

UNIVERSIDADE FEDERAL DE VIÇOSA

**Modelagem da biomassa de mangues utilizando sensores remotos e
inteligência artificial: estudo de caso na Reserva de Desenvolvimento
Sustentável Municipal Piraquê-Açu-Mirim no estado do Espírito Santo, Brasil**

Matheus Guimarães Cancela Silva
Magister Scientiae

**VIÇOSA - MINAS GERAIS
2026**

MATHEUS GUIMARÃES CANCELA SILVA

Modelagem da biomassa de mangues utilizando sensores remotos e inteligência artificial: estudo de caso na Reserva de Desenvolvimento Sustentável Municipal Piraquê-Açu-Mirim no estado do Espírito Santo, Brasil

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Geografia, para obtenção do título de *Magister Scientiae*.

Orientador: Andre Luiz Lopes de Faria

**VIÇOSA - MINAS GERAIS
2026**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade
Federal de Viçosa - Campus Viçosa**

T

S586m
2026

Silva, Matheus Guimarães Cancela, 1993-

Modelagem da biomassa de mangues utilizando sensores remotos e inteligência artificial: estudo de caso na Reserva de Desenvolvimento Sustentável Municipal Piraquê-Açu-Mirim no Estado do Espírito Santo, Brasil / Matheus Guimarães Cancela Silva. – Viçosa, MG, 2026.

1 dissertação eletrônica (57 f.): il. (algumas color.).

Orientador: André Luiz Lopes de Faria.

Dissertação (mestrado) - Universidade Federal de Viçosa, Departamento de Geografia, 2026.

Referências bibliográficas: f. 52-57.

DOI: <https://doi.org/10.47328/ufvbbt.2026.539>

Modo de acesso: World Wide Web.

1. Reserva de Desenvolvimento Sustentável Municipal Piraquê-Açu-Mirim (Aracruz, ES). 2. Ecologia dos manguezais. 3. Sensoriamento remoto. I. Faria, André Luiz Lopes de, 1970-. II. Universidade Federal de Viçosa. Departamento de Geografia. Programa de Pós-Graduação em Geografia. III. Título.

CDD 22. ed. 577.698

MATHEUS GUIMARÃES CANCELA SILVA

Modelagem da biomassa de mangues utilizando sensores remotos e inteligência artificial: estudo de caso na Reserva de Desenvolvimento Sustentável Municipal Piraquê-Açu-Mirim no estado do Espírito Santo, Brasil

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Geografia, para obtenção do título de *Magister Scientiae*.

APROVADA: 7 de julho de 2026.

Assentimento:

Matheus Guimarães Cancela Silva
Autor

Andre Luiz Lopes de Faria
Orientador

Essa dissertação foi assinada digitalmente pelo autor em 16/09/2026 às 14:02:16 e pelo orientador em 17/09/2026 às 07:28:32. As assinaturas têm validade legal, conforme o disposto na Medida Provisória 2.200-2/2001 e na Resolução nº 37/2012 do CONARQ. Para conferir a autenticidade, acesse <https://siadoc.ufv.br/validar-documento>. No campo 'Código de registro', informe o código **THNI.WFXV.BFMY** e clique no botão 'Validar documento'.

AGRADECIMENTOS

Este trabalho foi realizado com o apoio das seguintes agências de pesquisa brasileiras:

Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001, Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) e Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

RESUMO

SILVA, Matheus Guimarães Cancela, M.Sc., Universidade Federal de Viçosa, julho de 2026. **Modelagem da biomassa de mangues utilizando sensores remotos e inteligência artificial: estudo de caso na Reserva de Desenvolvimento Sustentável Municipal Piraquê-Açu-Mirim no estado do Espírito Santo, Brasil.** Orientador: Andre Luiz Lopes de Faria.

Os manguezais são ecossistemas costeiros de elevada relevância ecológica, destacando-se como sumidouros de carbono azul com capacidade de sequestro superior à maioria das florestas tropicais. No entanto, sua estimativa de biomassa acima do solo (AGB) por métodos tradicionais é onerosa e limitada espacialmente. Esta pesquisa desenvolveu e validou um modelo preditivo de AGB para o manguezal da Reserva de Desenvolvimento Sustentável Municipal Piraquê-Açu-Mirim (ES), utilizando exclusivamente dados gratuitos de sensores remotos (Sentinel-1, Sentinel-2 e GEDI) e algoritmos de aprendizado de máquina (Random Forest) na plataforma Google Earth Engine. A metodologia integrou índices espectrais de vegetação, bandas de reflectância e retroespalhamento SAR, tendo como variável dependente as amostras de densidade de biomassa do GEDI. O modelo foi aplicado em dois cenários (pré e pós-evento climático extremo ocorrido em junho de 2016), permitindo quantificar a perda de biomassa. Os resultados indicaram redução de aproximadamente 7.581 toneladas de biomassa total em seis meses, com redução da densidade média de 31,9 t/ha para 27,8 t/ha. As métricas de validação apresentaram R^2 de 49,98% (pré-evento) e 45,99% (pós-evento), com RMSE de 19,17 e 21,55 Mg/ha, respectivamente, evidenciando subestimação em altos valores de AGB e superestimação em baixos valores, consistentes com o efeito de compressão à média e limitações do GEDI em dosséis densos. Conclui-se que a abordagem multisensor e de baixo custo é viável para o monitoramento espaço-temporal da biomassa em manguezais, fornecendo subsídios para a gestão do carbono azul e a conservação costeira no Brasil.

Palavras-chave: carbono azul; Random Forest; GEDI; sensoriamento remoto; manguezais

ABSTRACT

SILVA, Matheus Guimarães Cancela, M.Sc., Universidade Federal de Viçosa, July, 2026. **Mangrove biomass modeling using remote sensing and artificial intelligence: a case study in the Piraquê-Açu-Mirim Municipal Sustainable Development Reserve, Espírito Santo State, Brazil.** Adviser: Andre Luiz Lopes de Faria.

Mangroves are coastal ecosystems of high ecological relevance, standing out as blue carbon sinks with a sequestration capacity that surpasses that of most tropical forests. However, estimating their above-ground biomass (AGB) through traditional methods is costly and spatially limited. This research developed and validated a predictive AGB model for the mangrove forest of the Piraquê-Açu-Mirim Municipal Sustainable Development Reserve (ES), using exclusively freely available remote sensing data (Sentinel-1, Sentinel-2, and GEDI) and machine learning algorithms (Random Forest) on the Google Earth Engine platform. The methodology integrated spectral vegetation indices, reflectance bands, and SAR backscatter, with GEDI biomass density samples as the dependent variable. The model was applied in two scenarios (pre- and post-extreme climatic event occurring in June 2016), allowing for the quantification of biomass loss. The results indicated a reduction of approximately 7,581 tons of total biomass over six months, with a decrease in mean density from 31.9 t/ha to 27.8 t/ha. Validation metrics yielded an R^2 of 49.98% (pre-event) and 45.99% (post-event), with RMSE of 19.17 and 21.55 Mg/ha, respectively, evidencing underestimation at high AGB values and overestimation at low values, consistent with the compression-to-the-mean effect and GEDI limitations in dense canopies. It is concluded that the low-cost, multi-sensor approach is feasible for the spatiotemporal monitoring of biomass in mangroves, providing support for blue carbon management and coastal conservation in Brazil.

Keywords: blue carbon; Random Forest; GEDI; remote sensing; mangroves

LISTA DE ILUSTRAÇÕES

Figura 1 - Exemplos de flora nativa dos manguezais Capixabas.....	35
Figura 2 - Localização do manguezal Piraquê-Açu - ES.....	36
Figura 3 - Comparação da aplicação do modelo SIAC.....	38
Figura 4 - Mosaico dos índices gerados.....	39
Figura 5 - Diferença entre o dado original e de treinamento.....	40
Figura 6 - Definição da área de mangue utilizada como delimitação.....	41
Figura 7 - Biomassa acima do solo - Piraquê-Açu (antes do evento).....	42
Figura 8 - Biomassa acima do solo - Piraquê-Açu (depois do evento).....	43
Figura 9 - Comparação lado a lado.....	43
Figura 10 - Diferença de biomassa (ΔAGB).....	44
Figura 11 - Gráfico de regressão pré-evento.....	47
Figura 12 - Gráfico de regressão pós-evento.....	47

LISTA DE TABELAS

Quadro 1 - Sumário de características dos sensores.....	21
Quadro 2 - Fórmula dos índices utilizados.....	25
Quadro 3 - Critérios da máscara de redução de ruído (superfícies secas).....	40
Tabela 1 - Métricas da biomassa estimada em 100 m ²	44
Tabela 2 - Métricas do modelo de regressão.....	46

LISTA DE ABREVIATURAS E SIGLAS

AGB	<i>Aboveground Biomass</i> (Biomassa Acima do Solo)
Δ AGB	Variação de Biomassa Acima do Solo
AGBD	<i>Aboveground Biomass Density</i> (Densidade de Biomassa Acima do Solo)
APA	Área de Proteção Ambiental
BOA	<i>Bottom of Atmosphere</i> (Reflectância na base da atmosfera)
C	Carbono
CNN	<i>Convolutional Neural Networks</i> (Redes Neurais Convolucionais)
CO ₂	Dióxido de Carbono
CO ₂ e	Dióxido de Carbono Equivalente
DAP	Diâmetro à Altura do Peito
ES	Espírito Santo
ESA	European Space Agency (Agência Espacial Europeia)
EVI	<i>Enhanced Vegetation Index</i> (Índice de Vegetação Melhorado)
GEDI	Global Ecosystem Dynamics Investigation
GEE	Google Earth Engine
GRD	Ground Range Detected
IA	Inteligência Artificial
IBAMA	Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis
ICMBio	Instituto Chico Mendes de Conservação da Biodiversidade
IEMA	Instituto Estadual de Meio Ambiente e Recursos Hídricos
IPCC	Intergovernmental Panel on Climate Change (Painel Intergovernamental sobre Mudanças Climáticas)
ISS	International Space Station (Estação Espacial Internacional)
IW	<i>Interferometric Wide Swath</i>
LAI	<i>Leaf Area Index</i> (Índice de Área Foliar)
LiDAR	<i>Light Detection and Ranging</i> (Detecção e alcance de luz)
MAE	<i>Mean Absolute Error</i> (Erro Médio Absoluto)
MDT	Modelo Digital de Terreno
Mg/ha	Megagramas por hectare
ML	<i>Machine Learning</i> (Aprendizado de Máquina)
MMA	Ministério do Meio Ambiente
MODIS	Moderate Resolution Imaging Spectroradiometer

MSI	<i>Multi-Spectral Instrument</i> (Instrumento Multiespectral)
NASA	National Aeronautics and Space Administration (Administração Nacional da Aeronáutica e Espaço)
NDMI	<i>Normalized Difference Moisture Index</i> (Índice de Umidade por Diferença Normalizada)
NDPI	<i>Normalized Difference Polarization Index</i> (Índice de Polarização por Diferença Normalizada)
NDRE	<i>Normalized Difference Red Edge Index</i> (Índice de Diferença Normalizada da Borda Vermelha)
NDVI	<i>Normalized Difference Vegetation Index</i> (Índice de Vegetação por Diferença Normalizada)
NDWI	<i>Normalized Difference Water Index</i> (Índice de Água por Diferença Normalizada)
NIR	<i>Near Infrared</i> (Infravermelho Próximo)
RDS	Reserva de Desenvolvimento Sustentável
RDSM	Reserva de Desenvolvimento Sustentável Municipal
RF	<i>Random Forest</i> (Floresta Aleatória)
RMSE	<i>Root Mean Square Error</i> (Raiz do Erro Quadrático Médio)
RVI	<i>Radar Vegetation Index</i> (Índice de Vegetação por Radar)
S1	Sentinel-1
S2	Sentinel-2
SAR	<i>Synthetic Aperture Radar</i> (Radar de Abertura Sintética)
SAVI	Soil Adjusted Vegetation Index (Índice de Vegetação Ajustado ao Solo)
SEMAM	Secretaria Municipal de Meio Ambiente
SIAC	<i>Sensor Invariant Atmospheric Correction</i> (Método de correção atmosférica)
SNUC	Sistema Nacional de Unidades de Conservação da Natureza
SR	Sensoriamento Remoto
SWIR	Short-Wave Infrared (Infravermelho de Onda Curta)
t/ha	Toneladas por hectare
TOA	<i>Top of Atmosphere</i> (Reflectância no topo da atmosfera)
UAV	<i>Unmanned Aerial Vehicle</i> (Veículo Aéreo Não Tripulado)
UFES	Universidade Federal do Espírito Santo
UNESCO	Organização das Nações Unidas para a Educação, a Ciência e a Cultura

VH	Vertical-Horizontal (Polarização Vertical na transmissão e Horizontal na recepção)
VV	Vertical-Vertical (Polarização Vertical na transmissão e na recepção)

SUMÁRIO

1 INTRODUÇÃO.....	13
2 PROBLEMA.....	15
3 OBJETIVOS.....	16
3.1 Geral.....	16
3.2 Específicos.....	16
4 FUNDAMENTAÇÃO TEÓRICA.....	16
4.1 A Paisagem.....	16
4.2 O Olhar Analítico da Geografia.....	17
4.3 Sensoriamento Remoto.....	19
4.3.1 Sensores remotos.....	19
4.3.2 Sentinel-2.....	20
4.3.3 Sentinel-1.....	20
4.3.4 GEDI (<i>Global Ecosystem Dynamics Investigation</i>).....	21
4.3.5 Índices aplicados às imagens satelitais.....	21
4.3.5.1 Índice NDVI.....	22
4.3.5.2 Índice EVI.....	22
4.3.5.3 Índice SAVI.....	23
4.3.5.4 Índice NDRE.....	23
4.3.5.5 Índice NDMI.....	23
4.3.5.6 Índice NDWI.....	24
4.3.5.7 Índice RVI.....	24
4.3.5.8 Índice NDPI.....	25
4.4 Aprendizado de Máquina.....	25
4.4.1 Random Forest.....	26
4.5 Google Earth Engine.....	27
4.6 Definição e importância ecológica dos manguezais e sua biomassa.....	27
4.6.1 O papel da AGB na mitigação das mudanças climáticas.....	28
4.6.2 Mensuração tradicional de AGB em manguezais.....	29

4.7 Estimativa de biomassa por sensoriamento remoto.....	29
4.7.1 Relações Alométricas e Variáveis Preditoras.....	30
4.7.2 Aplicabilidade dos sensores orbitais.....	31
4.7.3 Integração de Dados Multisensores e Machine Learning.....	32
4.8 Estudos de caso.....	33
4.8.1 Lacunas na Estimativa de AGB em Manguezais por Sensoriamento Remoto.....	33
5 METODOLOGIA.....	34
5.1 Caracterização da área de estudo.....	34
5.2 Aquisição dos dados.....	37
5.2.1 Filtragem dos dados do Sentinel-2.....	37
5.2.2 Filtragem dos dados do Sentinel-1.....	38
5.2.3 Filtragem dos dados GEDI.....	38
5.2.4 Aplicação de índices às imagens.....	39
5.2.5 Criação da imagem para treinamento.....	40
5.3 Delimitação da área de mangue.....	40
5.4 Predição da biomassa acima do solo.....	41
5.4.1 Aplicação de reescala aos dados de biomassa.....	41
6 RESULTADOS.....	42
6.1 Estatísticas gerais da área.....	43
6.2 Métricas do modelo de regressão.....	46
6.2.1 Diagnóstico do modelo.....	47
6.2.2 Limitações do GEDI em áreas de alta concentração de biomassa.....	48
6.2.3 Escolhas metodológicas.....	49
7 CONSIDERAÇÕES FINAIS.....	50
REFERÊNCIAS.....	52

1 INTRODUÇÃO

As mudanças climáticas e as atividades humanas são reconhecidamente indissociáveis. As ações antrópicas, sobretudo aquelas que intensificam a emissão de gases do efeito estufa, sempre exerceram um papel histórico na contribuição para o aquecimento global, de modo que, atualmente, a temperatura média encontra-se 1,1 °C acima do nível registrado no final do século XIX. As emissões de gases continuam a aumentar, impulsionadas pelo uso insustentável de energia, pelas alterações no uso da terra e pelos padrões de consumo vigentes. Sem a desaceleração do processo atual, projeta-se que a temperatura global atinja 1,5 °C acima da média entre 2030 e 2035 (IPCC, 2023).

O aumento da concentração de gases do efeito estufa, desde 1750, é intrinsecamente causado pelas atividades humanas, com taxas de emissão históricas entre 1850 e 2019, sendo 58% desta emissão registrada entre 1850 e 1989 e 42% entre 1990 e 2019. Para limitar o aquecimento, as emissões globais precisam ser reduzidas em pelo menos 43% até 2030 e 60% até 2035 (IPCC, 2023).

Como forma notoriamente eficaz de mitigar os efeitos da concentração de dióxido de carbono (CO₂) na atmosfera, a preservação da cobertura vegetal terrestre é, reconhecidamente, um fator fundamental no enfrentamento às mudanças climáticas no contexto global. O papel desempenhado por ela ocorre tanto de forma direta, com a interceptação dos raios solares (barreira física), quanto indiretamente, com destaque para o processo de fotossíntese. Nesse processo, ao utilizarem o CO₂, as plantas retêm o carbono (C), o qual é incorporado à sua estrutura, e retornam com o oxigênio (O) para a atmosfera (Taub, 2010).

Entre as formações vegetais com maior relevância para a mitigação das mudanças climáticas, os manguezais destacam-se como ecossistemas costeiros de excepcional capacidade sequestradora de carbono. Distribuídos ao longo das regiões tropicais e subtropicais do planeta, esses sistemas apresentam uma eficiência biogeoquímica singular: estudos demonstram que sua combinação do sistema radicular especializado com a dinâmica sedimentar permite taxas de sequestro de carbono até 50 vezes superiores às de florestas terrestres (Donato *et al.*, 2011; McLeod *et al.*, 2011).

Além do potencial de captura de CO₂ e proteção costeira já mencionados, os manguezais enfrentam ameaças crescentes decorrentes de atividades humanas, como urbanização costeira, aquicultura e extração de recursos e dos impactos das mudanças climáticas, incluindo a elevação do nível do mar e eventos extremos (UNESCO, 2019). A preservação e a gestão sustentável desses ecossistemas, encontrados em regiões tropicais, desempenham papel crítico

tanto na mitigação das mudanças climáticas quanto na proteção das áreas costeiras, notadamente por sua contribuição ao chamado “carbono azul”.

Conceitualmente, mangue refere-se a um conjunto de árvores tropicais que pertencem a diferentes famílias botânicas, mas que compartilham adaptações fisiológicas que permitem sua sobrevivência em ambientes de água salobra ou salgada, adaptações importantes em solos com baixa disponibilidade de oxigênio e substrato instável. Por outro lado, o manguezal se refere às comunidades florestais formadas por essas árvores, englobando o ecossistema de maneira integral. Isso inclui as interações entre plantas, animais e microrganismos, além das condições abióticas do ambiente, configurando um sistema ecológico complexo onde diversas formas de vida coexistem em um habitat específico (Schaeffer-Novelli, 2018).

Além do fato de 50% da madeira encontrada nos manguezais ser constituída de carbono, ou seja, pode ser um depósito duradouro caso seja preservado, outra característica desse ecossistema se destaca; sua grande capacidade de estocar carbono no solo e nos sedimentos, o que é conhecido como *sinks* ou sumidouros de carbono. Esse estoque pode manter grandes quantidades de CO₂ armazenadas por longos períodos (Breithaupt *et al.*, 2012).

Além do potencial de captura do CO₂, as florestas de mangues, com destaque para a *Rhizophora mangle* (mangue-vermelho), atuam diretamente na proteção das áreas costeiras, na medida que amortecem a energia das águas do mar em períodos de ressacas marinhas. Essa atuação diminui significativamente os processos erosivos causados pelas marés, uma vez que as raízes entrelaçadas filtram o fluxo de sedimentos (Deyoe, 2020).

Conforme exposto, os mangues são considerados grandes fontes de carbono, exercendo uma importante função de “sequestro” e “estocagem” desse elemento. Todavia, mesmo com esse papel de grande importância, os manguezais são ecossistemas ameaçados, que sofrem com constantes desgastes, tendo sua área reduzida drasticamente no decorrer dos anos (ICMBio, 2018).

Os manguezais também apresentam uma grande e importante diversidade vegetal e animal, representando uma estrutura fundamental para as comunidades costeiras e provendo insumos como alimentos e matéria-prima, assim como provê fonte de renda advinda de atividades pesqueiras.

Diante da crescente degradação dos manguezais e de seu reconhecido potencial como sumidouros de carbono, este estudo objetiva quantificar a capacidade e avaliar a importância ecológica desses ecossistemas no Espírito Santo, utilizando como estudo de caso a Reserva Piraquê-Açu-Mirim. A pesquisa estrutura-se em duas etapas: (1) a análise do papel desses ecossistemas nos sistemas de carbono azul e (2) o desenvolvimento de modelos preditivos

baseados em inteligência artificial para estimar seu potencial de sequestro de carbono, utilizando como parâmetro principal a biomassa acima do solo (AGB, do inglês Aboveground Biomass).

A estratégia apresentada, utilizará como base, dados de sensores remotos gratuitos com abrangência global, como Sentinel-1 e 2, que serão melhor descritos na metodologia. Soma-se a isso, a aplicação de formas de modelagem que se mostrem mais facilmente replicáveis e de baixo custo operacional quando comparadas às tradicionalmente utilizadas.

2 PROBLEMA

Muitas das análises e modelagens propostas para o território nacional, no que se refere aos estoques de carbono, concentram-se em áreas de floresta amazônica, como no estudo realizado por Sato *et al.* (2015), que analisou a biomassa florestal no sudoeste da Amazônia. Essas análises contam com a maior disponibilidade de dados de campo, bem como com dados LiDAR de alta precisão, obtidos por sensoriamento a laser, os quais são de grande importância para a mensuração da biomassa vegetal.

Análises realizadas em regiões de mangues buscam identificar, espacializar, interpretar e responder problemas relacionados a dinâmicas ou ações ocorridas localmente, mas a mensuração das consequências desses problemas, principalmente no que diz respeito à variação de carbono “sequestrado” ainda se mostra incipiente. Isso se torna ainda mais escasso quando se trata de análises via sensoriamento remoto no Brasil.

No que tange à mensuração do sequestro de carbono pelo ecossistema de manguezais, a estimativa da biomassa acima do solo constitui um dado fundamental. Contudo, sua determinação depende de um conjunto de técnicas e ferramentas que abrangem desde análises botânicas até mensurações indiretas, baseadas em dados coletados em campo ou por meio de sensores LiDAR, conforme evidenciado nos estudos de Pereira (2016) e Huang (2025), os quais realizaram medições com sensores aerotransportados. Esse modelo pode tornar-se oneroso, tanto do ponto de vista analítico quanto financeiro, quando aplicado a regiões extensas ou a múltiplas áreas de interesse.

Diante desse cenário, o desenvolvimento de um modelo alternativo para estimar a biomassa dos manguezais e, conseqüentemente, sua capacidade de sequestrar carbono apresenta grande relevância. Um método baseado em dados de fácil acesso, gratuitos e com consistência estatística adequada, além de replicável espacialmente e independente de dados de alta resolução ou operações de campo, se mostra valioso para análises climáticas e ambientais de manguezais por sensoriamento remoto.

Diante do exposto, a utilização de modelos de aprendizado de máquina baseados em dados gratuitos (Sentinel-1 e 2) permite quantificar a capacidade de sequestro de carbono dos manguezais com base na biomassa acima do solo, bem como analisar as implicações da redução de sua cobertura. Ao elucidar esse papel na mitigação das mudanças climáticas, o estudo visa subsidiar estratégias de conservação mais eficazes e promover maior conscientização para sua preservação. Adicionalmente, a metodologia proposta poderá ser replicada em outras áreas de manguezais, possibilitando monitoramento contínuo da capacidade de retenção de carbono por esses ecossistemas.

3 OBJETIVOS

3.1 Geral

Desenvolver um modelo capaz de quantificar a biomassa acima do solo no manguezal Piraquê-Açu no estado do Espírito Santo–ES, utilizando técnicas de sensoriamento remoto e uso de inteligência artificial para aprendizado de máquina.

3.2 Específicos

- Identificar os principais dados e variáveis necessários para mensuração da biomassa dos manguezais e fatores que influenciam a capacidade de sequestro de carbono dos manguezais para construção de um modelo de inteligência artificial (IA);
- Desenvolver um modelo de *machine learning* (ML) de baixo custo e capaz de estimar a biomassa das áreas de manguezais;
- Identificar áreas que passaram por grandes alterações em sua composição e os efeitos disso em sua biomassa;
- Quantificar, avaliar e validar o modelo a partir da modelagem da biomassa.

4 FUNDAMENTAÇÃO TEÓRICA

4.1 A Paisagem

De acordo com Maximiano (2004), a noção de paisagem antecede a criação do seu conceito, acompanhando o homem desde o início de sua jornada evolutiva. A relação entre o homem e a natureza foi e ainda é foco de análise da Geografia. Parte disso se deve ao fato da complexidade de fatores e agentes intrínsecos a essa relação, partindo desde ideias descritivas da paisagem iniciadas com Alexander von Humboldt, até as complexas e profundas relações interdependentes propostas por Milton Santos.

A relação entre o homem e a natureza se conecta constantemente nas definições de paisagem propostas pelos principais pensadores da geografia. Para Ab'Saber (2003), a paisagem

é uma formação complexa, resultado da dinâmica da natureza no decorrer do tempo, mas também é uma construção social, fruto da interação entre o homem e o meio ambiente. As relações de forma, biótica e o conceito de antroposfera indicam os agentes envolvidos nessa dinâmica.

Também seguindo uma proposta integrada da paisagem, onde todos seus fatores e personagens se relacionam de forma sistêmica, Bertrand (1968) propõe uma abordagem sistêmica e integrada da natureza, desenvolvendo o conceito de Geossistema, que retira a natureza de uma visão puramente estatística ou descritiva e a coloca como um sistema dinâmico onde a ação humana é um componente central, evoluindo de uma classificação técnica da paisagem para um modelo filosófico e social.

Bertrand define a paisagem não como um cenário estático, mas como o resultado da combinação dinâmica de elementos físicos, biológicos e antrópicos. O geossistema é regido por uma tríade de forças que interagem dialeticamente: potencial ecológico (suporte físico-químico), exploração biológica (componente vivo) e ação antrópica (intervenção humana). Sendo a intervenção humana não um fator "externo", mas parte integrante do sistema.

Sendo assim, a paisagem não se apresenta somente como um conjunto de elementos geográficos, mas sim como uma combinação dinâmica e instável de elementos físicos, biológicos e antrópicos, fazendo da paisagem um conjunto único, indissociável e em constante evolução (Bertrand, 2004).

4.2 O Olhar Analítico da Geografia

Ao analisar eventos naturais que decorrem de processos complexos envolvendo múltiplos agentes, Silva (2012) prega que a postura a ser adotada pelo geógrafo deve se basear em compreender além de fatos fragmentados e dados isolados, pretendendo-se assim uma análise dinâmica que considera as complexidades, conflitos e contradições envolvidos no processo.

Para Silva, a relação entre o homem e a natureza é um tema central na Geografia, que busca compreender as complexas interações entre a sociedade e o ambiente. A crescente interferência humana nos ecossistemas, amplia a necessidade de se avaliar os custos ecológicos, sociais e econômicos dessa ação. Além disso, o estudo do ambiente físico implica na análise do espaço geográfico e dos aspectos ambientais nele inseridos, incluindo a dinâmica da paisagem.

A partir da relação apresentada, as geotecnologias, como ferramentas de registro e compreensão dos padrões e processos que atuam na paisagem, desempenham um papel fundamental nesta análise. No entanto, o uso efetivo das geotecnologias requer uma abordagem interdisciplinar e a adoção do pensamento sistêmico. Nesse aspecto, a Teoria da Paisagem surge

como uma estrutura conceitual capaz de integrar diferentes áreas do conhecimento e compreender a complexidade dos sistemas ambientais (Silva, 2012).

Do ponto de vista dos estudos do ambiente por meio da geografia, objetivando a análise das dinâmicas envolvidas na paisagem, a abordagem geoecológica apresentada por Rodriguez (2017) se mostra como uma perspectiva necessária para a compreensão dessas dinâmicas. Nessa abordagem, procedimentos e técnicas investigativas são utilizados como forma de obter conhecimento sobre o ambiente, permitindo, a partir disso, estabelecer uma abordagem operacional.

Ainda de acordo com Rodriguez (2017), o conceito central da Geoecologia da Paisagem é o geossistema, que define a paisagem como um sistema territorial composto por elementos naturais e antrópicos em interação, funcionando na totalidade. Para classificar e mapear as paisagens, a Geoecologia utiliza métodos de regionalização e tipologia, distinguindo unidades individuais (regiões) e unidades repetitivas (tipos).

Além disso, a Geoecologia da Paisagem também aborda a geodiversidade, conceito que engloba a variedade de elementos abióticos em um território e suas inter-relações. Essa abordagem destaca a importância fundamental da geodiversidade para a manutenção da biodiversidade e da diversidade sociocultural. O campo de estudo analisa sistematicamente os impactos ambientais, examinando tanto as ações antrópicas quanto as mudanças naturais, bem como seus efeitos ecológicos decorrentes. Como parte essencial dessa análise, propõe métodos robustos para avaliar e classificar tais impactos, contribuindo para o planejamento territorial sustentável.

A Geoecologia fornece uma base para um planejamento ambiental integrado, que considere as propriedades e potencialidades dos geossistemas. Suas contribuições para a Geografia incluem uma visão sistêmica e holística da paisagem, uma análise aprofundada da relação sociedade-natureza e o desenvolvimento de ferramentas para o planejamento e a gestão ambiental, bem como para a conservação da natureza (Rodriguez, 2017).

As alterações antrópicas constituem uma variável determinante na transformação da paisagem. Para analisar sistematicamente tanto a magnitude dessas alterações quanto suas implicações ecológicas e sociais, a abordagem geoecológica proposta por Rodriguez (2017) oferece um arcabouço metodológico robusto. Esta abordagem integra técnicas investigativas para compreensão da dinâmica natural e protocolos diagnósticos operacionais que permitem avaliar o estado e evolução de ecossistemas.

A partir de análises propostas, o papel da Geografia e consequentemente do geógrafo no contexto de um estudo da natureza, se encontra em analisar e compreender não apenas

fragmentos isolados do tempo e espaço, mas sim uma dinâmica interdependente, cercada de conflitos e contradições de diversas formas (Silva, 2012).

4.3 Sensoriamento Remoto

No que se refere à análise ambiental de áreas extensas ou de difícil acesso, o sensoriamento remoto (SR) se coloca como uma ferramenta de análise fundamental, permitindo que o pesquisador obtenha imagens e informações da superfície terrestre sem contato físico entre as ferramentas envolvidas no processo de obtenção das informações (Meneses; Almeida, 2012).

Em complemento à definição anterior, Silva (2022, p. 21) afirma que: “[...] o Sensoriamento Remoto é uma metodologia que a partir de diferentes técnicas (aplicação de índices, composição de bandas, modelagens) permite a extração de informações sem que haja, efetivamente, contato físico entre o pesquisador e o seu objeto de interesse”.

A versatilidade e o amplo espectro de aplicações do sensoriamento remoto possibilitam análises paisagísticas abrangentes em regiões geograficamente distantes do observador. Essa característica singular permite investigar de forma integrada os diversos agentes envolvidos em fenômenos de grande escala que ocorrem na superfície terrestre (Lillesand, 2015).

4.3.1 Sensores remotos

Os dados utilizados pelo SR derivam em sua maioria de sensores remotos orbitais posicionados ao redor da terra, captando a radiação eletromagnética refletida ou emitida pelos alvos de interesse e podendo ser aplicada em diversas áreas, como monitoramento ambiental, agricultura, urbanismo e gestão de recursos naturais.

Conforme Lillesand (2015), os sensores remotos são dispositivos optoeletrônicos passíveis de classificação em duas categorias principais: sensores passivos, que captam a radiação refletida ou emitida naturalmente pelos objetos, tendo a luz solar como fonte mais comum; e sensores ativos, que emitem sua própria radiação e mensuram a energia refletida de volta. Exemplos desses sistemas incluem radar e *Light Detection and Ranging* (LiDAR), os quais utilizam pulsos de laser para mapear a superfície terrestre, dados *Synthetic Aperture Radar* (SAR), obtidos por radares com emissões de micro-ondas, e dados provenientes de satélites ópticos convencionais, que oferecem informações tanto do espectro visível quanto do infravermelho.

Os sensores multiespectrais, são uma das principais formas de obter dados da superfície. Eles são eficientes devido à capacidade de obter dados em formato digital, operar em plataformas espaciais e captar imagens em um amplo intervalo de comprimento de onda. Isso permite uma monitoração precisa dos eventos e mudanças ambientais, além de possibilitar aplicações

em diversas áreas, como Ciências da Terra. O processamento digital de imagens é uma tecnologia que surgiu a partir do uso desses sensores, permitindo a análise qualitativa e quantitativa das imagens (Meneses; Almeida, 2012).

As imagens do SAR, operam na região das micro-ondas, com comprimentos de onda maiores que os da luz visível, permitindo obter imagens mesmo em condições de nuvens ou à noite. Porém, as imagens de radar não são tão intuitivas quanto às imagens multiespectrais ópticas e requerem um processamento distinto e interpretação distintas (Meneses; Almeida, 2012).

4.3.2 Sentinel-2

O Sentinel-2 (S2) é uma missão de observação da Terra desenvolvida pela *European Space Agency* (ESA) como parte do programa Copernicus. Esta missão consiste em uma constelação de dois satélites, Sentinel-2A e Sentinel-2B, que operam em órbita para fornecer imagens ópticas de alta resolução da superfície terrestre. O Sentinel-2C foi lançado em setembro de 2024, aumentando a capacidade de coleta de dados da missão (ESA, 2025).

O S2 é equipado com um instrumento denominado *Multi-Spectral Instrument* (MSI), que possui 13 bandas espectrais. Essas bandas variam em resolução espacial de 10 m a 60 m, permitindo a captura de dados em diferentes comprimentos de onda, incluindo visível, infravermelho próximo e infravermelho de onda curta. A missão oferece uma cobertura global da superfície terrestre a cada 5 dias, permitindo o monitoramento agrícola, gestão de desastres e estudos ambientais. A largura do feixe orbital é de 290 km, permitindo uma ampla cobertura em cada passagem (ESA, 2025).

4.3.3 Sentinel-1

O Sentinel-1 (S1) é uma missão de observação da Terra que também faz parte do programa Copernicus, desenvolvido pela ESA. Esta missão consiste em uma constelação de satélites que utilizam radar de abertura sintética (SAR) na banda C, permitindo a captura de imagens da superfície terrestre em qualquer condição climática, tanto de dia quanto de noite (ESA, 2025).

A constelação do S1 é composta por dois satélites, Sentinel-1A e Sentinel-1B, que operam em um plano orbital com um desfasamento de 180°. Isso permite que a cobertura da Terra seja realizada a cada seis dias, melhorando significativamente a frequência de revisita em comparação com missões anteriores. O instrumento principal a bordo é um radar de abertura sintética que opera em quatro modos de imagem, com resoluções que podem chegar a 5 metros (ESA, 2025).

4.3.4 GEDI (*Global Ecosystem Dynamics Investigation*)

O Global Ecosystem Dynamics Investigation (GEDI) é uma missão espacial da National Aeronautics and Space Administration (NASA) que utiliza um instrumento de LiDAR para mapear a estrutura tridimensional das florestas da Terra. Lançado em 5 de dezembro de 2018, o GEDI está acoplado à Estação Espacial Internacional (ISS) e é projetado para coletar dados sobre a dinâmica dos ecossistemas, contribuindo para a compreensão do ciclo do carbono e da biodiversidade (GEDI, 2024).

O GEDI utiliza três lasers que produzem um total de oito transectos de feixes, permitindo medições de alta resolução da altura da copa das árvores, da estrutura vertical da copa e da elevação da superfície. Cada feixe cobre uma área de aproximadamente 30 metros de diâmetro, com espaçamento de cerca de 60 metros ao longo do trajeto (GEDI, 2024).

As principais características técnicas, potencialidades e limitações de cada sensor é apresentada na (Quadro 1).

Quadro 1 - Sumário de características dos sensores

Características	Sentinel-2 (Óptico)	Sentinel-1 (SAR)	GEDI (LiDAR)
Informação Primária	Propriedades fisiológicas, reflectância da superfície, índices de vegetação	Estrutura do dossel, rugosidade da superfície, umidade, penetração	Estrutura vertical 3D, altura do dossel, perfil de folhagem
Comprimentos de Onda/Bandas-chave	Visível, NIR, SWIR, Red-Edge	C-band (L-band, P-band para maior penetração)	Infravermelho próximo (1064 nm)
Resolução Espacial Típica	10-60m	10-20m	25m (amostra)
Vantagens Principais para Manguezais	Ampla cobertura, dados de livre acesso, bandas red-edge	Penetração de nuvens, dia/noite, sensibilidade à estrutura	Alta precisão, não saturação em alta biomassa, estrutura vertical
Limitações Principais para Manguezais	Saturação em alta biomassa, afetado por nuvens	Saturação em alta biomassa (C-band), complexidade de processamento	Dados amostrais (não contínuos), necessidade de extrapolação

Elaboração: O autor (2026)

Fonte: Baloloy (2018); Farzanmanesh (2024); Li (2021); O autor (2026).

4.3.5 Índices aplicados às imagens satelitais

Os índices de imagens de satélite são fórmulas matemáticas aplicadas a dados de imagens multiespectrais, que combinam informações de diferentes bandas espectrais para destacar características específicas da superfície da Terra. Esses índices são fundamentais na análise de imagens de satélite, pois permitem a extração de informações valiosas sobre fenômenos ambientais, como a saúde da vegetação, a umidade do solo e a composição da terra (EOS, 2024).

Os índices espectrais fundamentam-se no comportamento diferenciado da reflectância dos alvos ao longo do espectro eletromagnético, explorando contrastes entre bandas específicas para realçar propriedades biofísicas da superfície. Um exemplo, é o *Normalized Difference Vegetation Index* (NDVI), que utiliza as bandas do vermelho e do infravermelho próximo para estimar vigor vegetativo.

Nesta pesquisa, múltiplos índices com diversas correlações de bandas e características foram utilizados, objetivando entregar ao algoritmo principal correlações mais complexas das superfícies do que apenas os dados originais do satélite.

O motivo da escolha de cada índice utilizado e suas respectivas características serão devidamente indicados nos itens abaixo.

4.3.5.1 Índice NDVI

O NDVI, proposto por Rouse (1973) é uma métrica amplamente utilizada para quantificar a saúde e a densidade da vegetação na superfície terrestre. Ele é calculado a partir da diferença normalizada dados espectrométricos que medem a luz refletida em duas bandas específicas: o vermelho (Red) e o infravermelho próximo (NIR).

O intervalo de valores do NDVI varia de -1 a 1, no qual valores negativos (próximos de -1) correspondem geralmente a água ou nuvens, valores próximos de zero indicam áreas desprovidas de vegetação, como rochas ou areia e valores positivos (0,1 a 0,5) representam vegetação esparsa, enquanto valores acima de 0,6 indicam vegetação densa e saudável, como florestas tropicais.

4.3.5.2 Índice EVI

O *Enhanced vegetation index* (EVI) desenvolvido por Huete (1994) foi criado para melhorar a sensibilidade na detecção de vegetação em áreas de alta biomassa e para reduzir os efeitos da atmosfera e do solo nas medições de vegetação, especialmente em regiões densamente vegetadas. O EVI é uma modificação do NDVI e foi projetado para ser menos suscetível à saturação em áreas com vegetação densa, o que o torna uma ferramenta valiosa para monitoramento ambiental e agrícola. A fórmula do EVI inclui correções para a dispersão de aerossóis e fatores de ajuste para o solo, permitindo uma análise mais precisa da saúde da vegetação.

O EVI utiliza as bandas do espectro vermelho (*Red*), azul (*Blue*) e infravermelho próximo (NIR). Sua formulação conta com fator de ganho “G” (geralmente definido como 2.5), “C1” e “C2” com coeficientes para correção da influência atmosférica (normalmente definidos como 6 e 7,5, respectivamente) e fator “L” para o ajuste do fundo da copa (geralmente definido

como 1) para lidar com a transferência de radiação não linear através da copa das árvores (Huete, 1994).

4.3.5.3 Índice SAVI

O *Soil Adjusted Vegetation Index* (SAVI) constitui uma importante ferramenta para o monitoramento da cobertura vegetal, desenvolvido por Huete (1988) especificamente para corrigir distorções causadas pela reflectância do solo em áreas com vegetação esparsa. Este índice surgiu como uma solução para duas limitações críticas do NDVI: sua sensibilidade excessiva ao solo exposto em áreas de baixa cobertura vegetal e sua rápida saturação em regiões de vegetação densa, onde perde capacidade discriminatória entre diferentes níveis de biomassa.

O SAVI destaca-se como ferramenta especialmente útil para áreas com cobertura vegetal esparsa, como regiões áridas ou semiáridas, além de locais impactados por perturbações antrópicas (desmatamento, queimadas) ou naturais que resultaram em significativa perda de biomassa. Sua formulação incorpora um parâmetro de correção L, variando geralmente entre 0,5 e 1,0, que atenua os efeitos da reflectância do solo sobre o sinal espectral, permitindo maior sensibilidade na detecção da vegetação mesmo em áreas com exposição significativa de solo. Esse ajuste é particularmente relevante em ambientes com densidade vegetal baixa a intermediária, nos quais a contribuição do solo poderia distorcer as estimativas de vigor vegetativo obtidas por índices convencionais, como o NDVI.

4.3.5.4 Índice NDRE

O *Normalized Difference Red Edge* (NDRE), proposto por Barnes *et al.* (2000), é aplicado na detecção da variação na concentração de clorofila e nitrogênio, sendo ideal para monitorar deficiências nutricionais em estágios tardios da cultura.

Este índice é mais resistente à saturação em culturas de alta densidade, como milho e cana-de-açúcar, ao contrário do NDVI, que pode perder sensibilidade quando a clorofila atinge níveis mais altos no decorrer da maturação.

A interpretação de seus valores é similar a outras diferenças normalizadas voltadas a análises vegetativas.

4.3.5.5 Índice NDMI

O *Normalized Difference Moisture Index* (NDMI) é um índice espectral utilizado em sensoriamento remoto para avaliar a condição hídrica da vegetação. Esse índice é calculado a partir das reflectâncias nas regiões do infravermelho próximo (NIR) e do infravermelho de ondas curtas (SWIR), sendo expresso pela razão normalizada entre essas duas bandas.

A utilização da região SWIR está relacionada à sua elevada sensibilidade à presença de água na vegetação, uma vez que a absorção da radiação nessa faixa espectral aumenta com o conteúdo hídrico das folhas, resultando, em geral, em menor reflectância. A região NIR, por sua vez, apresenta elevada reflectância da vegetação e é fortemente influenciada por sua estrutura interna.

O índice NIR–SWIR foi proposto por Gao (1996) sob a denominação *Normalized Difference Water Index* (NDWI), enquanto a denominação *Normalized Difference Moisture Index* (NDMI) foi empregada posteriormente por Wilson e Sader (2002) para esse tipo de índice espectral.

4.3.5.6 Índice NDWI

O NDWI, proposto por McFeeters (1996) no mesmo ano que Gao (1996), é um índice utilizado em sensoriamento remoto para identificar e quantificar a presença de água em uma determinada área. Diferentemente do NDMI, que busca estimar a umidade foliar, o NDWI é especialmente eficaz para destacar corpos d'água em imagens de satélite, permitindo que esses corpos se sobressaíam em relação ao solo e à vegetação. O índice é gerado a partir da diferença normalizada entre as bandas do verde (*Green*) e do infravermelho próximo (NIR).

Seus valores variam de -1 a +1: valores acima de 0,5 indicam presença significativa de água; valores entre 0 e 0,2 podem indicar áreas de inundação ou umidade; e valores negativos correspondem, geralmente, a superfícies não aquáticas, como solo ou vegetação seca.

4.3.5.7 Índice RVI

O *Radar Vegetation Index* (RVI), é utilizado em sensoriamento remoto para avaliar a cobertura e a saúde da vegetação. Este índice é voltado para utilização com dados de radar, como os obtidos por meio de sistemas de Radar de Abertura Sintética (SAR). O RVI é calculado a partir das intensidades de retroespalhamento linear, que incluem tanto polarizações co-polarizadas quanto cruzadas, onde σ_{VH} é o coeficiente de retroespalhamento polarizado cruzado (Vertical-Horizontal) e σ_{VV} é o coeficiente de retroespalhamento polarizado co-polarizado (Vertical-Vertical).

Os valores do RVI variam teoricamente de 0 a 1 (podem ultrapassar 1), sendo valores próximos a 0 indicativos de áreas áridas ou com pouca vegetação, como solo nu ou plantas jovens e valores próximos a 1 indicativos de uma densa cobertura vegetal, como florestas ou campos agrícolas saudáveis (Kim, 2001).

4.3.5.8 Índice NDPI

O *Normalized Difference Polarization Index* (NDPI) é frequentemente empregado em técnicas de sensoriamento remoto por SAR. Este índice fundamenta-se nas polarizações SAR, habitualmente σ_{VV} e σ_{VH} (ou HH e HV). Valores elevados (≥ 1) indicam predomínio de espalhamento superficial, característico de solo exposto e áreas áridas; por outro lado, valores reduzidos (≤ 0), associados ao maior espalhamento volumétrico, são representativos de vegetação densa com elevada biomassa.

As fórmulas e as relações entre bandas dos índices utilizados encontram-se no Quadro 2, apresentado a seguir.

Quadro 2 - Fórmula dos índices utilizados.

Índice	Fórmula
NDVI	$NDVI = \frac{(NIR - Red)}{(NIR + Red)}$
EVI	$EVI = \frac{G * (NIR - Red)}{(NIR + C1 * Red - C2 * Blue + L)}$
SAVI	$SAVI = \frac{(1 + L) * (NIR - Red)}{(NIR + Red + L)}$
NDRE	$NDRE = \frac{(NIR - Red\ Edge)}{(NIR + Red\ Edge)}$
NDMI	$NDMI = \frac{(NIR - SWIR1)}{(NIR + SWIR1)}$
NDWI	$NDWI = \frac{(Green - NIR)}{(Green + NIR)}$
RVI	$RVI = \frac{4 * \sigma_{VH}}{\sigma_{VV} + \sigma_{VH}}$
NDPI	$NDPI = \frac{(\sigma_{VV} - \sigma_{VH})}{(\sigma_{VV} + \sigma_{VH})}$

Fonte: O autor, 2026.

4.4 Aprendizado de Máquina

O Aprendizado de Máquina (ML) é um subcampo da Inteligência Artificial (IA) que se concentra na criação de algoritmos que podem aprender com dados sem serem explicitamente programados. Ao contrário da programação tradicional, na qual as instruções são codificadas manualmente, os algoritmos de ML aprendem com exemplos e dados históricos, identificando padrões e relações complexas que podem ser usados para fazer previsões, tomar decisões e automatizar tarefas (Monard, 2003).

De acordo com Hosch (2023), *Machine Learning* é um método de análise de dados que automatiza a construção de modelos analíticos. É um ramo da inteligência artificial baseado na ideia de que os sistemas podem aprender através dos dados estruturados, identificar padrões e tomar decisões com uma reduzida intervenção humana.

Dentre os principais métodos de ML, três se destacam: o aprendizado supervisionado, o aprendizado não supervisionado e o aprendizado por reforço. No aprendizado supervisionado os algoritmos recebem um conjunto de dados de treinamento rotulados, de modo que cada exemplo possui um rótulo que define a classe ou valor correto. O objetivo do algoritmo é aprender a mapear os dados de entrada para os rótulos correspondentes, permitindo que ele faça previsões para novos dados não rotulados.

Em um modelo de aprendizado não supervisionado, os algoritmos recebem um conjunto de dados não rotulados, sem informações prévias sobre as classes ou valores dos dados. Nesse contexto, o algoritmo busca identificar padrões e estruturas subjacentes nos dados, agrupando-os em *clusters* ou identificando relações entre eles

No aprendizado por reforço, os algoritmos interagem com um ambiente dinâmico, tomando ações e recebendo recompensas ou penalidades em resposta às suas ações. O objetivo do algoritmo é aprender a tomar ações que maximizem a recompensa cumulativa ao longo do tempo (Ludermir, 2021).

4.4.1 Random Forest

O *Random Forest* (RF), apresentado originalmente por Leo Breiman (2001), é um algoritmo de aprendizado de máquina amplamente utilizado que combina a saída de múltiplas árvores de decisão para melhorar a precisão das previsões. Ele é classificado como um algoritmo de aprendizado supervisionado, o que significa que utiliza dados rotulados para treinar o modelo e reconhecer padrões.

O algoritmo cria um "bosque" composto por várias árvores de decisão. Cada árvore é treinada em uma amostra aleatória dos dados, utilizando um método conhecido como *bootstrap sampling*, que envolve a seleção aleatória de subconjuntos de dados com reposição. Ao construir cada árvore, o RF considera somente um subconjunto aleatório das características (ou colunas) disponíveis. Isso ajuda a garantir que as árvores sejam diferentes entre si, reduzindo o risco de sobreajuste, também conhecido como *overfitting* (Cutler, 2012).

Para tarefas de classificação, a previsão final é determinada pela votação da maioria das árvores (*Bootstrap + Aggregating = Bagging*), enquanto para tarefas de regressão, a previsão é

a média das saídas de todas as árvores. Essa abordagem de "sabedoria das multidões" tende a resultar em previsões mais confiáveis e precisas.

O uso de múltiplas árvores ajuda a melhorar a precisão e a estabilidade das previsões, tornando o modelo menos suscetível a erros de uma única árvore. O algoritmo desempenha bem mesmo na presença de dados ausentes, o que é uma vantagem significativa em muitos cenários reais, fornecendo informações sobre quais características são mais relevantes para as previsões e auxiliando na interpretação dos dados (Hartshorn, 2016).

4.5 Google Earth Engine

O Google Earth Engine (GEE) é uma plataforma de análise geoespacial baseada em nuvem que permite a visualização e análise de imagens de satélite em escala planetária. Esta ferramenta é amplamente utilizada por cientistas, pesquisadores e organizações sem fins lucrativos para uma variedade de aplicações, incluindo monitoramento ambiental, gestão de recursos naturais, pesquisa em sensoriamento remoto, previsão de surtos de doenças entre outros (GOOGLE FOR DEVELOPERS, s.d.).

O GEE combina um catálogo de dados geoespaciais que abrange mais de 40 anos de imagens de satélite com capacidades computacionais robustas, permitindo que os usuários realizem análises complexas em grandes volumes de dados sem a necessidade de infraestrutura técnica ampla. A plataforma oferece acesso a uma vasta coleção de dados geoespaciais, incluindo imagens do Landsat, Sentinel e outros conjuntos de dados ambientais (GOOGLE EARTH EDUCATION, s.d.).

A plataforma opera na infraestrutura do Google Cloud, o que significa que todo o processamento ocorre em servidores da empresa, permitindo que os usuários realizem análises rapidamente, mesmo em dispositivos com capacidade limitada, sem a necessidade de download de grandes arquivos e dados.

O GEE é utilizado em várias áreas, como monitoramento de desmatamento, avaliação de impactos ambientais, gestão de água e segurança alimentar. A ferramenta é gratuita para uso não comercial, enquanto o uso comercial está sujeito a taxas de assinatura e custos de computação. A plataforma é projetada para ser acessível a uma ampla gama de usuários, desde acadêmicos até organizações governamentais e empresas (GOOGLE FOR DEVELOPERS, s.d.).

4.6 Definição e importância ecológica dos manguezais e sua biomassa

Os manguezais são ecossistemas costeiros vitais, amplamente reconhecidos por sua dominância em áreas tropicais e subtropicais ao redor do mundo. Essas formações vegetais são

notáveis por sua capacidade de adaptação a condições ambientais características, como as zonas entre-marés, caracterizadas por solos lamacentos e salinidade variável (Tengku, 2021).

Ecologicamente, os manguezais desempenham um papel multifacetado, fornecendo uma gama de serviços ecossistêmicos importantes para o bem-estar humano e a saúde ambiental. Entre esses serviços, destacam-se a captura e o armazenamento de carbono, a proteção contra a erosão costeira, a ciclagem de nutrientes e o suporte à biodiversidade, atuando como berçários para diversas espécies marinhas e terrestres (Hu, 2020).

A AGB é definida como a massa total de matéria orgânica viva presente na parte aérea de um ecossistema, incluindo troncos, galhos e folhas. Essa variável biofísica serve como um indicador importante da saúde, produtividade e função de um ecossistema. A quantificação precisa da AGB é, portanto, essencial para o monitoramento da vitalidade dos manguezais, a compreensão do ciclo do carbono e a implementação de estratégias eficazes de conservação da biodiversidade (Li, 2021).

4.6.1 O papel da AGB na mitigação das mudanças climáticas

Os manguezais são ecossistemas intrinsecamente ricos em carbono, possuindo uma notável capacidade de armazenar mais carbono por unidade de área do que qualquer outro tipo de ecossistema (Donato *et al.*, 2011; McLeod *et al.*, 2011). Essa característica os consolida como aliados importantes na luta contra as mudanças climáticas globais (Tengku, 2021).

Eles são frequentemente classificados como ecossistemas de "carbono azul", um termo que reflete sua capacidade superior de sequestrar e armazenar grandes volumes de carbono, tanto em sua biomassa aérea quanto em seus solos. A capacidade de armazenamento de carbono dos manguezais é reportada como sendo até quatro vezes maior do que a da maioria das outras florestas tropicais, apesar de representarem apenas uma pequena fração (cerca de 2,4%) da área total de florestas tropicais (De Araujo, 2024).

A degradação e a perda de manguezais, impulsionadas por fatores naturais e antrópicos, resultam na liberação de quantidades substanciais de dióxido de carbono equivalente (CO₂e) para a atmosfera. O CO₂e é uma unidade padrão usada para medir o impacto climático de diferentes gases de efeito estufa, como metano (CH₄), óxido nitroso (N₂O) e gases fluorados, convertendo-os em uma quantidade equivalente de CO₂, o que agrava o cenário das mudanças climáticas.

Por outro lado, a conservação e a restauração desses ecossistemas oferecem significativo potencial para a geração de receita, especialmente por meio de mercados de carbono, dada sua função de repositório de carbono azul. Além dos benefícios diretos na mitigação climática,

a proteção dos manguezais proporciona vantagens adicionais, como a preservação de habitats para a vida aquática e a melhoria da qualidade da água por meio da filtragem (Farzanmanesh, 2024).

A dificuldade inerente à coleta de dados de campo em manguezais, devido às suas condições ambientais peculiares, impulsiona a adoção e o desenvolvimento de abordagens de sensoriamento remoto como a ferramenta principal para o monitoramento e a gestão de longo prazo do carbono azul em escalas regionais e globais. Esse cenário transforma o sensoriamento remoto de uma mera opção metodológica em uma necessidade crítica para o avanço da agenda climática global (Kairo, 2021).

Esta abordagem não propõe a substituição de pesquisas em campo, mas contribuir com métodos e técnicas que extraíam informações com qualidade destes importantes ambientes a partir da utilização de sensores remotos e geoprocessamento.

4.6.2 Mensuração tradicional de AGB em manguezais

A medição de biomassa em campo nos manguezais é complexa e desafiadora. Métodos diretos, como a remoção e a pesagem da vegetação, são precisos, porém onerosos, destrutivos e inviáveis para grandes extensões territoriais.

As particularidades dos manguezais como, solo lamoso, raízes aéreas densas e difícil acesso, tornam a pesquisa de campo complexa. Além disso, a classificação inconsistente das raízes aéreas gera variações entre estudos. As medições tradicionais fornecem apenas dados pontuais, limitando a análise contínua da biomassa em grandes extensões (Hu, 2020; Rocha, 2018).

Testar diferentes metodologias, como, por exemplo, as que utilizam dados de sensores remotos podem agregar importantes informações para pesquisas em manguezais.

4.7 Estimativa de biomassa por sensoriamento remoto

De acordo com IPCC (2006), uma das principais formas de se estimar o potencial de captura de carbono de uma determinada área vegetada, como os manguezais, é por meio da mensuração de sua biomassa, ou seja, mensurar a quantidade de matéria orgânica existente em uma determinada área. Esse dado se mostra de grande importância na criação de modelos que pretendem utilizar dados obtidos remotamente, como, por exemplo, imagens de sensores remotos.

Os modelos que se utilizam de dados de sensores remotos para estimar a biomassa de uma vegetação e que apresentam o maior nível de acurácia atualmente, empregam três principais tipos de dados, sendo eles:

- Dados LiDAR, responsáveis por informações topográficas e vegetais obtidas por meio de lasers;
- Dados SAR, obtidos por meio de radares com emissões de micro-ondas; e
- Dados provenientes de satélites ópticos convencionais, que oferecem informações tanto do espectro visível, quanto infravermelho (Baloloy, 2018; Farzanmanesh, 2024).

Estudos que utilizam o modelo apresentado acima, já são aplicados ao território nacional, mas apresentam maior parte das análises localizadas em áreas do bioma amazônico, o que se justifica justamente por sua grande extensão, implicando em maiores dificuldades em obter dados de campo como apresentado por Chagas (2021) em “Uso de dados LIDAR, SAR e Sentinel-2 para estimativa da biomassa florestal acima do solo na Floresta Nacional do Tapajós” e em outros estudos como o de Sato *et al.* (2015) que analisou o sudoeste amazônico.

Modelagens desse tipo também já foram aplicadas a áreas de mangues, como no estudo realizado por Pereira (2016), onde o método foi aplicado em uma área de manguezais na APA (Área de Proteção Ambiental) de Guapimirim, Rio de Janeiro, visando estimar a biomassa da área de estudo definida.

A estimativa de AGB por meio do sensoriamento remoto não se baseia na medição direta da biomassa, mas sim na correlação entre propriedades físicas da floresta, como a altura do dossel, e a biomassa real, utilizando essas propriedades como variáveis preditoras (Tian, 2023).

4.7.1 Relações Alométricas e Variáveis Preditoras

A quantificação da biomassa em formações vegetais pode ser realizada por métodos diretos (destrutivos), ou indiretos (não destrutivos). Os métodos indiretos, que são amplamente empregados em conjunto com dados de sensoriamento remoto, baseiam-se em informações obtidas por meio de inventários florestais. Nessa metodologia, funções alométricas são utilizadas para converter parâmetros florestais mensuráveis, como altura total, diâmetro à altura do peito (DAP) e/ou volume, em estimativas de biomassa (Macedo, 2018).

A estimativa da AGB, por meio de dados de sensoriamento remoto, frequentemente requer dados de referência obtidos em campo, geralmente derivados de medições dendrométricas e de relações alométricas, para a calibração e a validação dos modelos. A representatividade espacial e estrutural das parcelas de campo é fundamental para a redução das incertezas das estimativas. Entre as variáveis preditoras utilizadas, destacam-se os índices de vegetação, a reflectância espectral, os parâmetros biofísicos, como o Índice de Área Foliar (*Leaf Area Index - LAI*), e as informações sobre a estrutura e a cobertura da vegetação. A combinação de diferentes

variáveis espectrais, estruturais e ambientais pode aprimorar o desempenho dos modelos de estimativa de AGB. A resolução espacial deve ser definida conforme a escala das parcelas de campo, a heterogeneidade da vegetação, as características do sensor e os objetivos da estimativa (Lu *et al.*, 2016; Ullah *et al.*, 2025).

O sensoriamento remoto não mede a biomassa diretamente, mas a estima a partir de propriedades florestais usando relações alométricas. A precisão depende principalmente da qualidade dos dados de campo para calibrar e validar esses modelos. Embora o sensoriamento remoto permita escalabilidade, medições de campo (mesmo em pequena escala) são essenciais para garantir acurácia. As relações alométricas conectam campo e sensoriamento, sendo qualquer incerteza nessa etapa uma fonte primária de erro nas estimativas de biomassa (Tian, 2023).

4.7.2 Aplicabilidade dos sensores orbitais

As vantagens de sensores ópticos como o Sentinel-2 incluem sua alta resolução espacial e espectral, além da disponibilidade gratuita dos dados, o que facilita o acesso e a aplicação em diversas pesquisas. No entanto, a principal limitação dos sensores ópticos é a saturação espectral, especialmente em regiões com vegetação densa. A saturação ocorre quando o aumento da densidade da vegetação, seja em termos de Índice de Área Foliar (LAI) ou AGB, não resulta em mudanças proporcionais e significativas na reflectância espectral. O NDVI, por exemplo, é particularmente suscetível a esse problema, saturando em níveis de AGB de aproximadamente $0,3 \text{ g/cm}^2$, o que leva à perda de sensibilidade à informação biofísica em florestas muito densas (Li, 2021).

O Radar de Abertura Sintética (SAR) é uma tecnologia de sensoriamento remoto ativa que opera emitindo sinais de micro-ondas e registrando a energia retroespalhada de volta ao sensor. A interação desses sinais de micro-ondas com os diversos componentes da floresta como: folhas, galhos e troncos, fornece informações valiosas sobre a estrutura do dossel florestal. Uma das principais vantagens do SAR é sua capacidade de penetrar nuvens e operar independentemente das condições de iluminação solar (dia ou noite), tornando-o uma solução ideal para regiões tropicais úmidas, onde a cobertura de nuvens persistente impede frequentemente a aquisição de dados por sensores ópticos (Sinha, 2015).

LiDAR é uma tecnologia de sensoriamento remoto ativa que opera emitindo pulsos de laser em direção à superfície terrestre e medindo o tempo que leva para esses pulsos retornarem ao sensor. Essa medição de tempo de voo permite a criação de uma representação tridimensional (3D) detalhada da superfície da Terra e da estrutura da vegetação.

A principal contribuição do GEDI é sua capacidade de capturar a distribuição vertical da estrutura da vegetação por meio de seus perfis de forma de onda. Esses perfis são então utilizados para derivar estimativas de densidade de biomassa acima do solo (AGBD) em cada ponto de amostragem (*footprint*). O GEDI gera bilhões de amostras de alta resolução que incluem informações sobre elevação da superfície, altura da vegetação e a distribuição da folhagem dentro do dossel (Duncanson, 2022).

4.7.3 Integração de Dados Multisensores e Machine Learning

A estimativa precisa da biomassa em manguezais (AGB) exige uma abordagem multi-sensor devido à complexidade do ecossistema e às limitações individuais dos sensores. Sensores ópticos (ex: Sentinel-2) analisam propriedades da vegetação, mas têm restrições: saturação em áreas de alta biomassa e dependência de céu aberto, tornando-se ineficazes sob nuvens (Tian, 2023).

Por outro lado, os sensores de radar, como o Sentinel-1, possuem a notável capacidade de penetrar nuvens e vegetação, além de serem sensíveis à rugosidade da superfície, textura e teor de umidade, o que os torna valiosos para a análise estrutural do dossel. Contudo, o SAR também enfrenta problemas de saturação em biomassa densa, especialmente na banda C, que tem demonstrado correlações fracas com a AGB em alguns estudos devido à sua limitada capacidade de penetração (Sinha, 2015).

O LiDAR, exemplificado pelo GEDI, oferece informações importantes sobre a estrutura vertical da floresta e, diferentemente dos sensores ópticos e de radar, não satura em níveis elevados de biomassa. No entanto, a principal limitação do GEDI é que ele fornece apenas dados amostrais (pontos), não uma cobertura contínua de lado a lado em grandes áreas.

A combinação de dados provenientes de múltiplos sensores representa uma abordagem inovadora que aprimora significativamente a precisão da estimativa de AGB. Essa melhoria decorre da natureza complementar das características de dados de cada sensor: o SAR é sensível à rugosidade, textura e umidade; o óptico à reflectância e condições fisiológicas; e o LiDAR à estrutura 3D e altura. Estudos têm demonstrado que a integração entre o Sentinel-1 e o Sentinel-2, por exemplo, resulta em maior acurácia na estimativa de AGB do que o uso de sensores individuais (Salazar, 2023).

O RF é um algoritmo de aprendizado de conjunto que constrói múltiplas árvores de decisão. O RF é conhecido por sua robustez e eficiência, apresentando um bom desempenho em estimativas de AGB. Em um estudo feito por Li (2021), focado em florestas tropicais secas, o modelo RF, ao combinar dados Sentinel-1 e Sentinel-2, alcançou um R^2 de 0,78 e um RMSE

de 42,25 Mg/ha para a estimativa de AGB. Em outro estudo de Huang (2025) sobre manguezais, o RF obteve um R^2 de 0,33 e um RMSE de 32,05 Mg/ha utilizando dados Sentinel-1, Sentinel-2 e ALOS-PALSAR.

Nesta pesquisa a ideia de utilizar vários índices obtidos a partir de diferentes sensores surgiu da necessidade não apenas de sua aplicação, mas na comparação dos resultados obtidos, tentando criar caminhos que possam contribuir para o avanço do conhecimento.

4.8 Estudos de caso

A combinação de dados Sentinel-1 e Sentinel-2 tem sido amplamente investigada para a estimativa de AGB em diversos tipos de florestas, incluindo manguezais. Um estudo conduzido por Navarro (2019) no Senegal, demonstrou a eficácia da utilização de imagens Sentinel-1 (radar) e Sentinel-2 (ópticas) como informações auxiliares para estimar a AGB em plantações jovens de mangue. Nesse caso, os dados de UAV (Veículos Aéreos Não Tripulados) foram empregados para validação ao nível de parcela, e os resultados indicaram que a combinação dos dados de ambos os satélites produziu as melhores estimativas.

Estudos têm integrado dados GEDI LiDAR e Sentinel-2 para mapear a altura do dossel e estimar o estoque de carbono em manguezais. Índices de vegetação do Sentinel-2 (como bandas red-edge) são usados em modelos de RF, enquanto o GEDI fornece dados estruturais 3D. Essa combinação supera limitações de modelos tradicionais, melhorando a precisão ao incorporar variações interespecíes e estrutura vertical (Jamaluddin, 2025; Sanam, 2024).

4.8.1 Lacunas na Estimativa de AGB em Manguezais por Sensoriamento Remoto

Um dos desafios mais persistentes na estimativa de AGB em manguezais por sensoriamento remoto é o problema da saturação de sinal, que afeta tanto os dados ópticos quanto os de radar. A saturação ocorre quando, em florestas densas e com alta biomassa, a reflectância espectral (para sensores ópticos) ou o retroespalhamento (para sensores de radar) atinge um ponto em que não há mais uma mudança significativa detectável, mesmo com o aumento contínuo da biomassa. Isso resulta em subestimação da AGB em áreas de alta densidade, comprometendo a precisão das estimativas (Tian, 2023).

A precisão das estimativas de AGB derivadas de sensoriamento remoto está intrinsicamente ligada à acurácia das equações alométricas utilizadas para converter parâmetros florestais (como altura e diâmetro) em biomassa. Uma das principais fontes de incerteza reside na escassez de equações alométricas específicas para as diversas espécies de mangue. A aplicação de equações pantropicais, que não são específicas para as espécies locais, pode introduzir grandes erros e vieses nas estimativas em escala de paisagem (Macedo, 2018).

A dinâmica das marés em manguezais desafia a aquisição precisa de Modelos Digitais de Terreno (MDT) por LiDAR, já que o laser não penetra na água. Coletar dados na maré baixa minimiza o problema, mas limita levantamentos em grandes áreas. Além disso, as marés afetam dados de radar (SAR), alterando propriedades dielétricas da superfície, mesmo que o SAR seja imune a condições climáticas (Rocha, 2018).

Além disso, ressaltamos os riscos que envolvem pesquisas nestes ambientes em algumas partes do mundo. Como, por exemplo, tigres na Índia e crocodilos de águas salgadas. Este tipo de metodologia pode contribuir para a obtenção de dados de qualidade para análises ambientais complexas e que envolvam, inclusive, planejamento e gestão para os manguezais.


5 METODOLOGIA

5.1 Caracterização da área de estudo

Os manguezais do Espírito Santo compõem um rico e biodiverso ecossistema costeiro, abrangendo uma área de aproximadamente 114 km², distribuída por 17 municípios litorâneos. Essa área apresenta grande importância ecológica, socioeconômica e cultural para o estado.

Os manguezais capixabas abrigam uma grande variedade de fauna e flora. Entre as espécies vegetais, destacam-se os mangues propriamente ditos, representados por árvores como o mangue-vermelho (*Rhizophora mangle*), o mangue-preto (*Avicennia schaueriana*) e o siriri-zeiro (*Hibiscus pernambucensis*). Já a fauna é composta por uma rica comunidade de invertebrados, peixes, aves, mamíferos e répteis, incluindo espécies ameaçadas de extinção (IEMA, 2023). As principais áreas de manguezais mapeadas pelo IEMA (Figura 1).

Figura 1 - Exemplos de flora nativa dos manguezais Capixabas



Fonte: ICMBio, 2018.


A Reserva de Desenvolvimento Sustentável Municipal (RDSM) Piraquê-Açu-Mirim, localizada em Aracruz (ES), representa um importante território de conservação que evoluiu de um modelo de proteção integral (Reserva Ecológica, 1986) para um de uso sustentável (RDS, 2013), adequando-se ao SNUC e reconhecendo formalmente a presença de populações tradicionais. Com aproximadamente 2.080 hectares de manguezais (a maior extensão contínua por município no Espírito Santo) a unidade é regida pela Lei Municipal nº 3.739/2013 e gerida pela Secretaria Municipal de Meio Ambiente (SEMAM), contando com um Conselho Deliberativo ativo.

Do ponto de vista biofísico, o sistema estuarino dos rios Piraquê-Açu (braço sul) e Piraquê-Mirim (braço norte) sustenta três espécies principais de mangue (*Rhizophora mangle*, *Avicennia schaueriana*, *Laguncularia racemosa*) e serve como berçário para a fauna marinha, abrigando espécies ameaçadas como o Papagaio-Chauá. No entanto, entre 1985 e 2020, houve redução da cobertura de mangue de 66,8% para 53,4% da área total, agravada por eventos climáticos extremos – como a seca de 2016 seguida de um evento de granizo, provocando mortalidade massiva de cerca de 700 hectares por hipersalinidade. A região passa também por pressões industriais históricas, além dos impactos do rompimento da barragem de Fundão (2015), que trouxe metais pesados à região (Servino *et al.*, 2018).

O caranguejo-uçá (*Ucides cordatus*) é o recurso extrativista de maior relevância socioeconômica, seguindo normativas federais, embora práticas predatórias como a “redinha” ainda ocorram. Em resposta à degradação, o projeto ENEC (FEST/FUNBIO, investimento de R\$ 8,65 milhões) visou restaurar 200 hectares de manguezais com participação comunitária e ciência cidadã, enquanto um novo Plano de Manejo está em elaboração para consolidar o zoneamento e a segurança jurídica da unidade (UFES, 2025).

A área de estudo caracteriza-se, portanto, como um território de intensa disputa socioambiental, onde a conservação da biodiversidade está indissociavelmente ligada à justiça social, à reparação de impactos industriais e climáticos, e à construção de uma co-gestão que valoriza a região (Figura 2).

Figura 2 - Localização do manguezal Piraquê-Açu - ES



Fonte: O Autor, 2026.

Para alcançar os objetivos propostos, a pesquisa seguiu diferentes etapas de desenvolvimento, sendo elas: coleta de dados, definição das variáveis, desenvolvimento e avaliação de modelos de inteligência artificial para mensuração de biomassa, e avaliação das possíveis alterações da capacidade de sequestro de carbono dessas regiões.

Para facilitar a validação do modelo, optou-se por uma análise fenomenológica, tendo como referência os impactos causados por um evento climático extremo em 1º de junho de 2016, conforme documentado por Silva (2022) e Servino (2018).

Devido à escassez de dados para validação do modelo, principalmente para o período definido, optou-se por uma abordagem comparativa, na qual dois modelos, um anterior e outro posterior a um evento que alterou significativamente a densidade vegetal do mangue, foram utilizados, buscando uma validação mais focada em consistência comparativa e empírica do que em acurácia e validação com modelos e métricas existentes.

5.2 Aquisição dos dados

Todo o processo de aquisição e modelagem dos dados foi realizado na plataforma Google Earth Engine (GEE), descrita no item 4.5. Nesse processo, as imagens foram filtradas em um período anterior (11/02/2016) e posterior (09/08/2016) ao evento indicado. Foram selecionadas as cenas com menor cobertura de nuvens, cenário adequado para mensurar a biomassa sem interferências nos sensores.


5.2.1 Filtragem dos dados do Sentinel-2

A coleção selecionada para o estudo foi a Sentinel-2 MSI harmonizada (instrumento multiespectral, nível 1C – TOA), que não apresenta correção atmosférica na reflectância da superfície, mas sim reflectância no topo da atmosfera. Além do filtro temporal mencionado anteriormente (5.2), aplicou-se um filtro de cobertura de nuvens, selecionando apenas cenas com menos de 10% de nebulosidade.

A escolha da coleção L1C deve-se ao período analisado (anterior a 2017), no qual não há imagens nível 2A (reflectância de superfície) disponíveis.

Para contornar a ausência de correção atmosférica, aplicou-se o método SIAC (*Sensor Invariant Atmospheric Correction*). Trata-se de um método bayesiano que corrige efeitos atmosféricos (aerossóis, vapor d'água, ozônio) utilizando dados auxiliares do MODIS (*Moderate Resolution Imaging Spectroradiometer*) e modelos de elevação (MDE). O método produz reflectância BOA (base da atmosfera) com estimativas de incerteza por pixel (Figura 3) (Yin; Lewis; Gomez-Dans, 2022).

Figura 3 - Comparação da aplicação do modelo SIAC.



Fonte: O autor, 2026.

5.2.2 Filtragem dos dados do Sentinel-1

As imagens do Sentinel-1 disponíveis no GEE correspondem ao produto *Ground Range Detected* (GRD), que já passou por processos de remoção de ruído térmico, calibração radiométrica e correção de terreno, com valores expressos em decibéis (dB). Para este estudo, foram utilizadas imagens do mesmo período mencionado anteriormente (5.2), filtradas pelo modo de imageamento *Interferometric Wide Swath* (IW), com as polarizações VV (vertical/vertical) e VH (vertical/horizontal), e considerando exclusivamente a órbita de passagem descendente, única disponível na região de estudo.

No processamento das imagens SAR, aplicou-se a média temporal das imagens do mês selecionado. Essa abordagem demonstrou-se mais eficaz para redução de ruído no sinal de retroespalhamento quando comparada a outras técnicas, além de minimizar a necessidade de filtros adicionais para supressão de ruído, que neste caso específico não se mostraram necessários.

5.2.3 Filtragem dos dados GEDI

A coleção do GEDI utilizada neste estudo foi a *Aboveground Biomass Density* (Version 2.1), que fornece previsões da densidade de biomassa acima do solo (AGBD - *Aboveground*

Biomass Density, em Mg/ha) juntamente com estimativas do erro padrão associado a cada pegada de laser geolocalizada.


Embora esta coleção apresente uma cobertura temporal mais limitada (2019-2025) em comparação com as imagens de satélite utilizadas, ela foi adotada como variável dependente no modelo (predição), enquanto as imagens do período desejado compuseram as variáveis independentes. Para equilibrar essa diferença temporal, optou-se pela utilização da mediana dos dados do GEDI.

5.2.4 Aplicação de índices às imagens

Foram implementadas duas funções distintas para o cálculo de índices aplicáveis às imagens de satélite. Para as imagens ópticas do Sentinel-2, desenvolveram-se os tradicionais índices espectrais de vegetação e umidade, incluindo o NDVI, EVI, SAVI, NDMI e NDWI.

No caso das imagens SAR do Sentinel-1, além do RVI foram calculadas a diferença normalizada entre as polarizações VV e VH, bem como relações simples entre bandas obtidas através da divisão de uma polarização pela outra. O mosaico de visualização dos índices pode ser visto na Figura 4.

Figura 4 - Mosaico dos índices gerados.



Fonte: O autor, 2026.

5.2.5 Criação da imagem para treinamento

O tratamento final das imagens envolveu duas etapas principais: (1) o empilhamento das imagens Sentinel-1 e Sentinel-2 em uma única imagem (*stack*) e (2), o mascaramento de áreas irrelevantes para reduzir ruídos e diminuir o volume de processamento, uma vez que pixels mascarados são automaticamente descartados das amostras e consequentemente do treinamento do algoritmo no GEE.

A máscara aplicada foi desenvolvida para excluir, principalmente, corpos d'água, áreas inundadas e outras superfícies com elevado teor de umidade, além de regiões com baixo retro-espalhamento nas bandas SAR (VV e VH), preservando superfícies terrestres com resposta mais consistente com a vegetação. Essa etapa é necessária, pois tais superfícies podem apresentar inconsistências na mensuração da biomassa, especialmente os corpos d'água, nos quais a limitada penetração do sinal do GEDI pode comprometer as estimativas, resultando em valores superestimados (Quadro 3).

Quadro 3 - Critérios da máscara de redução de ruído (superfícies secas)

Índice / banda	Critério	Valor
VV (banda)	maior que (>)	-20 dB
VH (banda)	maior que (>)	-20 dB
NDWI (índice)	menor que (<)	-0,15

Fonte: O autor, 2026.

A diferença entre a imagem original e os dados de treinamento pode ser observada na Figura 5. Para visualização, um fundo de preenchimento em ciano (corpos d'água) foi adicionado para realçar as áreas mascaradas.

Figura 5 - Diferença entre o dado original e de treinamento




Fonte: O autor, 2026.

5.3 Delimitação da área de mangue

Como forma de definir uma delimitação consistente da área de mangue, utilizou-se a definição de área do IBAMA, configurada a partir de dados obtidos em 2018. Dessa forma,

todo o cálculo e mensuração é feito respeitando uma mesma área pré-definida, fator importante para definir o cálculo de densidade (Figura 6).

Figura 6 - Definição da área de mangue utilizada como delimitação.



Fonte: IBAMA, 2018; O autor, 2026.

5.4 Predição da biomassa acima do solo

Conforme estabelecido no item 5.2.3, os dados do GEDI foram adotados como variável dependente no modelo, expressos em megagramas por hectare (Mg/ha). Essa unidade é equivalente a toneladas por hectare (t/ha), uma vez que ambas representam 1.000 quilogramas por hectare. No modelo de regressão implementado, as bandas espectrais e os índices de vegetação derivados dos satélites Sentinel-1 e Sentinel-2 compuseram o conjunto de variáveis independentes.

5.4.1 Aplicação de reescala aos dados de biomassa

Conforme mencionado no item 5.4, os valores estimados de biomassa são originalmente expressos em megagramas por hectare (Mg/ha), que corresponde à unidade amostral do GEDI. Contudo, a resolução espacial de saída do algoritmo é de 10 por 10 metros (100 m² por pixel), o que demanda uma readequação dos valores para representarem corretamente a biomassa em cada pixel. Essa conversão é essencial para permitir o cálculo preciso da biomassa total na área de estudo, respeitando a resolução dos dados de saída. A transformação necessária foi realizada por meio da seguinte equação:


$$AGB(Mg/100\,m^2) = AGB(Mg/ha) * 0,01$$

6 RESULTADOS

Para a validação da metodologia proposta, selecionou-se a Reserva de Desenvolvimento Sustentável Municipal Piraquê-Açu-Mirim como área de estudo. Essa escolha justifica-se por duas razões principais: primeiro, trata-se de uma região com características ambientais estáveis, por ser uma reserva ambiental; segundo, apresenta um histórico documentado de impactos causados por um evento climático extremo ocorrido em junho de 2016, conforme relatado por Silva (2022).


A aplicação dos procedimentos metodológicos descritos anteriormente resultou em um produto raster no qual cada pixel representa o valor de biomassa contida em sua área correspondente de 100 m² para os dois momentos descritos no item 5.2. Este resultado está representado nas Figuras 7 e 8, que ilustram espacialmente a distribuição da biomassa na área de estudo em um período anterior e posterior, respectivamente.

Figura 7 - Biomassa acima do solo - Piraquê-Açu (antes do evento).



Fonte: O autor, 2026.


Figura 8 - Biomassa acima do solo - Piraquê-Açu (depois do evento).



Fonte: O autor, 2026.

Como forma adicional de melhor visualizar a extensão das variações ocorridas na região do manguezal, uma visualização lado a lado é apresentada na Figura 9.

Figura 9 - Comparação lado a lado.



Fonte: O autor, 2026.

6.1 Estatísticas gerais da área

Como forma de melhor quantificar as métricas da área analisada, foram calculados a média, os valores máximo e mínimo e o montante total da biomassa estimada. Os cálculos consideraram como parâmetro uma área de 100 m². Os valores são indicados na Tabela 1.

Tabela 1 - Métricas da biomassa estimada em 100 m².


Métrica	Pré-evento	Pós-evento
Média	0,319 (t/100 m ²)	0,278 (t/100 m ²)
Valor máximo	1,607 (t/100 m ²)	1,575 (t/100 m ²)
Valor mínimo	0,008 (t/100 m ²)	0,003 (t/100 m ²)
Biomassa total	56.658,585 (t)	49.077,460 (t)

Fonte: O autor, 2026.

Os resultados obtidos expressam coerência com os dados observacionais, demonstrando métricas drasticamente diferentes em um intervalo de cerca de seis meses. No total, foi encontrada uma diferença de 7.581,12 toneladas entre os dois modelos, pré e pós-evento, respectivamente. Observa-se também diminuição nos valores máximos e mínimos encontrados, o que indica queda na densidade vegetal mesmo em áreas que se mantiveram com bons níveis de sanidade, bem como perdas em áreas já debilitadas.

Alguns estudos e publicações sobre o evento ocorrido no Piraquê-Açu indicam perdas entre 500 e 700 hectares (cerca de 29,3% da área total) de área de mangue, conforme apresentado por Servino (2018). Para validar as áreas de perda de biomassa estimadas neste estudo, aplicou-se uma diferença (Δ) às estimativas, na qual valores negativos (<0) expressam perda de biomassa e valores positivos (>0) expressam ganho. A diferença pode ser visualizada na Figura 10, sendo calculada a partir da seguinte fórmula:

$$\Delta AGB = \text{Pós AGB} - \text{Pré AGB}$$

Figura 10 - Diferença de biomassa (ΔAGB).

Fonte: O autor, 2026.

As métricas apresentadas por essa diferença indicam regiões extremas que chegaram a valores de perda superiores a 1 t/100 m², com uma perda média de 0,03 t/100 m².

Considerando toda a área de perda identificada no intervalo temporal analisado, estima-se que aproximadamente 945,78 hectares apresentaram perda de biomassa entre 11/02/2016 e 09/08/2016, enquanto áreas de ganho de biomassa totalizaram cerca de 775,78 hectares. Porém, vale ressaltar que, enquanto a perda se apresenta espacialmente concentrada em pontos específicos, conforme também documentado por Servino (2018) e Silva (2022), os ganhos são mais dispersos e pontuais, como observado na Figura 10.

Os resultados obtidos demonstram que o modelo de estimativa desenvolvido apresenta consistência empírica com o cenário real observado. Um estudo anterior realizado por Da Motta (2017), baseado em amostras de campo coletadas em 2011 (cinco anos antes) na Reserva de Desenvolvimento Sustentável Municipal Piraquê-Açu-Mirim, estimou a biomassa média em aproximadamente 48,61 t/ha. Em comparação, o modelo preditivo aqui apresentado estimou valores médios de 31,9 e 27,8 t/ha para a área, respectivamente.

Embora exista uma diferença média significativa de cerca de 18,76 t/ha entre as estimativas de Da Motta (2017) e as deste estudo, é fundamental considerar três fatores: (1) o intervalo temporal de cinco anos entre as datas analisadas; (2) os impactos da escassez hídrica induzida pelo El Niño (2014-2016), conforme documentado por Servino (2018); e (3) as alterações na cobertura vegetal decorrentes de um evento de chuva de granizo, documentado por Servino (2018) e Silva (2022). Esses efeitos são claramente visíveis nas Figuras 7 a 10, que evidenciam alterações substanciais na cobertura vegetal da reserva, não consideradas pelos dados do IBAMA (2018).

O estudo de campo realizado por Da Motta (2017) apresenta ainda uma limitação metodológica relevante: sua amostragem foi baseada em apenas seis parcelas de 100 m² distribuídas em diferentes áreas do manguezal. Embora cálculos alométricos tenham sido aplicados para extrapolar os resultados para toda a área de estudo, é importante destacar que essa amostragem corresponde a apenas seis pixels (600 m²) na resolução espacial dos sensores utilizados no modelo de predição (10 x 10 metros). Essa reduzida representatividade amostral pode comprometer a capacidade de captar adequadamente a heterogeneidade espacial característica dos ecossistemas de mangue e os danos heterogeneamente dispersos, superestimando ou subestimando os montantes de biomassa acima do solo.

6.2 Métricas do modelo de regressão

Como apresentado no tópico 4.4.1, o modelo utilizado foi o de regressão com florestas aleatórias. Para identificar como os dados estimados se comportaram em relação às observações (amostras) do GEDI, foram utilizadas as métricas de Erro Médio Absoluto (MAE), Raiz do Erro Quadrático Médio (RMSE) e Coeficiente de Determinação (R^2). Essas métricas empregaram um padrão de 70% das amostras para treinamento e 30% para validação. No total, foram amostrados 1.806 pontos de AGBD do GEDI.

O MAE e o RMSE estimam, respectivamente, a média das diferenças absolutas e a raiz quadrada da média dos erros ao quadrado entre valores reais e preditos, ambos expressos na unidade dos dados originais, que, no caso do GEDI, é AGB em Mg/ha (quanto menor, melhor). Enquanto o RMSE penaliza mais intensamente erros grandes, o R^2 estima a proporção da variância explicada pelo modelo, sendo uma medida adimensional que representa o percentual de quão bem o modelo explica os dados de referência (quanto maior, melhor).

As métricas resultantes dos modelos gerados encontram-se na Tabela 2.


Tabela 2 - Métricas do modelo de regressão.

Métrica	Pré-evento	Pós-evento
MAE	13,155 (Mg/ha)	15,008 (t/100m ²)
RMSE	19,171 (Mg/ha)	21,550 (t/100m ²)
R^2	49,980 (%)	45,988 (%)

Fonte: O autor, 2026.


Como pode ser observado, as margens de erro encontradas não foram baixas, assim como o R^2 indicou que apenas cerca de 50% dos modelos podem ser explicados a partir dos dados de biomassa do GEDI. Buscando compreender essas métricas, os gráficos de regressão dos respectivos modelos foram gerados objetivando entender a distribuição dos dados originais e preditos (Figura 11 e Figura 12).

Figura 11 - Gráfico de regressão pré-evento.



Fonte: O autor, 2026.

Figura 12 - Gráfico de regressão pós-evento.



Fonte: O autor, 2026.

6.2.1 Diagnóstico do modelo

A divergência entre a linha vermelha e a linha 1:1 (azul) ($y = a * x + b$) esboça uma relação linear simples visando uma comparação visual dos modelos gráficos (*Random Forest* não é linear). Essa divergência revela duas características observadas em modelos RF sob condições de “caudas esparsas”:

(1) a subestimação em valores altos de AGB, com uma linha de tendência abaixo da referência, significando que, para parcelas com AGB observada alta (acima de aproximadamente 60 Mg/ha), o modelo subestimou sistematicamente. Visualmente, os pontos ficam cada vez mais abaixo da linha azul conforme os valores do eixo X crescem;

(2) A superestimação em valores baixos de AGB. No intervalo de 0 a 20 Mg/ha, a linha de tendência está acima da linha 1:1 (azul), indicando que o modelo tende a superestimar parcelas com baixa biomassa.

O comportamento acima poderia ser explicado pelo efeito de compressão (reversão à média) possível no RF, que ocorre porque as previsões finais são a média das árvores

individuais, puxando valores extremos para a média global dos dados de treinamento, achatando os extremos e apresentando valores reduzidos ou aumentados em *outliers*. No entanto, a mesma dinâmica também poderia ocorrer devido à baixa representatividade dos valores extremos nos dados amostrais do GEDI, o que de fato pode ser observado pela distribuição dos pontos verdes no gradiente do gráfico.

A nuvem de pontos amostrais se apresenta bastante dispersa ao longo de todo o gradiente de AGB, especialmente acima de 60 Mg/ha, onde a variância aumenta consideravelmente. Isso pode indicar: (1) Heterogeneidade estrutural da floresta não capturada pelas bandas espectrais usadas; (2) Tamanho amostral insuficiente nas classes de alta biomassa; (3) saturação do sinal de radar/óptico/LiDAR em dosséis densos, limitando o poder preditivo nessa faixa.

Apesar de todas as três características citadas acima serem possíveis, o tamanho amostral insuficiente nas classes de alta biomassa é o mais evidente.

6.2.2 Limitações do GEDI em áreas de alta concentração de biomassa

De acordo com Dubayah *et al.* (2021), no manual de usuário do GEDI, as principais limitações do sensor estão relacionadas à alta biomassa devido ao projeto físico de seus lasers. Os feixes de cobertura não penetram nas copas com cobertura superior a 95% em condições médias. Em florestas densas, estes feixes podem não atingir o solo.

Os algoritmos padrão podem ser subótimos em vegetação densa. As otimizações globais nem sempre funcionam para locais específicos, como florestas tropicais. Pesquisadores devem verificar parâmetros alternativos disponíveis nos produtos de dados, em vez de confiar apenas nos resultados padrão (Dubayah *et al.*, 2021).

Uma das variáveis utilizadas para avaliar a qualidade das observações do GEDI é a sensibilidade do sinal. Essa métrica representa a máxima cobertura de dossel que pode ser penetrada pelo sinal, considerando a relação sinal-ruído da forma de onda. Para a seleção de observações terrestres, recomenda-se comumente a utilização de um limiar de sensibilidade $\geq 0,9$, em conjunto com outros critérios de qualidade, como marcador de qualidade e marcador de degradação. Em áreas de vegetação densa, a escolha do limiar de sensibilidade pode exigir uma avaliação específica, uma vez que valores mais rigorosos podem reduzir o número de observações disponíveis, embora possam contribuir para a seleção de retornos com maior qualidade em determinadas condições. Assim, recomenda-se avaliar empiricamente diferentes limiares de sensibilidade conforme as características da área de estudo e os objetivos da análise (Dubayah *et al.*, 2021; Moudrý *et al.*, 2024).

Estudar ecossistemas de alta biomassa com GEDI exige estratégias cuidadosas: priorizar feixes de alta potência, aplicar limites de sensibilidade mais restritivos e avaliar algoritmos alternativos. Embora o GEDI seja valioso globalmente, seu desempenho nas florestas mais densas é limitado pela física do instrumento e pelo projeto do algoritmo, o que exige controle de qualidade adicional pelo usuário (Dubayah *et al.*, 2021).

6.2.3 Escolhas metodológicas

A partir das informações apresentadas por Dubayah *et al.* (2021) no tópico acima, entende-se que, apesar de passar por técnicas de pós-processamento, os dados do GEDI ainda podem apresentar medições enganosas em regiões de alta densidade vegetal. Diante disso, escolhas metodológicas precisaram ser feitas para a modelagem dos dados.

Para garantir que os dados amostrais do GEDI fossem confiáveis, todas as máscaras de confiança disponibilizadas com o produto foram utilizadas. Isso fez com que dados extremos, como estimativas de 1.200 Mg/ha, fossem removidos, os quais, segundo vários estudos, como o de (Wang; Xiang; Liang, 2025), podem ser considerados *outliers*, sendo dados acima de 300 Mg/ha cada vez menos confiáveis.

Valores como 350 Mg/ha foram encontrados e mantidos nos dados do GEDI para o modelo do Piraquê-Açu. Essa escolha deveu-se à possibilidade real dessa medida em florestas tropicais, sendo também uma forma de manter minimamente a representatividade de áreas com alta biomassa. Assim, métricas de regressão melhores poderiam ser apresentadas com a filtragem de *outliers* manual ou por percentis. No entanto, empiricamente isso poderia resultar em sub-representatividade de densidades mais elevadas.

Portanto, para este trabalho, optou-se pela manutenção de valores extremos para poderem ser regularizados pelo algoritmo de florestas aleatórias por sua robustez a *outliers*.

7 CONSIDERAÇÕES FINAIS

O presente estudo atingiu seu objetivo principal ao desenvolver e validar um modelo de predição de biomassa acima do solo (AGB) para o ecossistema de manguezais da Reserva de Desenvolvimento Sustentável Municipal Piraquê-Açu-Mirim, utilizando exclusivamente dados gratuitos de sensores remotos e técnicas de aprendizado de máquina. A integração de dados ópticos (Sentinel-2), de radar (Sentinel-1) e perfis de LiDAR orbital (GEDI) demonstrou ser uma alternativa viável e de baixo custo para o monitoramento biofísico de áreas de difícil acesso.

Os resultados evidenciaram a sensibilidade do modelo ao detectar variações temporais significativas na biomassa. A análise comparativa entre os períodos pré e pós-evento climático de 2016 quantificou uma perda expressiva de aproximadamente 7.581 toneladas de biomassa total na área de estudo. Essa redução, que levou a média de AGB de 31,9 t/ha para 27,8 t/ha em apenas seis meses, reforça a vulnerabilidade desses ecossistemas a eventos extremos e a importância de ferramentas de monitoramento contínuo para a gestão ambiental e estratégias de mitigação de mudanças climáticas.

Do ponto de vista técnico, o algoritmo *Random Forest* mostrou-se robusto para espacializar a biomassa, embora tenha apresentado limitações típicas de modelos de regressão baseados em árvores de decisão, como o efeito de "compressão à média". Observou-se uma tendência de subestimativa em áreas de alta densidade de biomassa (acima de 60 Mg/ha) e superestimativa em áreas de baixa densidade. Tais divergências podem ser atribuídas à saturação do sinal em dosséis densos e à natureza amostral (não contínua) dos dados GEDI utilizados como variável dependente.

Apesar das incertezas inerentes à modelagem, o Coeficiente de Determinação (R^2) próximo a 50% e o erro médio absoluto (MAE) entre 13 e 15 Mg/ha indicam que o modelo possui consistência estatística suficiente para aplicações em escala de paisagem, superando as limitações de custo e logística dos inventários de campo tradicionais e das medições com sensores LiDAR aerotransportados.

Como recomendações para trabalhos futuros, sugere-se a incorporação de séries temporais mais longas para capturar a recuperação da vegetação após eventos de degradação, além do teste de outros algoritmos de inteligência artificial, como redes neurais convolucionais (CNNs), que podem extrair padrões contextuais mais complexos.

Adicionalmente, o modelo poderia ser aprimorado com a utilização da coleção Satellite Embedding V1 da Google. A utilização dessas representações vetoriais anuais de alta dimensão, geradas por modelos de *Deep Learning* pré-treinados em escala global, pode permitir que

o algoritmo capture características espaciais e texturais complexas que os índices espectrais tradicionais, de natureza linear, muitas vezes não conseguem isolar. Ao integrar esses *embeddings* como variáveis preditoras, espera-se não apenas elevar o coeficiente de determinação (R^2) do modelo, mas também reduzir a dependência de processos manuais de seleção de variáveis, conferindo maior robustez à estimativa de biomassa em dosséis densos e minimizando os ruídos causados pela saturação espectral observada nas áreas de maior densidade vegetal.

Espera-se que este modelo possa servir de subsídio para gestores públicos na conservação do "carbono azul" e na implementação de projetos de restauração ecológica na costa brasileira.

REFERÊNCIAS

- AB'SÁBER, Aziz Nacib. **Os domínios de natureza no Brasil: potencialidades paisagísticas**. Ateliê editorial, 2003.
- BALOLOY, Alvin Balidoy *et al.* Estimation of mangrove forest aboveground biomass using multispectral bands, vegetation indices and biophysical variables derived from optical satellite imageries: Rapideye, planetscope and sentinel-2. **ISPRS annals of the photogrammetry, remote sensing and spatial information sciences**, v. 4, p. 29-36, 2018.
- BARNES, E. M. *et al.* Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data. In: **Proceedings of the fifth international conference on precision agriculture, Bloomington, MN, USA**. 2000.
- BERTRAND, Georges. Paisagem e geografia física global. Esboço metodológico. **Raega-O Espaço Geográfico em Análise**, v. 8, 2004.
- BREIMAN, Leo. Random forests. **Machine learning**, v. 45, n. 1, p. 5-32, 2001.
- BREITHAUP, Joshua L. *et al.* Organic carbon burial rates in mangrove sediments: Strengthening the global budget. **Global Biogeochemical Cycles**, v. 26, n. 3, 2012.
- CARVALHO, Natália. **Ecossistemas de carbono azul e as sinergias entre medidas de mitigação e adaptação às mudanças climáticas e eventos extremos: o caso dos manguezais da baía de Sepetiba - RJ**. 2020. 339f. Tese (Doutorado em Planejamento Energético) - Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2020.
- CHAGAS, Gabriel Oliveira. **Uso de Dados Lidar, Sar e Sentinel-2 para Estimativa da Biomassa Florestal Acima do Solo na Floresta Nacional do Tapajós**. CEP, v. 12, p. 010, 2021.
- CUTLER, Adele; CUTLER, D. Richard; STEVENS, John R. Random forests. **Ensemble machine learning: Methods and applications**, p. 157-175, 2012.
- DA MOTTA PORTILLO, José Thales; LONDE, Vinícius; MOREIRA, Francisco Wagner Araújo. Aboveground biomass and carbon stock are related with soil humidity in a mangrove at the Piraquê-Açu River, Southeastern Brazil. **Journal of Coastal Conservation**, v. 21, p. 139-144, 2017.
- DE ARAUJO, Ralph Wendel Oliveira; DE LIMA CARDOSO, Ariston; DA SILVA, Luiz Artur dos Santos. ESTIMATIVA MULTITEMPORAL DE BIOMASSA EM MANGUEZAIS UTILIZANDO ÍNDICES MULTIESPECTRAIS. **Boletim de Conjuntura (BOCA)**, v. 20, n. 60, p. 441-459, 2024.
- DEYOE, H.; Lonard, R.I.; Judd, F.W.; Stalter, R., and Feller, I. Biological flora of the tropical and subtropical intertidal zone: Literature review for *Rhizophora mangle* L. **Journal of Coastal Research**, Florida, ISSN 0749-0208, 2020.
- DHARMAWAN, I. Wayan Eka. Mangrove health index distribution on the restored post-tsunami mangrove area in Biak Island, Indonesia. In: **IOP Conference Series: Earth and Environmental Science**. IOP Publishing, 2021. p. 012007.
- DONATO, Daniel C. *et al.* Mangroves among the most carbon-rich forests in the tropics. **Nature geoscience**, v. 4, n. 5, p. 293-297, 2011.
- DUBAYAH, R. *et al.* **GEDI L2B Canopy Cover and Vertical Profile Metrics Data Global Footprint Level V002**. Sioux Falls: NASA EOSDIS Land Processes DAAC, 2021. DOI:

10.5067/GEDI/GEDI02_B.002. Disponível em:

https://doi.org/10.5067/GEDI/GEDI02_B.002. Acesso em: 20 mar. 2026.

DUKE, Norman C. *et al.* A world without mangroves?. **Science**, v. 317, n. 5834, p. 41-42, 2007.

DUNCANSON, Laura *et al.* Aboveground biomass density models for NASA's Global Ecosystem Dynamics Investigation (GEDI) lidar mission. **Remote Sensing of Environment**, v. 270, p. 112845, 2022.

EGGLESTON, H. S. *et al.* **2006 IPCC guidelines for national greenhouse gas inventories**. 2006.

EOS DATA ANALYTICS. **Make an Analysis: Crop Monitoring with Satellite Imagery**. [S. l.], [2025]. Disponível em: <https://eos.com/make-an-analysis/>. Acesso em: 5 maio. 2025.

ESA. **Sentinel Online**: SENTINEL-1 MISSION. [S. l.], 2025. Disponível em: <https://sentiwiki.copernicus.eu/web/s1-mission>. Acesso em: 16 jan. 2025.

ESA. **Sentinel Online**: SENTINEL-2 MISSION. [S. l.], 2025. Disponível em: <https://sentiwiki.copernicus.eu/web/s2-mission>. Acesso em: 15 jan. 2025.

FARZANMANESH, Raheleh *et al.* Quantifying Mangrove aboveground biomass changes: Analysis of conservation impact in blue forests projects using sentinel-2 satellite imagery. **Forest Ecology and Management**, v. 561, p. 121920, 2024.

GALIDAKI, Georgia *et al.* Vegetation biomass estimation with remote sensing: focus on forest and other wooded land over the Mediterranean ecosystem. **International Journal of Remote Sensing**, v. 38, n. 7, p. 1940-1966, 2017. DOI: 10.1080/01431161.2016.1266113.

GAO, Bo-Cai. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote sensing of environment**, v. 58, n. 3, p. 257-266, 1996.

GEDI. Instrument Overview. Disponível em: <https://gedi.umd.edu/instrument/instrument-overview/>. Acesso em: 1 maio 2025.

GEDI. Mission Overview. Disponível em: <https://gedi.umd.edu/mission/mission-overview/>. Acesso em: 1 maio 2025.

GHOSH, Sujit Madhab; BEHERA, Mukunda Dev; PARAMANIK, Somnath. Canopy height estimation using sentinel series images through machine learning models in a mangrove forest. **Remote Sensing**, v. 12, n. 9, p. 1519, 2020.

GOMES, Leilson Ferreira *et al.* Estimativas das alterações na biomassa florestal utilizando LiDAR em área de manejo florestal sustentável na Amazônia Sul-Occidental. **Anuário do Instituto de Geociências**, v. 43, n. 3, p. 260-268, 2020.

GOOGLE EARTH EDUCATION. **Google Earth Engine**. Disponível em: <https://www.google.com/earth/education/tools/google-earth-engine/>. Acesso em: 7 jun. 2025.

GOOGLE FOR DEVELOPERS. **Google Earth Engine**. Disponível em: <https://developers.google.com/earth-engine?hl=pt-br>. Acesso em: 7 jun. 2025.

HAI, Nguyen Trung *et al.* Towards a more robust approach for the restoration of mangroves in Vietnam. **Annals of Forest Science**, 77, p.1-18, 2020.

HARTSHORN, Scott. **Machine Learning with Random Forests and Decision Trees: A Mostly Intuitive Guide, But Also Some Python**. 2016.

HOSCH, William. **Machine Learning**: artificial intelligence. [S. l.]: Britannica, 29 out. 2023. Disponível em: <https://www.britannica.com/technology/machine-learning>. Acesso em: 30 out. 2023.

HU, Tianyu *et al.* Mapping the global mangrove forest aboveground biomass using multisource remote sensing data. **Remote sensing**, v. 12, n. 10, p. 1690, 2020.

HUANG, Shan *et al.* Enhancing Mangrove Aboveground Biomass Estimation with UAV-LiDAR: A Novel Mutual Information-Based Feature Selection Approach. **Sustainability**, v. 17, n. 7, p. 3004, 2025.

HUETE, Alfredo R. A soil-adjusted vegetation index (SAVI). **Remote sensing of environment**, v. 25, n. 3, p. 295-309, 1988.

HUETE, Alfredo; JUSTICE, Christopher; LIU, Huiqing. Development of vegetation and soil indices for MODIS-EOS. **Remote Sensing of environment**, v. 49, n. 3, p. 224-234, 1994.

ICMBIO; MMA. **Atlas dos Manguezais do Brasil**. Brasília: [s. n.], 2018. Atlas. Disponível em: <https://www.gov.br/icmbio/pt-br/centrais-de-conteudo/atlas-dos-manguezais-do-brasil-pdf>. Acesso em: 24 ago. 2023.

IEMA. **Mapeamento e análise espaço-temporal dos manguezais do espírito santo**: comparativo entre 1970, 2007 e 2015. Cariacica, ES: [s. n.], 2023. Disponível em: https://iema.es.gov.br/Media/iema/CGEO/MAPEAMENTOS_CGEO_VOL1_MANGUEZAL_28.12.2023.pdf. Acesso em: 3 jun. 2024.

IPCC, Intergovernmental Panel on Climate Change. 2014. **Quinto Relatório de Avaliação do Painel Intergovernamental sobre Mudança do Clima**. Setembro de 2014.

IPCC. Mudança do Clima 2023: **Relatório Síntese**. Genebra, Suíça, 2023. 34 p. Disponível em: https://www.gov.br/mcti/pt-br/acompanhe-o-mcti/sirene/publicacoes/relatorios-do-ipcc/arquivos/pdf/copy_of_IPCC_Longer_Report_2023_Portugues.pdf. Acesso em: 20 mai. 2024.

JAMALUDDIN, Ilham *et al.* Exploring red-edge spectral indices for mangrove canopy height mapping using random forest regression with Sentinel-2 and spaceborne GEDI LiDAR data. In: **Land Surface and Cryosphere Remote Sensing V**. SPIE, 2025. p. 1326306.

KAIRO, James *et al.* Total ecosystem carbon stocks of mangroves in Lamu, Kenya; and their potential contributions to the climate change agenda in the country. **Frontiers in Forests and Global Change**, v. 4, p. 709227, 2021.

KIM, Yunjin; VAN ZYL, Jakob. Comparison of forest parameter estimation techniques using SAR data. In: IGARSS 2001. Scanning the Present and Resolving the Future. Proceedings. **IEEE 2001 International Geoscience and Remote Sensing Symposium** (Cat. No. 01CH37217). IEEE, 2001. p. 1395-1397.

LI, Chunhua; ZHOU, Lizhi; XU, Wenbin. Estimating aboveground biomass using Sentinel-2 MSI data and ensemble algorithms for grassland in the Shengjin Lake Wetland, China. **Remote Sensing**, v. 13, n. 8, p. 1595, 2021.

LILLESAND, Thomas; KIEFER, Ralph W.; CHIPMAN, Jonathan. **Remote sensing and image interpretation**. John Wiley & Sons, 2015.

LOPES, Raquel; OLIVEIRA, Barbara. **Área de mangue no ES encolheu o equivalente a 120 campos de futebol**. [S. l.]: A Gazeta, 5 jun. 2020. Disponível em: <https://www.agazeta.com.br/es/cotidiano/area-mangue-es-encolheu-120-campos-futebol-0620>. Acesso em: 10 ago. 2023.

LU, Dengsheng *et al.* A survey of remote sensing-based aboveground biomass estimation methods in forest ecosystems. **International Journal of Digital Earth**, v. 9, n. 1, p. 63-105, 2016.

LUDERMIR, Teresa Bernarda. Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. **Estudos Avançados**, v. 35, p. 85-94, 2021.

MACDICKEN, Kenneth G. *et al.* **A guide to monitoring carbon storage in forestry and agroforestry projects**. 1997.

MACEDO, Fabrício Lopes de *et al.* Função alométrica de biomassa com imagens de satélite de alta resolução espacial. **Ciência Florestal**, v. 28, n. 03, p. 960-969, 2018.

MAXIMIANO, Liz Abad. Considerações sobre o conceito de paisagem. **Raega-O Espaço Geográfico em Análise**, v. 8, 2004.

MCFEETERS, Stuart K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. **International journal of remote sensing**, v. 17, n. 7, p. 1425-1432, 1996.

MCLEOD, Elizabeth *et al.* A blueprint for blue carbon: toward an improved understanding of the role of vegetated coastal habitats in sequestering CO₂. **Frontiers in Ecology and the Environment**, v. 9, n. 10, p. 552-560, 2011.

MENESES, P. R., & ALMEIDA, T. D. **Introdução ao processamento de imagens de sensoriamento remoto**. Universidade de Brasília, Brasília, 2012.

MONARD, Maria Carolina; BARANAUSKAS, José Augusto. Conceitos sobre aprendizado de máquina. **Sistemas inteligentes-Fundamentos e aplicações**, v. 1, n. 1, p. 32, 2003.

MOUDRÝ, Vítězslav *et al.* How to find accurate terrain and canopy height GEDI footprints in temperate forests and grasslands?. **Earth and Space Science**, v. 11, n. 10, p. e2024EA003709, 2024.

NAVARRO, José Antonio *et al.* Integration of UAV, Sentinel-1, and Sentinel-2 data for mangrove plantation aboveground biomass monitoring in Senegal. **Remote Sensing**, v. 11, n. 1, p. 77, 2019.

ONU. **UNESCO afirma que manguezais são aliados do ser humano na luta contra as mudanças climáticas**. [S. l.], 26 jul. 2019. Disponível em: <https://brasil.un.org/pt-br/83822-unesco-afirma-que-manguezais-s%C3%A3o-aliados-do-ser-humano-na-luta-contra-mudan%C3%A7as-clim%C3%A1ticas>. Acesso em: 22 jun. 2023.

Osmanoglu, Ö.; AlSeiari, M. K.; AlKhoori, H. A.; Shams, S.; Bencurova, E.; Dandekar, T.; Naseem, M. Topological Analysis of the Carbon-Concentrating CETCH Cycle and a Photorespiratory Bypass Reveals Boosted CO₂-Sequestration by Plants. **Frontiers in Bioengineering and Biotechnology**, 2021.

PEREIRA, F.R.S. **Sensoriamento Remoto LiDAR e Óptico Aplicados à Estimativa de Biomassa Aérea de Manguezais: Estudo de Caso na Apa de Guapimirim, RJ**. 2016. 189

f. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2016.

RAUBER, Thomas Walter. Redes neurais artificiais. **Universidade Federal do Espírito Santo**, v. 29, 2005.

ROCHA DE SOUZA PEREIRA, Francisca *et al.* Reducing uncertainty in mapping of mangrove aboveground biomass using airborne discrete return lidar data. **Remote Sensing**, v. 10, n. 4, p. 637, 2018.

RODRIGUEZ, José Manuel Mateo (Org.). **Geoeecologia das Paisagens**: uma visão geossistêmica da análise ambiental. 5. ed. José Mateo Rodriguez; *et al.* - Fortaleza: Edições UFC, 2017. 222 p.

ROUSE, J. W; Haas, R. H; Schell, J. A; & Deering, D. W. Monitoring vegetation systems in the Great Plains with ETRS. In: **Third ETRS Symposium**, NASA SP353, Washington, DC. 1: 309-317. 1973.

SALAZAR VILLEGAS, Mike H. *et al.* Examining the potential of sentinel imagery and ensemble algorithms for estimating aboveground biomass in a tropical dry forest. **Remote Sensing**, v. 15, n. 21, p. 5086, 2023.

SANAM, Humaira *et al.* Multi-sensor approach for the estimation of above-ground biomass of mangroves. **Journal of the Indian Society of Remote Sensing**, v. 52, n. 4, p. 903-916, 2024.

SANTOS, Milton. **A natureza do espaço: técnica e tempo, razão e emoção**. Edusp, 2002.

SAS® INSIGHTS (Cary). **Machine Learning**: O que é e qual sua importância?. Cary, 2022. Disponível em: https://www.sas.com/pt_br/insights/analytics/machine-learning.html. Acesso em: 6 set. 2023.

SATO, Luciane Yumie *et al.* Análise da relação entre dados de LiDAR e de biomassa florestal no sudoeste da Amazônia. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2015, **Anais**. Embrapa Monitoramento por Satélite, p. 2015.

SCHAEFFER-NOVELLI, Y. A diversidade do ecossistema manguezal. In: **Atlas dos Manguezais do Brasil** (1ª ed.). Instituto Chico Mendes de Conservação da Biodiversidade. ICMBio, Brasília, D.F, p. 23-36, 2018b.

SERVINO, Ricardo Nogueira; Gomes, Luiz Eduardo de Oliveira; Bernardino, Angelo Fraga. Extreme weather impacts on tropical mangrove forests in the Eastern Brazil Marine Ecoregion. **Science of the Total Environment**. New York, USA; n. 628, p.233-240, 2018. doi:10.1016/j. scitotenv. 2018.02.068.

SILVA, Charlei Aparecido da Silva (Org.). **Geografia e Natureza**: experiências e abordagens de pesquisas. Dourados: Ed. UFGD, 2012. 256 p.

SILVA, Marco Antonio Saraiva da; FARIA, André Luiz Lopes de. Impact evaluation of the extreme weather event in mangroves of the Brazilian Southeast Coast with remote sensing. **Sociedade & Natureza**, v. 34, 2022.

SILVA, Marco Antonio Saraiva da. Análise de impacto climático extremo, a partir de imagens de sensores remotos, nos manguezais da Reserva Municipal de Desenvolvimento Sustentável do Piraquê Açu-Mirim em Aracruz (ES). 2022. Dissertação (Mestrado em Geografia) – Universidade Federal de Viçosa, Viçosa, 2022.

SINHA, Suman *et al.* A review of radar remote sensing for biomass estimation. **International Journal of Environmental Science and Technology**, v. 12, n. 5, p. 1779-1792, 2015.

SOAVINSKI, Ricardo; MARETTI, Cláudio. **Atlas dos Manguezais do Brasil / Instituto Chico Mendes de Conservação da Biodiversidade**. – Brasília: Instituto Chico Mendes de Conservação da Biodiversidade, 2018. 176 p.: il.

TAUB, D. Effects of Rising Atmospheric Concentrations of Carbon Dioxide on Plants. **Nature**, 2010.

TENGKU HASHIM, Tengku Mohd Zarawie; SURATMAN, Mohd Nazip. **Mangroves as a carbon sink/stocks. Mangroves: Ecology, Biodiversity and Management**, p. 157-175, 2021.

TIAN, Lei *et al.* Review of remote sensing-based methods for forest aboveground biomass estimation: Progress, challenges, and prospects. **Forests**, v. 14, n. 6, p. 1086, 2023.

UFES. **Projeto de recuperação de manguezal conquista 1º lugar no Prêmio Consciência Ambiental 2025**. Disponível em: <https://www.ufes.br/conteudo/projeto-de-recuperacao-de-manguezal-conquista-1o-lugar-no-premio-consciencia-ambiental>. Acesso em: 25 dez. 2025.

ULLAH, Sana *et al.* Remote sensing for aboveground biomass monitoring in terrestrial ecosystems: A systematic review. **Remote Sensing Applications: Society and Environment**, v. 39, p. 101635, 2025.

WANG, Jiarun; XIANG, Chengzhi; LIANG, Ailin. Estimation of Forest Aboveground Biomass in China Based on GEDI and Sentinel-2 Data: Quantitative Analysis of Optical Remote Sensing Saturation Effect and Terrain Compensation Mechanisms. **Remote Sensing**, v. 17, n. 20, p. 3437, 2025.

Wilson, E. H.; Sader, S. A. Detection of forest harvest type using multiple dates of Landsat TM imagery. **Remote Sensing of Environment**, v. 80, n. 3, p. 385–396, 2002. DOI: 10.1016/S0034-4257(01)00318-2.

YIN, Feng; LEWIS, Philip E.; GOMEZ-DANS, Jose L. Bayesian atmospheric correction over land: Sentinel-2/MSI and Landsat 8/OLI. **Geoscientific Model Development**, v. 15, p. 7933-7976, 2022. DOI: <https://doi.org/10.5194/gmd-15-7933-2022>. Disponível em: arquivo digital. Acesso em: 9 abr. 2026.