudos. As principais razões para essa discrepância incluem limitações na

penetraçãodo dossel, a densidade da vegetação e as características específicas dos sensores utilizados (Krause *et al.*, 2019). No caso do LiDAR PLS, a acurácia na estimativa da altura das árvores foi abordada em poucos estudos (Cabo *et al.*, 2018; Gianneti *et al.*, 2018; Jurjević *et al.*, 2020; Del Perugia *et al.*, 2019). Esses trabalhos discutem a aplicação da varredura a laser portátil (PLS) em inventários florestais e, em geral, relatam uma tendência de superestimação das alturas das árvores, o que corrobora com as observações deste estudo.

5.5. Ajuste e validação do modelo de biomassa acima do solo

O modelo selecionado para a estimar a Biomassa Acima do Solo (AGB), assim como os resultados das estatísticas, estão apresentados nas Tabelas 9 e 10.

Tabela 9. Corresponde ao modelo de regressão da biomassa estimado pelas métricas da FAD-ARP.

Modelo	AGB = $\beta_0 + \beta_1 * H_5 + \beta_2 * H_{65} + \beta_3 * H_{80} + \beta_4 * D_1 + \beta_5 * D_2 + \beta_6 * D_3 + \beta_7 * D_5 + \xi_i \sim N(0, \sigma)$				
Variáveis	Parâmetro	Estimado	Erro Padrão	T-valor	p-valor
Intercepto	β_0	286.473	64.771	4.423	0.000579 ***
H ₅	β_1	210.34	77.910	2.700	0.017261 *
H ₆₅	β_2	81.759	21.538	3.796	0.001966 **
H ₈₀	β_3	-91.693	19.826	-4.625	0.000393 ***
D ₁	β_4	9.213	3.255	2.830	0.013367 *
D ₂	β_5	- 23.130	4.902	-4.718	0.000330 ***
D ₃	β_6	21.949	3.979	5.516	7.61e ⁻⁰⁵ ***
D ₅	β_7	- 8.529	1.587	-5.373	9.83e ⁻⁰⁵ ***

Significância: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Tabela 10. Corresponde ao modelo de regressão da biomassa estimado pelas métricas do LiDAR.

Modelo	AGB = $\beta_0 + \beta_1 * H_{cv} + \beta_2 * CC_{2m} + \beta_3 * H_{45} + \beta_4 * H_{70} + \beta_5 * D_1 + \beta_6 * D_2 + \xi_i \sim N(0, \sigma)$				
Variáveis	Parâmetro	Estimado	Erro Padrão	T-valor	p-valor
Intercepto	β_0	-363.944	120.285	- 3.026	0.00852 **
H _{cv}	β_1	- 826.925	213.722	- 3.869	0.00151 **
CC _{2m}	β_2	8.000	2.851	2.806	0.01329 *
H ₄₅	β_3	- 422.971	119.396	-3.543	0.00295 **
H ₇₀	β_4	- 513.452	130.633	3.930	0.00134 **
D ₁	β_5	- 20.200	6.369	-3.172	0.00632 **
D ₂	β_6	28.316	7.834	3.614	0.00255 **

Significância: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

As variáveis predictoradas selecionadas para o modelo de estimativa de AGB com a técnica FAD-ARP incluem percentis de altura (H₅, H₆₅, H₈₀) e métricas de densidade de retorno do dossel (D₁, D₂, D₃, D₅). Os percentis de altura representam a distribuição estatística da altura no retorno do sensor no dossel, em que H₅ denota a altura correspondente ao percentil 5%, enquanto H₈₀ refere-se ao percentil 80%. No que tange às métricas de densidade de retorno do dossel, estas quantificam a proporção acumulada de retornos abaixo de determinadas alturas,

normalizadas pelo total de retornos (Cao *et al.*, 2019).

Por outro lado, no modelo de estimativa de AGB utilizando a tecnologia LiDAR, as variáveis preditoras selecionadas abrangem o coeficiente de variação da altura (H_{cv}), a cobertura do dossel acima da altura média (CC_{2m}), percentis de altura (H_{45} , H_{70}) e a densidade de retorno do dossel (D_1 , D_2). O desvio padrão da altura (H_{cv}) é uma métrica estatística que avalia a dispersão dos retornos em relação à média da altura do dossel. A cobertura do dossel acima da altura média (CC_{2m}), por sua vez, expressa a proporção de retornos situados acima da altura média da vegetação, sendo amplamente utilizada para inferir a densidade da vegetação e a complexidade estrutural do dossel (Cao *et al.*, 2019; Cabral *et al.*, 2022).

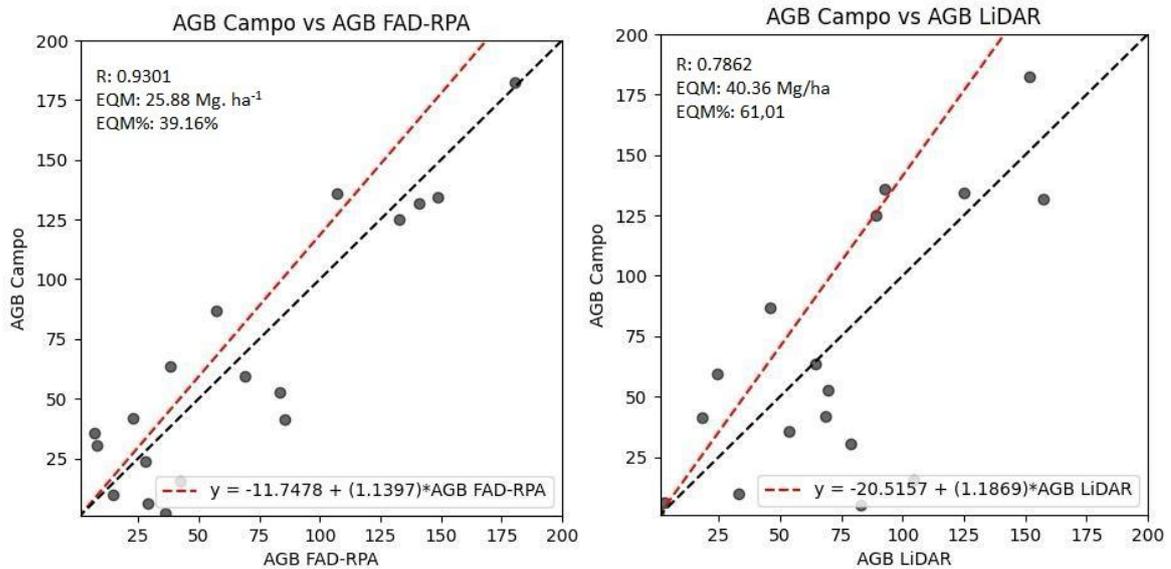
Todas as métricas do modelo foram significativas ($p < 0.0007612$ (FAD-ARP) e $p < 0.02339$ (LiDAR)) e não apresentaram multicolinearidade ($VIF < 10$). A normalidade dos resíduos foram verificado pelo teste de shapiro-wilk.

As estatísticas dos dados de ajuste de desempenho dos modelos são apresentados na Tabela 11 e Figura 16. Ambos demonstraram resultados satisfatórios, mas com diferenças na acurácia das estimativas. O modelo baseado no FAD-ARP apresentou um erro (EQM) de 39,16% (25,88 Mg. ha⁻¹) e um R² 0,86, enquanto o modelo LiDAR teve um EQM de 61,01% (40,36 Mg.ha⁻¹) e um R² de 0,62, indicando que FAD- ARP obteve melhor desempenho na predição da biomassa acima do solo na área de estudo

Tabela 11. Estatísticas utilizadas para avaliar o desempenho dos modelos na estimação da biomassa acima do solo da vegetação de mangue, obtidas por análise de RLM, para os dados de ajuste.

	FAD-ARP	LiDAR
EQM	25,88	40,36
EQM (%)	39,16	61,01
Viés	-2,437559	-2,158708
Viés (%)	-3,688039	-3,266136
R ²	0,86	0,62

Figura 16. Os gráficos dos valores de AGB observados e AGB estimadas obtidas por RLM pelo (a) FAD-ARP (b) LiDAR



O melhor desempenho do modelo FAD-ARP pode ser atribuído a diversos fatores relacionados à captura e representação da estrutura da vegetação. Primeiramente, a FAD-ARP permite a obtenção de um conjunto de dados com maior resolução espacial, resultando em uma caracterização mais detalhada do dossel florestal. Isso possibilita que as métricas de altura e densidade de retorno do dossel apresentem maior acurácia na descrição da estrutura tridimensional da vegetação, reduzindo incertezas no modelo. Além disso, ao contrário do LiDAR, que pode sofrer com oclusão em vegetações densas, os dados fotogramétricos capturam a distribuição da biomassa de maneira contínua, minimizando lacunas na modelagem.

Outro fator relevante é que as métricas de percentis de altura (H_5 , H_{65} , H_{80}) utilizadas no modelo FAD-ARP refletem de forma mais eficiente a variabilidade da altura do dossel, enquanto as métricas derivadas do LiDAR, como o coeficiente de variação da altura (H_{cv}), podem ser mais sensíveis ao ruído dos dados e à variabilidade estrutural da vegetação. A métrica de cobertura do dossel acima da altura média (CC_{2m}) no modelo LiDAR pode ser influenciada por diferenças na densidade dos retornos, impactando a acurácia das estimativas. Isso pode explicar o maior erro associado ao modelo LiDAR.

A variação no desempenho observado pode ser atribuída, em parte, às características específicas do ambiente em estudo. O manguezal analisado é resultado da regeneração passiva, o que pode ter influenciado a dinâmica do escoamento e, por conseguinte, afetado a performance dos modelos. Esse tipo de regeneração, caracterizada pela recuperação natural do ecossistema, pode resultar em uma estrutura florestal menos homogênea ou com características

únicas que não são representadas de forma otimizada pelos modelos utilizados. Além disso, a heterogeneidade estrutural da vegetação pode impactar diretamente na estimativa da biomassa, visto que a variação nos padrões de crescimento das espécies presentes pode dificultar a aplicação de modelos baseados em dados de sensoriamento remoto. Pesquisas anteriores têm demonstrado o potencial tanto do FAD-ARP quanto do LiDAR na estimativa da AGB em florestas de mangue (Basyuni *et al.*, 2023; Wirasatriya *et al.*, 2022; Basyuni *et al.*, 2025; Basyuni *et al.*, 2023; D'Oliveira *et al.*, 2020). No entanto, é importante ressaltar que o sucesso desses métodos pode ser condicionado por uma série de fatores ambientais, como a densidade da vegetação, a presença de espécies dominantes e a interação entre os diferentes componentes do ecossistema. O impacto desses fatores no desempenho dos modelos pode, portanto, justificar os resultados observados neste estudo.

6. CONCLUSÃO

A partir da aplicação de modelos de regressão, foi possível estimar a biomassa acima do solo (AGB) com base em variáveis estruturais extraídas das nuvens de pontos geradas por LiDAR-PLS e FAD-RPA. Os modelos ajustados apresentaram desempenho estatístico satisfatório, evidenciando uma forte correlação entre as métricas de altura, densidade e estrutura da vegetação e os valores de biomassa obtidos em campo. Isso confirma a viabilidade do uso de dados de sensoriamento remoto na estimativa de AGB em áreas de manguezal em restauração.

Na comparação entre os sensores, o LiDAR-PLS demonstrou maior precisão na representação da estrutura vertical da vegetação, gerando estimativas mais consistentes e com menor erro. Já o FAD-RPA, embora apresente maior variabilidade, mostrou-se uma alternativa viável e acessível, principalmente quando calibrado com dados de campo. Sua aplicabilidade é reforçada por seu baixo custo e maior facilidade logística em áreas de difícil acesso.

A estimativa acurada da biomassa acima do solo é essencial para a certificação de créditos de carbono, pois garante a integridade dos projetos de compensação de emissões. Metodologias como a fotogrametria (FAD-RPA) e o LiDAR são fundamentais para quantificar o carbono sequestrado, especialmente em ecossistemas como os manguezais. A precisão dessas metodologias impacta diretamente a validade dos créditos, sendo necessária para atender aos padrões de certificação exigidos por programas de compensação ambiental e mercados de carbono.

Dessa forma, conclui-se que ambas as tecnologias são eficazes na estimativa da biomassa em manguezais em regeneração, sendo o LiDAR mais indicado quando a prioridade é a alta precisão, enquanto o FAD-RPA se destaca pela viabilidade operacional e econômica. A escolha do método deve considerar o contexto do projeto, os recursos disponíveis e os requisitos técnicos exigidos, especialmente em iniciativas voltadas à certificação de carbono e à mitigação das mudanças climáticas.

7. REFERÊNCIAS BIBLIOGRÁFICAS

AGISOFT, L. L. C. **Agisoft Metashape User Manual: Professional Edition**, version 2.0. LLC Agisoft: St. Petersburg, Russia, 2023.

AHMAD, A. et al. Remotely piloted aircraft (ARP) in agriculture: A pursuit of sustainability. **Agronomy**, v. 11, n. 1, 2020.

ALMEIDA, M.V.V. **Estimação de Biomassa e Caracterização Estrutural de Áreas Restauradas da Mata Atlântica com Dados 3D Obtidos por Fotogrametria Aérea Digital**. 2023. 71 f. Dissertação (Mestrado em Desenvolvimento e Meio Ambiente) - Universidade Federal de Sergipe, São Cristóvão, 2023.

ARBACHE, J. et al. **Diagnóstico del mercado de crédito de carbono en América Latina y el Caribe**, 1.ed. Caracas: CAF, 2022, 52 p.

BADIN, T. L. Estimativa De Biomassa Utilizando Dados Lidar Em Floresta Tropical. p. 71, 2018.

BALENOVIĆ, I. et al. Hand-held personal laser scanning – current status and perspectives for forest inventory application. **Croatian Journal of Forest Engineering**, v. 42, n. 1, p. 165–183, 2020.

BASYUNI, M. et al. Aboveground biomass and carbon stock estimation using UAV photogrammetry in Indonesian mangroves and other competing land uses. **Ecological Informatics**, v. 77, n. July, p. 102227, 2023.

BAUWENS, S. et al. Forest inventory with terrestrial LiDAR: A comparison of static and hand-held mobile laser scanning. **Forests**, v. 7, n. 6, 2016.

BRASIL. Ministério da Ciência e Tecnologia. **Protocolo de Quioto: à convenção sobre mudança do clima: O Brasil e a convenção – quadro das nações unidas**. Disponível em: <<https://livroaberto.ibict.br/handle/1/855>>. Acesso em: 20/12/2024

_____. **Lei nº 15.042, de 11 de Dezembro de 2024**. Brasil, DF - Diário Oficial da União - Seção 1, p.4, , 2024. Disponível em: <Diário Oficial da União,Seção 1, p. 4>

_____. **Lei nº 14.119, de 13 de Janeiro de 20201**. Brasil, DF - Diário Oficial da União - Seção 1, p. 7, , 2025. Disponível em: <https://www.planalto.gov.br/ccivil_03/_ato2019-2022/2021/lei/114119.htm>

CABO, C. et al. Comparing terrestrial laser scanning (TLS) and wearable laser scanning (WLS) for individual tree modeling at plot level. **Remote Sensing**, v. 10, n. 4, 2018.

CABRAL, R. et al. Mapeamento do Estágio Sucessional de uma Floresta Secundária Utilizando Nuvens de Pontos Derivadas de Fotogrametria de VANT. **Sensoriamento Remoto** , v. 15, n. 2, p. 509, 2023.

CHAVE, J. et al. Improved allometric models to estimate the aboveground biomass of tropical

trees. **Global Change Biology**, v.20, n.10, p.3177-3190, 2014.

CHAVE, J. et al. Regional and phylogenetic variation of wood density across 2456 neotropical tree species. **Ecological applications**, v. 16, n. 6, p. 2356-2367, 2006.

CHAVE, J. et al. Tree allometry and improved estimation of carbon stocks and balance in tropical forests. **Oecologia**, v. 145, n. 1, p. 87–99, 2005.

COELHO FILHO, L. C. T.; BRITO, J. L. N. S. Fotogrametria digital. **Rio de Janeiro: EDUERJ**, 2007.

CORTE, A. P. D. et al. High-Density UAV-LiDAR in an Integrated Crop-Livestock-Forest System: Sampling Forest Inventory or Forest Inventory Based on Individual Tree Detection (ITD). **Drones**, v. 6, n. 2, 2022.

DE OLIVEIRA, Y. P. L. Desafios do Mercado de Carbono após o Acordo de Paris: Uma revisão. **Meio Ambiente (Brasil)**, v. 4, n. 1, 2021.

DE SOUZA, B. B. et al. Mapeamento Espaço-Temporal Da Carcinicultura No Litoral Do Estado De Sergipe, Brasil. **Caminhos de Geografia**, v. 23, n. 90, p. 179–192, 2022.

DEL PERUGIA, B. et al. Influence of scan density on the estimation of single-tree attributes by hand-held mobile laser scanning. **Forests**, v. 10, n. 3, p. 277, 2019.

ESTRADA, G. C. D.; SOARES, M. L. G. Global patterns of aboveground carbon stock and sequestration in mangroves. **Anais da Academia Brasileira de Ciencias**, v. 89, n. 2, p. 973–989, 2017.

FRANCA, T. S. S. **ICMS Ecológico em Sergipe: Uma Proposta de Incentivo À Implementação De Políticas Públicas Ambientais**. 2017. 109 f. Dissertação (Mestrado Profissional em Administração Pública em Rede Nacional) - Universidade Federal de Sergipe, São Cristóvão, 2017.

FRIESS, D. A. et al. Mangroves and people: Impacts and interactions. **Estuarine, Coastal and Shelf Science**, v. 248, 2021.

FLORENZANO, T.; G. **Iniciação em sensoriamento remoto**. Editora Oficina de Textos, 2019. 130 p. ISBN 9788579750168.

FLYABILITY. WHAT IS SIMULTANEOUS LOCALIZATION AND MAPPING (SLAM)?. 2022. Disponível em:<<https://www.flyability.com/simultaneous-localization-and-mapping>>. Acesso em: 08 fev. 2024.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Pesquisa pecuária municipal. IBGE (2023). Disponível em: < <https://www.ibge.gov.br/explica/producao-agropecuaria/camarao/br>>. Acesso em: 08 de abr. 2025.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Pesquisa pecuária municipal. IBGE (2022). Disponível em: <<https://sidra.ibge.gov.br/Tabela/3940>>. Acesso em: 02 de abr. 2025.

ICMBIO - Instituto Chico Mendes de Conservação da Biodiversidade. Atlas dos Manguezais do Brasil. Brasília, 2018. 176 p.

ICROA - International Carbon Reduction & Offsetting Accreditation. ICROA Code. Disponível em: <https://icroa.org/icroa-code-of-best-practice/>. Acesso em: 30 ago. 2023.

IUCN - International Union for Conservation of Nature. Red List of Ecosystems. Disponível em <<https://iucn.org/resources/conservation-tool/iucn-red-list-ecosystems>>. Acesso em: 06 de nov. 2024

GEOSLAM. What is SLAM (Simultaneous Localisation and Mapping). 2023b. Disponível em: <<https://geoslam.com/what-is-slam/>>. Acesso em: 30 jan. 2024.

GEOSLAM. ZEB HORIZON The ultimate mobile mapping solution. 2023a. Disponível em: <<https://geoslam.com/solutions/zeb-horizon/>>. Acesso em: 30 jan.2024.

GIANNETTI, et al. Integrating terrestrial and airborne laser scanning for the assessment of single-tree attributes in Mediterranean forest stands. **European Journal of Remote Sensing**, v. 51, n. 1, p. 795-807, 2018.

GIONGO, M. et al. LiDAR: princípios e aplicações florestais. **Pesquisa Florestal Brasileira**, v. 30, n. 63, p. 231–244, 2010.

GÓES, C.; ELLEN, M. Mais de 33 viveiros ilegais de criação de camarão ameaçam manguezais em Socorro. MPF/SE quer que Adema não conceda mais licenças para a carcinicultura. **Mangue Jornalismo**, Aracaju, 20 de fev. 2024

GOLLOB, C. et al. Influence of scanner position and plot size on the accuracy of tree detection and diameter estimation using terrestrial laser scanning on forest inventory plots. **Remote Sensing**, v. 11, n. 13, p. 1–30, 2019.

GOLLOB, C.; RITTER, T.; NOTHDURFT, A. Forest inventory with long range and high-speed Personal Laser Scanning (PLS) and Simultaneous Localization and Mapping (SLAM) technology. **Remote Sensing**, v. 12, n. 9, 2020.

GOMES, L. E. DE O. et al. Ecosystem carbon losses following a climate-induced mangrove mortality in Brazil. **Journal of Environmental Management**, v. 297, n. July, p. 113381, 2021.

GONÇALVES, L. G. D. **AEROFOTOGRAMETRIA APLICADA AO ACOMPANHAMENTO DE CANTEIRO DE OBRAS**. Brasília: Universidade de Brasília, 2020.

GUEDES, F. B.; SEEHUSEN, S. E. (Org.). **Pagamentos por serviços ambientais na Mata Atlântica: lições aprendidas e desafios**. Brasília: MMA, 2011. Disponível em: . Acesso em: 20 set. 2024.

GUERRA, B. R.; RANIERI, V. E. L. Guidelines for Planning and Designing Payment for Environmental Services Schemes. **Ambiente e Sociedade**, v. 26, 2023.

HE, J.; LI, Y.; ZHANG, K. Research of UAV Flight Planning Parameters. **Positioning**, v. 03,

n. 04, p. 43–45, 2012.

HORST, D. J.; JÚNIOR, P. P. DE A. Uma revisão sistemática sobre os mecanismos de monitoramento e captura, regulação de emissões e créditos de carbono. **Energías Renovables y Medio Ambiente**, v. 45, n. September, p. 51–62, 2020.

JIA, M. et al. Mapping global distribution of mangrove forests at 10-m resolution. **Science Bulletin**, v. 68, n. 12, p. 1306–1316, 2023.

JURJEVIĆ, L. et al. Is field-measured tree height as reliable as believed—Part II, A comparison study of tree height estimates from conventional field measurement and low-cost close-range remote sensing in a deciduous forest. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 169, p. 227–241, 2020.

KANDASAMY, K. et al. Carbon sequestration and storage in planted mangrove stands of *Avicennia marina*. **Regional Studies in Marine Science**, v. 43, p. 101701, 2021.

KANKARE, V. et al. Individual tree biomass estimation using terrestrial laser scanning. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 75, p. 64–75, 2013.

KAUFFMAN, J. B. et al. Carbon stocks of mangroves and salt marshes of the Amazon region, Brazil. **Biology Letters**, v. 14, n. 9, 2018a.

KAUFFMAN, J. B. et al. Shrimp ponds lead to massive loss of soil carbon and greenhouse gas emissions in northeastern Brazilian mangroves. **Ecology and Evolution**, v. 8, n. 11, p. 5530–5540, 2018b.

KYOTO PROTOCOL to the United Nations Framework Convention on Climate Change. Kyoto, 1997. Disponível em: <https://unfccc.int/resource/docs/convkp/kpeng.pdf>. Acesso em 01 de maio de 2023.

KRAUSE, S. et al. UAV-based photogrammetric tree height measurement for intensive forest monitoring. **Remote Sensing**, v. 11, n. 7, p. 1–18, 2019.

KUMAR ADIMOOLAM, Y. et al. Estimation of above ground biomass of mangrove forest plot using terrestrial laser scanner. **Egyptian Journal of Remote Sensing and Space Science**, v. 28, n. 1, p. 1–11, 2025.

LEITE, R. A. et al. The colonization of a coastal lagoon by a mangrove ecosystem: Benefit or threat to the lagoon? **Aquatic Botany**, v. 171, n. January, 2021.

LIANG, X. et al. Possibilities of a personal laser scanning system for forest mapping and ecosystem services. **Sensors (Switzerland)**, v. 14, n. 1, p. 1228–1248, 2014.

LIMA, I. M. C. **Subsídios para a Implementação do ICMS Ecológico no Estado de Sergipe**. 2019. 177 f. Dissertação (Mestrado em Meio Ambiente e Desenvolvimento) - Universidade de Sergipe, São Cristóvão, 2024.

MACHADO, M. D. **Uso De Equipamentos Analógicos, Digitais E Scanner Laser Na Estimação De Variáveis Dendrométricas**. 2023. 102 f. Dissertação (Mestrado em Ciências

Florestais) - Universidade Federal do Espírito Santo, Jerônimo Monteiro, 2023.

MapBiomas - Projeto MapBiomas – **Coleção 9 da Série Anual de Mapas de Cobertura e Uso da Terra do Brasil**. Disponível em: <<https://plataforma.brasil.mapbiomas.org/>>: Acesso em: 04 de nov. 2024

MARCOVITCH, J.; PINSKY, V. C. Um retrato da Amazônia planetária. *Revista de Estudios Brasileños*, v. 6, n. 11, p. 169-183, jan. 2019.

NARDI DE ARAUJO, J.; ABBADE, K. M. **A Efetividade do Acordo de Paris frente ao Acordo De Livre-Comércio Do Mercosul E União Europeia** *Revista del Centro d e Excelencia Jean Monnet de FGV Direito Rio*, 2021. Disponível em: <<https://bit.ly/2CppKzo>>

NAVARRO, A. et al. The application of Unmanned Aerial Vehicles (UAVs) to estimate above-ground biomass of mangrove ecosystems. **Remote Sensing of Environment**, v. 242, n. November 2019, p. 111747, 2020.

NEIVA, H. S. **Mercado Voluntário de Carbono no Brasil**. 2023. 78 f. Dissertação (Mestrado em Ciência da Conservação e Sustentabilidade) - Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2023.

ODUM, E. P.; BARRETT, G. W. **Fundamentos de ecologia**. São Paulo: Cengage Learning, 2007. 611 p. ISBN 9788522105410.

OLIVEIRA, J. J. L. **Mercado de Carbono : Proposta de Implementação em um Município Do Ceará**. 2024. 89 f. Dissertação (Mestrado em Saneamento Básico) - Universidade Federal do Ceará, Fortaleza, 2024.

OLIVERIA, A. H. M. et al. Exatidão e precisão de receptores GNSS em ambientes florestais. 2015. (Apresentação de Trabalho/Simpósio).

PARIS AGREEMENT. Paris, 2015. Disponível em: https://unfccc.int/files/essential_background/convention/application/pdf/english_paris_agreement.pdf. Acesso em 01 de dezembro de 2024.

R Core Team (2021). **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria. Disponível em: <<https://www.R-project.org/>>.

ROVAI, A. S. et al. Brazilian Mangroves: Blue Carbon Hotspots of National and Global Relevance to Natural Climate Solutions. **Frontiers in Forests and Global Change**, v. 4, n. January, 2022.

RYDING, J. et al. Assessing handheld mobile laser scanners for forest surveys. **Remote Sensing**, v. 7, n. 1, p. 1095–1111, 2015.

SALUM, R. B. et al. Improving mangrove above-ground biomass estimates using LiDAR. **Estuarine, Coastal and Shelf Science**, v. 236, n. November 2019, p. 106585, 2020.

SERGIPE. **Lei Ordinária nº 9.364, de 05 de Janeiro de 2024**. Sergipe, SE - Diário Oficial do Estado de Sergipe, 2024. Disponível em: < <https://leisestaduais.com.br/se/lei-ordinaria-n-9364-2024-sergipe-institui-a-> >

SILVEIRA, P. et al. O Estado Da Arte Na Estimativa De Biomassa E Carbono Em Formações Florestais. **Floresta**, v. 38, n. 1, p. 185–206, 2008.

SCHAEFFER-NOVELLI, Y. et al. Variability of mangrove ecosystems along the Brazilian coast. **Estuaries**, v. 13, p. 204-218, 1990c.

SCHAEFFER-NOVELLI, Y. **Mangue e Manguezal**. 1ª ed. Brasília, D.F.: ICMBio, 2018a, v., p. 17-22.

SCHAEFFER-NOVELLI, Y. Manguezais brasileiros: região sudeste-sul. 1987c.

SCHAEFFER-NOVELLI, Y. Manguezal ecossistema entre a terra e o mar. 1995b.

SHIRATSUCHI, L. S. et al. Sensoriamento Remoto: conceitos básicos e aplicações na Agricultura de Precisão. p. 58–73, 2014.

SILVA, N. M.; PESSI, D. D. Aeronaves Remotamente Pilotadas - ARP. n. January, 2021.

SILVEIRA, P. et al. O Estado Da Arte Na Estimativa De Biomassa E Carbono Em Formações Florestais. **Floresta**, v. 38, n. 1, p. 185–206, 2008.

SOUZA, C. A. et al. Biodiversidade e conservação dos manguezais: importância bioecológica e econômica. **Educação Ambiental sobre Manguezais. São Vicente: Unesp, p. 16-56, 2018**.

SPALDING, M.; PARRETT, C. L. Global patterns in mangrove recreation and tourism. **Marine Policy**, v. 110, n. April, p. 103540, 2019.

TOMASSELLI, A. Fotogrametria Básica. **Biblioteca Virtual da FAPESP**, v. 1, p. Cap. 1, 2009.

THOMÉ, R.; GARCIA, L.M . Direito Ambiental. 13. ed. rev., atual. e ampl. - Salvador: Juspodivm, 2021. v. 1. 656p .

TRENNEPOHL, N. **Mercado de Carbono e Sustentabilidade**. 1. ed. São Paulo: Saraiva Jur, 2022. v. 1p. 232

VECTORNAV. INERTIAL NAVIGATION ARTICLES. 2023. Disponível em: <<https://www.vectornav.com/resources/inertial-navigation-articles/what-is-an-inertial-measurement-unit-imu>>. Acesso em: 26 jan. 2023.

VINH, T. VAN et al. Allometric models to estimate above-ground biomass and carbon stocks in *Rhizophora apiculata* tropical managed mangrove forests (Southern Viet Nam). **Forest Ecology and Management**, v. 434, n. December 2018, p. 131–141, 2019.

VIRGULINO, P. C. C. et al. Biomass and carbon estimation for scrub mangrove forests and examination of their allometric associated uncertainties. **PLoS ONE**, v. 15, n. 3, p. 1–18, 2020.

WANG, D. et al. Estimating aboveground biomass of the mangrove forests on northeast Hainan Island in China using an upscaling method from field plots, UAV-LiDAR data and Sentinel-2 imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 85, n. October 2019, p. 101986, 2020.

WATZLAWICK, L. F.; SANQUETTA, C. R.; KIRCHNER, F. F. Gps: Ferramenta De Apoio Na Realização De Inventário Florestal. **Floresta**, v. 32, n. 1, p. 135–141, 2002.

WONG, C. J. et al. Assessment of anthropogenic disturbances on mangrove aboveground biomass in Malaysian Borneo using airborne LiDAR data. **Egyptian Journal of Remote Sensing and Space Science**, v. 27, n. 3, p. 547–554, 2024.

WU, X. et al. Assessment of individual tree detection and canopy cover estimation using unmanned aerial vehicle based light detection and ranging (UAV-LiDAR) data in planted forests. **Remote Sensing**, v. 11, n. 8, 2019.

WUNDER, S. Revisiting the concept of payments for environmental services. **Ecological Economics**, v. 117, p. 234–243, 2015.

8. ANEXOS

8.1. RELATÓRIO DE PROCESSAMENTO

Report

**Processing Report
28 January 2025**



Survey Data

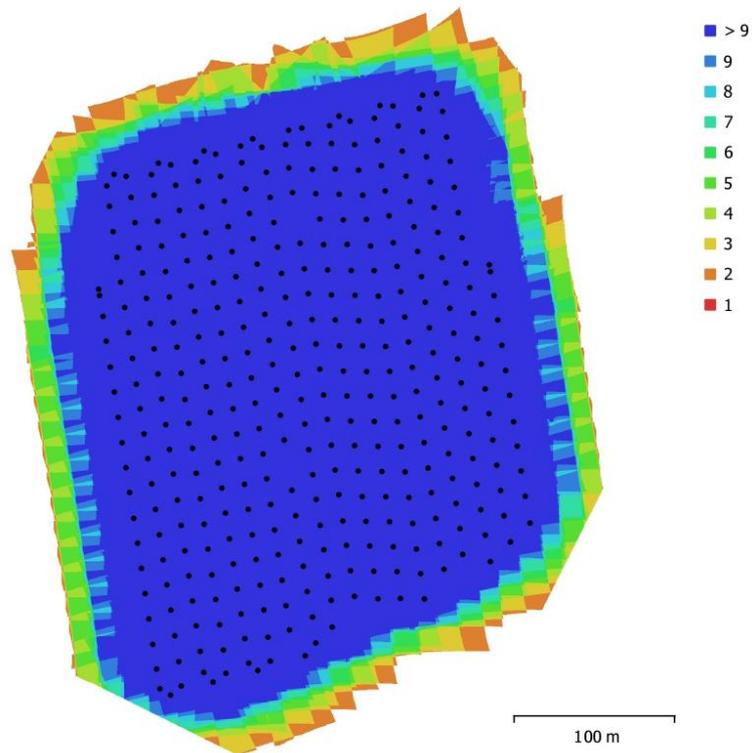


Fig. 1. Camera locations and image overlap.

Number of images:	378	Camera stations:	361
Flying altitude:	63.7 m	Tie points:	132,679
Ground resolution:	1.57 cm/pix	Projections:	410,305
Coverage area:	0.129 km ²	Reprojection error:	2.57 pix

Camera Model	Resolution	Focal Length	Pixel Size	Precalibrated
M3M (12.29mm)	5280 x 3956	12.29 mm	3.36 x 3.36 μ m	No

Table 1. Cameras.

Camera Calibration

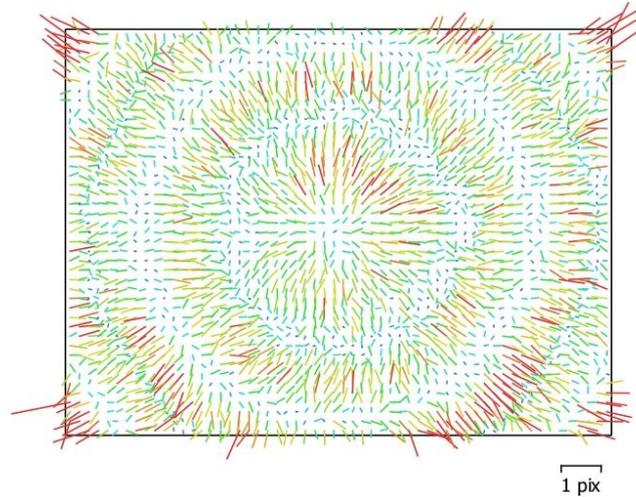


Fig. 2. Image residuals for M3M (12.29mm).

M3M (12.29mm)

378 images

Type Resolution Focal Length Pixel Size
Frame 5280 x 3956 12.29 mm 3.36 x 3.36 μ m

	Value	Error	F	Cx	Cy	B1	B2	K1	K2	K3	P1	P2
F	3561.39	2.9	1.00	-0.09	0.22	-0.01	-0.01	-0.90	-0.08	-0.43	0.10	-0.23
Cx	-6.32271	0.15		1.00	-0.05	0.17	-0.08	0.08	0.03	0.01	-0.70	0.02
Cy	-13.5976	0.12			1.00	0.05	0.16	-0.20	-0.01	-0.10	0.05	-0.66
B1	-0.803086	0.022				1.00	-0.09	0.03	-0.05	0.04	-0.13	-0.03
B2	-0.369695	0.022					1.00	0.01	-0.02	0.03	0.04	-0.09
K1	-0.0977686	0.00016						1.00	-0.30	0.68	-0.09	0.21
K2	-0.00310575	0.00015							1.00	-0.85	-0.03	0.02
K3	-0.010384	0.00012								1.00	-0.02	0.10
P1	6.84887e-005	4.9e-006									1.00	-0.03
P2	-0.000205435	4.1e-006										1.00

Table 2. Calibration coefficients and correlation matrix.

Camera Locations

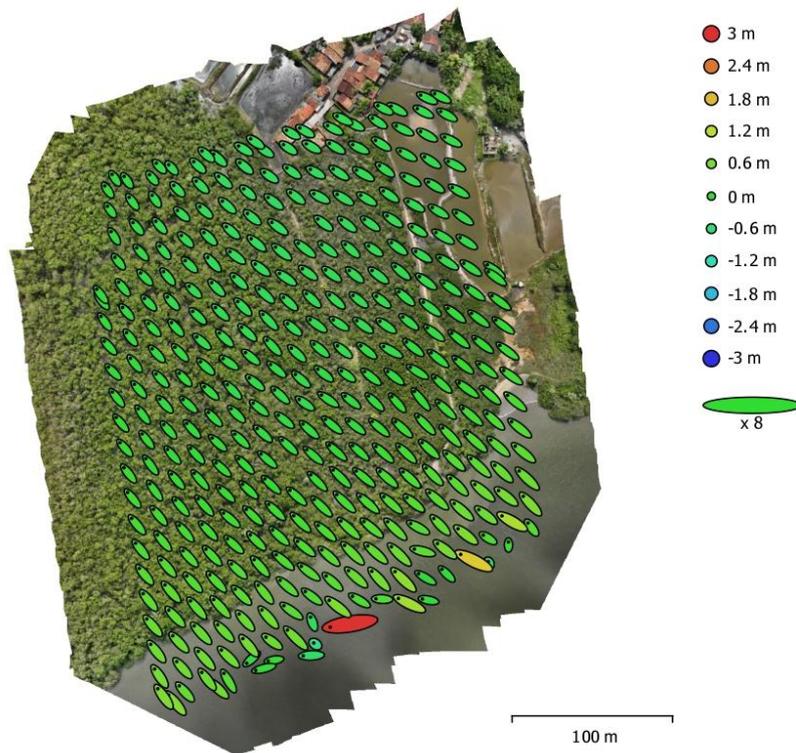


Fig. 3. Camera locations and error estimates.
 Z error is represented by ellipse color. X,Y errors are represented by ellipse shape.
 Estimated camera locations are marked with a black dot.

X error (m)	Y error (m)	Z error (m)	XY error (m)	Total error (m)
0.971965	0.850562	0.343474	1.29158	1.33647

Table 3. Average camera location error.
 X - Easting, Y - Northing, Z - Altitude.

Ground Control Points

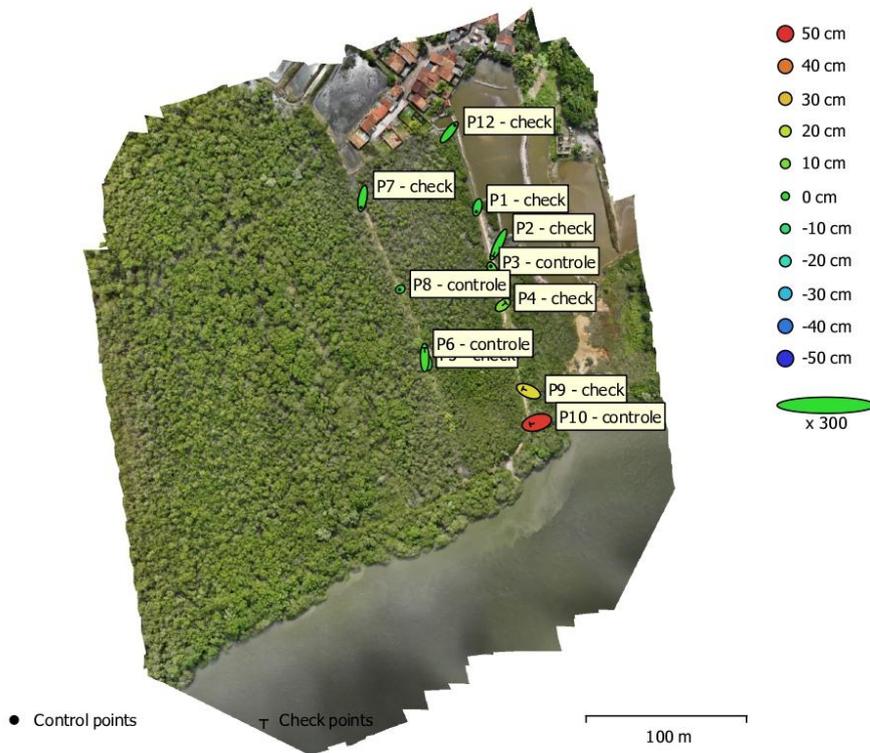


Fig. 4. GCP locations and error estimates.

Z error is represented by ellipse color. X,Y errors are represented by ellipse shape.
Estimated GCP locations are marked with a dot or crossing.

Count	X error (cm)	Y error (cm)	Z error (cm)	XY error (cm)	Total (cm)
6	1.05077	2.22662	1.93517	2.4621	3.13159

Table 4. Control points RMSE.
X - Easting, Y - Northing, Z - Altitude.

Count	X error (cm)	Y error (cm)	Z error (cm)	XY error (cm)	Total (cm)
5	2.03706	2.96079	25.2492	3.59387	25.5037

Table 5. Check points RMSE.
X - Easting, Y - Northing, Z - Altitude.

Label	X error (cm)	Y error (cm)	Z error (cm)	Total (cm)	Image (pix)
P1 - check	-0.437446	-1.81737	-3.22398	3.72669	0.158 (12)
P3 - controle	-0.591675	1.16608	3.14357	3.40468	0.364 (17)
P5 - check	-0.212966	1.52923	-1.10894	1.90096	0.222 (9)
P7 - check	-0.678066	-3.76588	0.947192	3.94193	0.045 (23)
P8 - controle	-0.295172	-0.152761	-0.0515744	0.336337	0.014 (17)
P12 - check	2.34328	2.92245	0.2522	3.75437	0.257 (25)
Total	1.05077	2.22662	1.93517	3.13159	0.214

Table 6. Control points.
X - Easting, Y - Northing, Z - Altitude.

Label	X error (cm)	Y error (cm)	Z error (cm)	Total (cm)	Image (pix)
P2 - check	-2.33036	-4.89506	0.241698	5.42684	0.344 (22)
P4 - check	1.2135	0.94015	10.3976	10.5103	0.121 (17)
P6 - controle	-0.0342317	4.14504	3.01154	5.12366	0.198 (10)
P9 - check	-2.46119	1.09745	26.1073	26.246	0.134 (26)
P10 - controle	-2.79038	-0.774732	48.8752	48.961	0.128 (22)
Total	2.03706	2.96079	25.2492	25.5037	0.205

Table 7. Check points.
X - Easting, Y - Northing, Z - Altitude.

Digital Elevation Model

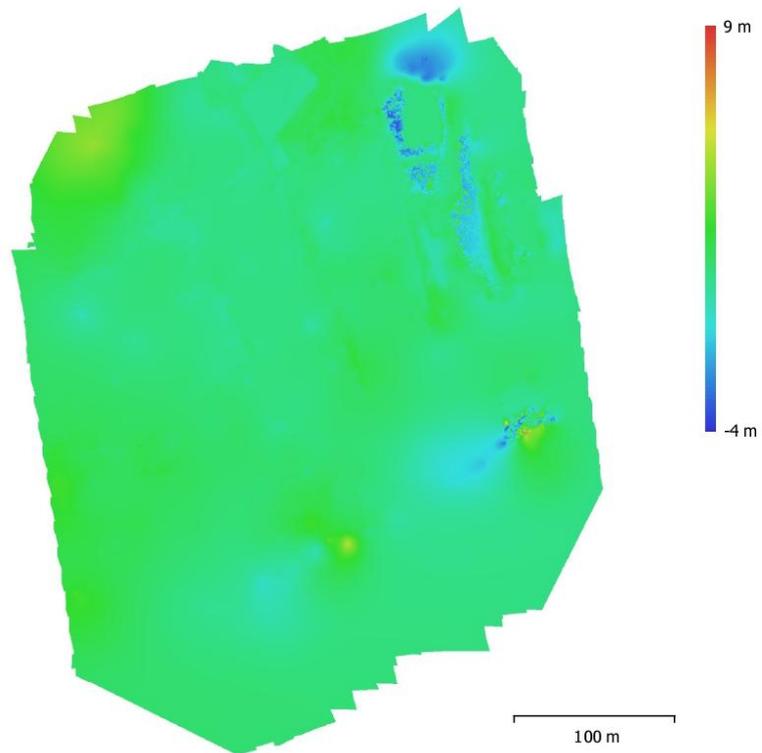


Fig. 5. Reconstructed digital elevation model.

Resolution: 6.28 cm/pix
Point density: 253 points/m²

Processing Parameters

General

Cameras	378
Aligned cameras	361
Markers	11

Shapes

Coordinate system	WGS 84 + EGM96 height
Coordinate system	SIRGAS 2000 / UTM zone 24S (EPSG::31984)
Rotation angles	Yaw, Pitch, Roll

Point Cloud

Points	132,679 of 144,760
RMS reprojection error	0.170994 (2.57077 pix)
Max reprojection error	1.15281 (40.5555 pix)
Mean key point size	12.4556 pix
Point colors	3 bands, uint8
Key points	No
Average tie point multiplicity	3.19629

Alignment parameters

Accuracy	Medium
Generic preselection	No
Reference preselection	Yes
Key point limit	40,000
Tie point limit	10,000
Filter points by mask	Yes
Mask tie points	No
Adaptive camera model fitting	Yes
Matching time	5 minutes 22 seconds
Alignment time	1 minutes 12 seconds

Optimization parameters

Parameters	f, b1, b2, cx, cy, k1-k3, p1, p2
Adaptive camera model fitting	No
Optimization time	2 seconds
Software version	1.5.2.7838

Depth Maps

Count	348
-------	-----

Depth maps generation parameters

Quality	Medium
Filtering mode	Mild
Processing time	13 minutes 7 seconds
Software version	1.5.2.7838

Dense Point Cloud

Points	52,022,477
Point colors	3 bands, uint8

Depth maps generation parameters

Quality	Medium
Filtering mode	Mild
Processing time	13 minutes 7 seconds

Dense cloud generation parameters

Processing time	11 minutes 38 seconds
Software version	1.5.2.7838

DEM

General	
Size	9,468 x 10,273
Coordinate system	SIRGAS 2000 / UTM zone 24S (EPSG::31984)
Reconstruction parameters	
Source data	Dense cloud
Interpolation	Enabled
Processing time	42 seconds
Software version	1.5.2.7838
Orthomosaic	
Size	23,631 x 30,055
Coordinate system	SIRGAS 2000 / UTM zone 24S (EPSG::31984)
Colors	3 bands, uint8
Reconstruction parameters	
Blending mode	Mosaic
Surface	DEM
Enable hole filling	Yes
Processing time	8 minutes 1 seconds
Software version	1.5.2.7838
Software	
Version	1.5.2 build 7838
Platform	Windows 64