

UNIVERSIDADE ESTADUAL DE FEIRA DE SANTANA
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM EM CIÊNCIAS DA
TERRA E DO AMBIENTE - PPGM

MATEUS TINÔCO SILVA

**MODELAGEM VOLUMÉTRICA DE PLANTIOS DE EUCALIPTO POR MEIO DE
DADOS DO LiDAR GEDI, SENTINEL E AMBIENTAIS**

UNIVERSIDADE ESTADUAL DE FEIRA DE SANTANA
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM EM CIÊNCIAS DA
TERRA E DO AMBIENTE - PPGM

MATEUS TINÔCO SILVA

**MODELAGEM VOLUMÉTRICA DE PLANTIOS DE EUCALIPTO POR MEIO DE
DADOS DO LiDAR GEDI, SENTINEL E AMBIENTAIS**

Dissertação apresentada ao Programa de Pós-Graduação Stricto Sensu em Modelagem em Ciências da Terra e do Ambiente, da Universidade Estadual de Feira de Santana, como requisito para obtenção do grau de Mestre em Ciências Ambientais.

Orientador: Edson Eyji Sano

Coorientadora: Joselisa Maria Chaves

Ficha Catalográfica - Biblioteca Central Julieta Carteado - UEFS

S581 Silva, Mateus Tinôco

Modelagem volumétrica de plantios de eucalipto por meio de dados do Lidar Gedi, Sentinel e Ambientais / Mateus Tinôco Silva. – 2023.

57 f.: il.

Orientador: Edson Eyji Sano.

Coorientadora: Joselisa Maria Chaves.

Dissertação (mestrado) – Universidade Estadual de Feira de Santana, Programa de Pós-graduação em Modelagem em Ciências da Terra e do Ambiente, Feira de Santana, 2023.

1. Eucalipto - plantio. 2. Inventário florestal. 3. Madeira I. Título.
II. Sano, Edson Eyji, orient. III. Chaves, Joselisa Maria, coorient.
IV. Universidade Estadual de Feira de Santana.

CDU 582.883.4(814.2)

Mateus Tinôco Silva

**"MODELAGEM VOLUMÉTRICA DE PLANTIOS DE EUCALIPTO
POR MEIO DE DADOS DO LIDAR GEDI, SENTINEL E
AMBIENTAIS"**

Dissertação apresentada ao Programa de
Pós-Graduação em Modelagem em Ciências da
Terra e do Ambiente da Universidade Estadual
de Feira de Santana.

Orientador: Prof. Dr. Edson Eyji Sano.

Linha de Pesquisa: Estudos Ambientais e
Geotecnologias.

Data de aprovação: 27 de março de 2023.

BANCA EXAMINADORA:



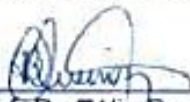
Prof. Dr. Edson Eyji Sano - Orientador
EMBRAPA Universidade Estadual de Feira de Santana - UEFS



Prof. Dr. Joselisa Maria Chaves - Coorientadora
Universidade Estadual de Feira de Santana - UEFS



Prof. Dr. Clayton Alcarde Álvares
Universidade Estadual Paulista "Júlio Mesquita Filho" - UNESP



Prof. Dr. Túlio Barroso Queiroz
Bracell Celulose

MODELAGEM VOLUMÉTRICA DE PLANTIOS DE EUCALIPTO POR MEIO DE DADOS DO LiDAR GEDI, SENTINEL E AMBIENTAIS

Orientador: Edson Eyji Sano

Coorientadora: Joselisa Maria Chaves

Resumo

Os ecossistemas florestais são considerados um componente crítico da biodiversidade mundial, sendo um importante indicador dos Objetivos de Desenvolvimento Sustentável (ODS) n. 15, Vida na Terra – proteger, recuperar e promover o uso sustentável dos ecossistemas terrestres, gerir de forma sustentável as florestas, combater a desertificação, deter e reverter a degradação da terra e deter a perda de biodiversidade. É imperativo que se conheça o estoque de material lenhoso presente nos plantios florestais para que o manejo dessas áreas possa suprir a demanda do mercado e respeitar o uso sustentável dos ecossistemas terrestres. Para tanto, faz-se uso dos inventários florestais baseados em medições de campo de parâmetros como diâmetro à altura do peito e altura total das árvores. Novas técnicas de integração dessas variáveis com dados obtidos por sensores remotos, como imagens ópticas e de radar, coletadas por sensores orbitais, câmeras a bordo de Aeronaves Remotamente Pilotadas ou LiDAR, estão sendo constantemente aprimoradas, visando a redução de custos de obtenção e maior eficiência. Nesse sentido, o presente trabalho tem, como objetivo principal, gerar estimativas volumétricas de madeiras de eucalipto a partir de dados do sensor orbital *Global Ecosystem Dynamics Investigation* (GEDI) e regressão *random forest*. A área de estudo está localizada no Litoral Norte, Agreste e Recôncavo do Estado da Bahia. Foram utilizados dados de inventários florestais coletados em campo, atributos oriundos do balanço hídrico climatológico usando dados climáticos do *Terraclimate*, atributos do terreno extraídos de modelo digital de elevação da missão *Shuttle Radar Topography Mission* (SRTM) e dados de radar obtidos pelo satélite Sentinel-1. A base de dados utilizada foi composta de 412 observações, dividida aleatoriamente entre treinamento e validação na proporção 70-30%, os quais foram submetidos a testes de normalidade, homocedasticidade, análise de variância e teste de média. O teste de Wilcoxon indicou que não existe diferença significativa a 5% de probabilidade entre a altura dominante do inventário florestal contínuo e as alturas relativas rh100 e rh99 oriundas do GEDI. A altura total, por sua vez, não apresentou diferenças significativas a 5% de probabilidade com rh97, rh96 e rh95. A altura relativa ao quantil 97 (rh97), a diversidade de altura de folhagem normalizada pelo índice de área de planta (fhd_norm), e a distribuição vertical da probabilidade de falha no dossel (pgap_theta) apresentaram alta correlação com o volume (coeficiente de correlação de 0,907, 0,824 e -0,432, respectivamente). O modelo que utilizou somente as métricas de altura e estrutura vertical do GEDI apresentou maior assertividade para previsão do volume (raiz do erro quadrático médio de 17,37 m³ ha⁻¹ e erro médio absoluto de 10,72 m³ ha⁻¹).

Palavras-chave: Inventário florestal; radar de abertura sintética; sensoriamento remoto; cobertura de copa; balanço hídrico climatológico.

VOLUMETRIC MODELING OF EUCALYPTUS PLANTATIONS USING GEDI LiDAR, SENTINEL AND ENVIRONMENTAL DATA

Advisor: Edson Eyji Sano

Co-advisor: Joselisa Maria Chaves

Abstract

Forest ecosystems are considered a critical component of the world's biodiversity, being an important indicator of Sustainable Development Goals (SDG) n. 15, Life on Earth – Protect, restore, and promote sustainable use of Earth's ecosystems, sustainably manage forests, combat desertification, halt and reverse land degradation and halt biodiversity loss. It is imperative to know the stock of woody material present in forest plantations so that the management of these areas can meet market demand and respect the sustainable use of terrestrial ecosystems. For this purpose, forest inventories based on field measurements of parameters such as diameter at breast height and total height of trees are used. New techniques for integrating these variables with data obtained by remote sensors, such as optical and radar images, collected by orbital sensors, cameras on board Remotely Piloted Aircraft or LiDAR, are constantly being improved, aiming at reducing acquisition costs and greater efficiency. In this sense, the main objective of this work is to generate volumetric estimates of eucalyptus timber from data from the Global Ecosystem Dynamics Investigation (GEDI) orbital sensor and random forest regression. The study area is located on the North Coast, Agreste and Reconcavo of the Bahia State. Data from forest inventories collected in the field, attributes from the climatological water balance using Terraclimate data, terrain attributes extracted from the digital elevation model of the Shuttle Radar Topography Mission (SRTM) and radar data obtained by the Sentinel-1 satellite were used. The database used consisted of 412 observations, randomly split between training and validation in the proportion 70-30%, which were submitted to tests of normality, homoscedasticity, analysis of variance and mean test. The Wilcoxon test indicated that there is no significant difference at 5% probability between the dominant height of the continuous forest inventory and the relative heights rh100 and rh99 derived from the GEDI. Total height, in turn, did not show significant differences at 5% probability with rh97, rh96 and rh95. Height relative to 97th quantile (rh97), foliage height diversity normalized by plant area index (fhd_norm), and vertical distribution of canopy failure probability (pgap_theta) showed high correlation with volume (correlation coefficients of 0.907, 0.824 and -0.432, respectively). The model that used only the height and vertical structure metrics from the GEDI showed greater accuracy for volume prediction (root mean squared error of 17.37 m³ ha⁻¹ and mean absolute error of 10.72 m³ ha⁻¹).

Keywords: Forest inventory; synthetic aperture radar; remote sensing; canopy cover; climatological water balance.

AGRADECIMENTOS

À Deus pela vida.

Aos meus pais e irmãos pelo amor e apoio incondicional.

A Mariana Novais pelo companheirismo, amor e paciência.

Aos colegas da Bracell pelas contribuições.

Aos orientadores, professores e colegas que compartilharam conhecimento ao longo da jornada.

Ao Programa de Pós-Graduação em Modelagem em Ciências da Terra e do Ambiente da Universidade Estadual de Feira de Santana, pela oportunidade.

SUMÁRIO

1. Introdução.....	8
2. Objetivo.....	9
3. Base Conceitual	10
3.1. Estimativa <i>in situ</i> de volume de madeira (inventários florestais)	10
3.2. Sensoriamento remoto aplicado à mensuração florestal	11
3.3. Uso de imagens ópticas de resolução espacial moderada na mensuração florestal.....	13
3.4. Uso de imagens ópticas de alta resolução espacial e fotogrametria na mensuração florestal	13
3.5. Uso de radar na mensuração florestal.....	14
3.6. Uso de LiDAR na mensuração florestal	16
3.7. Missão <i>Global Ecosystem Dynamics Investigation (GEDI)</i>	19
3.8. Missão Sentinel-1.....	20
3.9 <i>TerraClimate</i>	21
3.10 Missão <i>Shuttle Radar Topography Mission (SRTM)</i>	21
4. Materiais e Métodos	21
4.1 Área de estudo	21
4.2 Abordagem metodológica	24
3.2.1 Dados de campo	25
3.2.2 Dados do sensor GEDI.....	25
3.2.3 Dados do satélite Sentinel-1.....	26
4.2.4 Balanço hídrico climatológico	27
4.2.5 Atributos do terreno.....	28
3.2.6 Estrutura de fusão e modelagem.....	28
5. Resultados	32
5.1 Validação de métricas de altura de copa estimadas com base no GEDI.....	32
5.2 Modelagem dos dados	35
5.2.1 Modelagem volumétrica com dados GEDI	35
4.2.2 Modelagem volumétrica com dados Sentinel-1, balanço hídrico climatológico e atributos do terreno	38
5.2.3 Desempenho dos modelos	41
5.3 Estimativas volumétricas na área de estudo	42
6. Discussão	45
6. Conclusões.....	47
Referências.....	48
APÊNDICE A – Variáveis auxiliares	55

1. Introdução

A *Food and Agriculture Organization* (FAO) considera os ecossistemas florestais um componente crítico da biodiversidade mundial pelo fato de apresentarem maior biodiversidade que outros ecossistemas. A FAO determina que as áreas cobertas por florestas sejam um dos indicadores dos Objetivos de Desenvolvimento Sustentável (ODS) da ONU número 15 – Vida Terrestre – proteger, recuperar e promover o uso sustentável dos ecossistemas terrestres, gerir de forma sustentável as florestas, combater a desertificação, deter e reverter a degradação da terra e deter a perda de biodiversidade (FAO e UNEP, 2020). Essa organização classifica as florestas em naturais (primárias ou secundárias) e plantadas (para fins comerciais ou conservacionistas). Tais formações ocupam cerca de 30% da cobertura terrestre, das quais 93% são naturais e 7% são plantadas. Observou-se um aumento de 123 milhões de hectares na área de plantios florestais ao redor do globo desde 1993 (FAO e UNEP, 2021).

Estão incluídas, no setor florestal, as atividades que dependem da produção de bens e serviços da floresta (LEBEDYS, 2004). Desse modo, fazem parte desta concepção, as práticas de produção de fibras de madeira (em tora, serrada, lenha, carvão, painéis, polpa, papel etc.), aquelas baseadas em produtos não madeireiros (óleos, sementes, castanha, látex etc.), bem como os serviços florestais (sequestro de carbono, produção de água e conservação da biodiversidade). Segundo Baumgartner (2019), os desafios do setor florestal vão muito além da premissa de não consumir mais do que se produz. Para ele, o ramo também se encaixa no ODS 15 – Vida Terrestre. Ademais, o autor acredita que o ODS 15 ainda se relaciona diretamente com outros objetivos – Consumo e Produção Responsáveis, Combate a Alterações Climáticas e Energia Acessível e Limpa.

De acordo com o relatório de 2022 da Indústria Brasileira de Árvores, em 2021, o setor florestal brasileiro apresentou um valor de produção estimado em R\$ 244,6 bilhões, possuindo uma área de 9,93 milhões de hectares de florestas plantadas para fins industriais e 6,05 milhões de hectares destinados a Áreas de Preservação Permanente, Reserva Legal e Reservas Particulares do Patrimônio Natural (IBÁ, 2023). De acordo com o relatório de cobertura e uso da terra do MapBiomas, o Brasil perdeu 82 milhões de hectares de vegetação nativa entre os anos de 1985 e 2020. No mesmo período, a área de pastagem no país aumentou 44 milhões de hectares, enquanto as áreas de agricultura e silvicultura aumentaram 36 e 6 milhões de hectares, respectivamente (MAPBIOMAS, 2020).

Uma das maneiras de quantificar os recursos florestais é por meio da medição ou estimativa de atributos das árvores e das florestas, além de outras propriedades do local em que as árvores crescem (SOARES et al., 2011). A mensuração florestal fornece métodos e ferramentas para tanto, concentrando-se primariamente na avaliação quantitativa da árvore e do

povoamento em determinado instante no tempo de vida da floresta ou indivíduo, proporcionando dados para um manejo florestal eficiente (VAN LAAR e AKÇA, 2007).

Acontecimentos recentes ampliaram o escopo de técnicas que possibilitam gerar informações relevantes e confiáveis a um custo acessível para a silvicultura. Dentre eles, destacam-se os grandes avanços na qualidade das fotografias e o desenvolvimento da fotogrametria, sensores não-imageadores, imagens de satélite, computadores e aplicativos para processamento e análise desse conjunto de dados (KERSHAW et al., 2017). Nesse sentido, muitos trabalhos têm sido realizados nas últimas décadas para testar metodologias de integração de dados multi-sensores remotos, visando extrair parâmetros biofísicos de formações florestais (REIS et al., 2019; BISPO et al., 2020; DUNCANSON et al., 2020; SILVA et al., 2021; DUNCANSON et al., 2022).

Para tanto, podem ser utilizadas imagens ópticas e de radar coletadas por sensores orbitais e imagens de alta resolução adquiridas por câmeras a bordo de Aeronaves Remotamente Pilotadas (RPA). Estas tecnologias, no entanto, têm, como pontos negativos, o custo para mapear grandes áreas, eventuais indisponibilidades por nuvens e condições climáticas e problemas com saturação e incapacidade de penetrar o dossel florestal. O LiDAR, por outro lado, tem a vantagem de proporcionar a reconstituição tridimensional dos ambientes florestais e retratar a condição de todo o ambiente florestal (MARTELLO et al., 2022; CORTE et al., 2022).

O *Global Ecosystem Dynamics Investigation* (GEDI) é pioneiro por ter sido especificamente projetado para medir a estrutura da vegetação, produzir a observação da estrutura 3D da superfície da Terra em alta resolução, a partir de pulsos laser e derivar medições precisas de altura e estrutura vertical de dossel e elevação do terreno, possibilitando melhores condições de caracterizar ciclos de água, carbono e biodiversidade (DUBAYAH et al., 2020). Para que sejam determinadas suas capacidades e indicações de uso, são necessários estudos que consolidem as metodologias mais adequadas para o uso dessas ferramentas, a depender do objetivo.

2. Objetivo

O presente trabalho tem, como objetivo principal, gerar estimativas volumétricas de madeiras de eucalipto a partir de dados do sensor orbital *Global Ecosystem Dynamics Investigation* (GEDI) e regressão *Random Forest*. Serão utilizados ainda dados auxiliares de inventários florestais coletados em campo, dados de clima, atributos do terreno e dados oriundos do sensoriamento remoto por radar. As seguintes atividades serão desenvolvidas para alcançar o referido objetivo:

- Validação e teste de correlação de métricas de altura de copa do GEDI com medidas obtidas por inventário florestal convencional;
- Ajuste e avaliação da acurácia de modelos de aprendizado de máquina que estimem o volume de material lenhoso usando as métricas do GEDI associadas a dados de radar obtidos pelo satélite Sentinel-1, atributos oriundos do balanço hídrico climatológico usando dados climáticos do *Terraclimate* e atributos do terreno extraídos de modelo digital de elevação da missão *Shuttle Radar Topography Mission* (SRTM) como variáveis preditoras e a estimativa do volume do inventário florestal convencional como variável resposta.

3. Base Conceitual

3.1. Estimativa *in situ* de volume de madeira (inventários florestais)

A silvicultura é uma atividade de manejo que envolve florestas, plantas e animais que fazem parte de um território. Para tanto, se requer um plano de manejo contendo predições sobre o crescimento e produção dos recursos florestais que irão embasar tomadas de decisão a respeito de como, onde, quanto e quando essa floresta será tratada. Para que boas decisões sejam tomadas, são necessários bons modelos que, por sua vez, exigem dados de confiança. A aquisição desses dados diz respeito à mensuração florestal (KERSHAW et al., 2017).

De acordo com Van Laar e Akça (2007), a mensuração florestal lida com aspectos técnicos de aferição de árvores e plantios florestais, sejam eles a medição de variáveis de árvores ou povoamentos como diâmetro, altura, área basal, parâmetros de casca ou volume de árvores em pé ou derrubadas; determinação da forma e idade de árvores e povoamentos; aferições da copa e quantidade de folhagem; desenvolvimento de modelos para estimativa da biomassa, volume, crescimento e produtividade; e estimativa de dados sobre qualidade das árvores.

Para que o silvicultor seja capaz de suprir a demanda de forma sustentável, respeitando-se o Código Florestal (Lei 12.651 de 25 de maio de 2012) e evitando o avanço sobre áreas preservadas, deve-se conhecer o estoque de material lenhoso presente no maciço em questão. Para isso, faz-se o uso dos inventários florestais, que são procedimentos para aquisição de informações quantitativas, qualitativas e das condições dos recursos florestais (KERSHAW et al., 2017).

Normalmente, as informações supracitadas são obtidas por meio de medições *in loco* de características dos indivíduos arbóreos, como diâmetro à altura do peito (DAP) e altura total (HT), que são utilizados para estimar a variável de interesse (área basal, volume ou biomassa). Essas características também podem ser obtidas usando dados remotamente detectados, a partir de sensores embarcados em plataformas orbitais ou aéreas (KERSHAW et al., 2017).

O inventário florestal pode fornecer outras informações sobre a área em que a floresta está crescendo, como estimativas de área, descrição da topografia, mapeamento da propriedade, descrição dos seus acessos e instalações de transporte de madeira e estimativas de crescimento. A depender do objetivo, existem diferentes tipos de inventário (HUSCH et al., 1971). O inventário florestal de sobrevivência é realizado após o plantio para verificar o percentual de falhas/sobrevivência das mudas; o inventário florestal convencional é realizado para obtenção de volume de madeira em um determinado momento do ciclo de vida da floresta; o inventário pré-corte é executado antes da exploração, com alta intensidade amostral; e o inventário florestal contínuo é feito com o objetivo de verificar mudanças no povoamento ao longo do seu ciclo de vida (SOARES et al., 2011).

Segundo Leite e Andrade (2003), a medição da HT das árvores contribui de modo expressivo para o custo de um inventário, ficando atrás apenas do custo oriundo do deslocamento das equipes de campo. Desse modo, muitos trabalhos têm sido desenvolvidos com o objetivo de testar e aperfeiçoar técnicas que estimem tal variável de maneira prática e segura (BINOTI et al., 2012; CAMPOS et al., 2016; KOHLER et al., 2017).

3.2. Sensoriamento remoto aplicado à mensuração florestal

No sentido mais amplo, o sensoriamento remoto diz respeito à aquisição de informações de um objeto ou área de interesse por meio de um instrumento e sem que haja contato direto entre ambos (JENSEN, 2011). O instrumento (sensor) pode fornecer informações específicas do alvo, como diâmetro de uma copa ou limite espacial de um fragmento florestal. Os sensores remotos podem estar acoplados em diferentes plataformas, como a bordo de aeronaves tripuladas ou remotamente pilotadas, de satélites, de veículos terrestres ou fixos em um ponto no solo (JENSEN, 2011).

Normalmente se registra a energia eletromagnética refletida, emitida ou retroespalhada pelo objeto de estudo e que, após ser processada e transformada em informação, é usada para inferir propriedades deste elemento. Em outros casos, variáveis biofísicas podem ser diretamente medidas pelo sistema de sensoriamento remoto, como a extração da posição x , y e altura (z) de uma copa a partir de estereoscopia de imagens aéreas, de levantamentos *Light Detection and Ranging* (LiDAR) ou de interferometria de radar de abertura sintética (SAR) (JENSEN, 2011).

Os sensores remotos operam em diferentes faixas do espectro eletromagnético, sendo a resolução espectral do sensor definido pelo número e tamanho dos intervalos do comprimento de onda dentro do espectro (bandas ou canais) (Figura 1) em que o instrumento é sensível (JENSEN, 2011). Sistemas multiespectrais captam energia em diferentes canais, como é o caso do satélite Landsat 8, equipado com os sensores *Operational Land Imager* (OLI) e *Thermal Infrared Sensor* (TIRS) (USGS, 2016).




Figura 1 – Faixas do espectro eletromagnético. Fonte: Adaptado de Jensen (2011).

Com relação à fonte de energia registrada pelo instrumento, o sistema de sensoriamento remoto pode ser passivo, quando registra a energia eletromagnética que é refletida (tendo o Sol como fonte) ou emitida pelos alvos; ou ativo, quando não dependem da energia eletromagnética do Sol ou das propriedades termais da Terra, sendo capazes de emitir energia produzida pelo próprio sistema sensor (JENSEN, 2011). Dentre os sistemas ativos mais utilizados, estão o radar de abertura sintética (SAR) e o *Light Detection and Ranging* (LiDAR). O primeiro é baseado na transmissão de micro-ondas com comprimentos de onda nas faixas de 3 cm a 25 cm e na detecção da quantidade de energia retroespalhada pelo alvo. Já o LiDAR é baseado na transmissão de comprimentos de onda mais curtos da luz laser (1.064 nm) e na detecção da quantidade de energia retroespalhada (JENSEN, 2011).

Com relação ao nível de detalhamento possível, diz-se que a resolução espacial é a medida da menor separação entre dois objetos que pode ser detectada pelo sistema de sensoriamento remoto. A resolução temporal, por sua vez, está relacionada com a frequência em que o sistema captura informações de determinada área (JENSEN, 2011).

Uma das maiores mudanças nas práticas do inventário florestal nos últimos anos tem sido a ampla disponibilidade e integração de dados oriundos do sensoriamento remoto. Apesar do uso desses dados não ser recente, com suas raízes na fotografia aérea, a diversificação de tipos e fontes de informações, o aumento da sua disponibilidade e o rápido progresso nos dispositivos computacionais para lidar com esses enormes bancos de dados espaciais possibilitaram transformar as técnicas da mensuração nas últimas décadas (KERSHAW et al., 2017).

De acordo com Köhl et al. (2006), dados adquiridos remotamente possuem papel importante para estudos em ambientes naturais ou seminaturais, já que podem ser usados para desde uma simples interpretação visual de imagens até a extração de informação por meio de técnicas avançadas de processamento de imagens e estatística. Os autores reiteraram que a sinergia entre dados tradicionais e remotamente obtidos é reconhecidamente essencial para estudos em escalas local, regional e global.

Para Kershaw et al. (2017), a abordagem de sensoriamento remoto teoricamente ideal para a silvicultura seria via satélite, por causa da capacidade de prover cobertura global sob

demanda e de combinar dados adquiridos por sensores ativos e passivos com boa resolução espacial e espectral. Tais características permitiriam que fossem adquiridos dados durante o dia e à noite, sem grandes impactos de nuvens ou fumaça, fornecendo não somente medidas bidimensionais, mas também tridimensionais – como medida da elevação do terreno e altura de árvores. Na inexistência da abordagem ideal, os autores recomendam a escolha do conjunto de dados baseados na busca de equilíbrio entre cobertura, disponibilidade, resolução e custo de aquisição e processamento.

Segundo Spurr (1952-1953), a importância das imagens aéreas para o manejo florestal é conhecida há muito tempo, sendo que, após a II Guerra Mundial, as técnicas fotogramétricas se tornaram parte integral da ciência florestal, fato considerado como um dos maiores avanços modernos desta disciplina. Van Laar e Akça (2007) afirmaram que a primeira tentativa de introduzir uma fotografia aérea como ferramenta para o manejo florestal ocorreu em 1887 em Berlim, fazendo-se uso de um balão. Desde então, as imagens aéreas têm sido utilizadas para otimizar operações de mapeamento, orientação e estratificação da floresta.

3.3. Uso de imagens ópticas de resolução espacial moderada na mensuração florestal

O sensoriamento remoto orbital óptico de resolução espacial moderada tem sido utilizado para prever atributos estruturais de compartimentos florestais, como a biomassa e sua mudança ao longo do tempo, sendo úteis no suporte a inventários de escala regional (KERSHAW et al., 2017). A principal vantagem desses dados é a sua ampla cobertura de área, gratuidade e disponibilidade de dados históricos, como é caso do sensor *Moderate-resolution Imaging Spectroradiometer* (MODIS), do Landsat e do Sentinel-2 que podem fornecer dados coletados em diferentes resoluções espaciais ao longo de distintas faixas do espectro eletromagnético (KERSHAW et al., 2017). Diversas pesquisas têm sido feitas para avaliar o potencial do uso de imagens MODIS (LE MAIRE et al., 2011; MARSDEN et al., 2010), Landsat (REIS et al., 2018; DUBE e MUTANGA, 2015) e Sentinel 2 (NUTHAMMACHOT et al., 2018) na estimativa volumétrica de plantios florestais.

3.4. Uso de imagens ópticas de alta resolução espacial e fotogrametria na mensuração florestal

Uma das limitações do uso de imagens de resolução espacial moderada é a impossibilidade de se delimitar individualmente as copas das árvores, ao contrário das imagens de alta resolução que são, em sua maioria, fornecidas por vendedores comerciais (KERSHAW et al., 2017). Como exemplo de imagens de alta resolução coletadas em sistemas orbitais, podem-se citar o IKONOS, QuickBird, WorldView e mais recentemente a Planet e o SkySat, que podem fornecer imagens pancromáticas e multiespectrais com resolução submétrica. Pesquisadores tem

se dedicado, nas últimas décadas, a avaliar o efeito do uso de imagens orbitais de alta resolução do WorldView-2 (DUBE e MUTANGA, 2016; MOHSIN, 2021), QuickBird (VERMA et al., 2016) e PlanetScope (TADDESE et al., 2020) na estimativa de volume ou outro substituto em ecossistemas florestais.

As imagens de alta resolução também podem passar por processamento fotogramétrico. Almeida et al. (2021) avaliaram o potencial de uso de fotogrametria com imagens coletadas por RPA para detecção e estimativa de altura de indivíduos arbóreos e monitorar a qualidade da silvicultura de um plantio de eucalipto com 1,5 anos no Nordeste do Brasil. Os autores concluíram que os produtos dessa técnica permitem detectar em torno de 95% das árvores, estimar altura com raiz do erro quadrático médio (RMSE) de 0,36 m (11%) e determinar a uniformidade do fragmento com mesmo padrão de acurácia de inventário florestais convencionais.

Martello et al. (2022) aferiram o desempenho da estimativa de altura de árvores de eucalipto obtidas por processamento fotogramétrico de imagens coletadas por RPA em diferentes estágios de desenvolvimento das plantas. As alturas estimadas com as imagens do RPA foram comparadas com medidas de altura obtidas a campo, obtendo-se um coeficiente de determinação superior a 0,75 e RMSE inferiores a 3,94 m., demonstrando o alto potencial para o monitoramento e avaliação dos clones de *Eucalyptus* com a técnica proposta.

3.5. Uso de radar na mensuração florestal

Sistemas sensores que se baseiam na gravação da energia eletromagnética refletida com comprimentos de onda na casa de micrômetros, como é o caso do Landsat ou de fotografias aéreas, possuem a limitação de registrarem apenas as informações referentes às primeiras camadas de folhas ou galhos do dossel. A energia ativa de micro-ondas, no entanto, é capaz de penetrar o dossel em diferentes profundidades, dependendo de características do sensor (JENSEN, 2011). Os dados SAR, também possuem a vantagem de serem independentes do horário e de condições climáticas, como nuvens e precipitação. Além disso, o SAR é interessante para estudos em florestas pelo fato de o coeficiente de retroespalhamento ser influenciado por propriedades dielétricas e estruturais dos alvos que, no caso de copas de árvores, podem ser tamanho, orientação e número de elementos retroespalhantes (KÖHL et al., 2006).

O imageamento SAR depende primariamente de atributos da vegetação alvo e do comprimento da onda emitida (Tabela 1), já que a radiação de micro-ondas interage mais fortemente com alvos de dimensões semelhantes ou pouco maiores ao comprimento da onda (KERSHAW et al., 2017). Nesse sentido, existem diferentes mecanismos de espalhamento, sendo eles: espalhamento superficial – com fortes retornos de únicas reflexões de componentes da copa, galhos e troncos, sendo gravado com alto brilho de sinal; espalhamento volumétrico – quando a energia é espalhada múltiplas vezes dentro de volumes difusos da folha para o galho, para o tronco e de

volta para a folha, sendo despolarizada; e *double-bounce* – quando a energia atinge duas superfícies com ângulo reto, como uma parede, sendo sua maior porção refletida (JENSEN, 2011).

Tabela 1. Comprimentos de onda e frequência de radar mais utilizados em investigações com sensoriamento remoto com micro-ondas.

Bandas espectrais (comprimentos de onda comuns em parêntesis)	Comprimento de onda (λ) (cm)	Frequência (ν) (GHz)
Ka (0,86 cm)	0,75 – 1,18	40,0 – 26,5
K	1,19 – 1,67	26,5 – 18,0
Ku	1,67 – 2,4	18,0 – 12,5
X (3,0 e 3,2 cm)	2,4 – 3,8	12,5 – 8,0
C (7,5, 6,0 cm)	3,9 – 7,5	8,0 – 4,0
S (8,0, 9,6, 12,6 cm)	7,5 – 15,0	4,0 – 2,0
L (23,5, 24, 25 cm)	15,0 – 30,0	2,0 – 1,0
P (68 cm)	30,0 – 100	1,0 – 0,3

Fonte: Adaptado de Jensen (2011).

Um radar operando na banda X ou C, com comprimento de onda de poucos centímetros, interage com folhas e elementos da copa com pouca capacidade de penetração no dossel para descrever atributos de troncos ou do solo (Figura 2). As bandas L e P, com comprimentos de onda de dezenas de centímetros, atravessam a copa e interagem fortemente com ramos grossos, tronco e com o solo (KERSHAW et al., 2017).




Figura 2 – Resposta teórica de uma floresta de pinus a micro-ondas emitidas nas bandas L, C e X. Fonte: Adaptado de Jensen (2011).

Carver e Simino (1988) afirmaram que o imageamento SAR é capaz de fornecer parâmetros biofísicos das florestas como teor de biomassa por compartimento (folhas, galhos e fuste), estrutura da copa (inclusive índice de área foliar), orientação de folhagem, geometria e distribuição espacial de fuste, tamanho e distribuição de galhos e até teor de água do dossel.

O coeficiente de retroespalhamento em imagem de radar aumenta de forma aproximadamente linear com o aumento do teor de biomassa de sistemas florestais, até atingir um ponto de saturação, que depende da frequência de operação do sensor. Sensores que trabalham em maiores frequências tendem a apresentar menos sensibilidade à biomassa do que aqueles que utilizam ondas com menores frequências, possuindo também maiores níveis de saturação – 200 t ha⁻¹ para banda P e 100 t ha⁻¹ para banda L (JENSEN, 2011).

As agências espaciais têm feito investimentos visando melhorar a compreensão do ciclo do carbono e da água. Podem-se citar o satélite de radar de banda L denominado de NISAR, parceria entre a NASA e a *Indian Space Research Organization* (ISRO), com lançamento previsto para 2024 (NISAR, 2020) e o programa de radar na banda P da *European Space Agency* (ESA) denominado de BIOMASS, também previsto para ser lançado em 2024 (CARREIRAS et al., 2017; QUEGAN et al., 2019).

3.6. Uso de LiDAR na mensuração florestal

Os sistemas LiDAR normalmente consistem de um controlador e um transmissor/emissor acoplados à uma plataforma (RPA, aeronave tripulada, satélite, etc.) no qual os pulsos da luz laser são direcionados perpendicularmente à linha de voo por um espelho de escaneamento (JENSEN, 2011). Os pulsos são emitidos em alta frequência, sendo medido o tempo de viagem do laser, do transmissor até o alvo e de volta ao receptor, permitindo que seja calculada a distância (alcance) e obtida uma coleção de pontos tridimensionais (x , y e z) (BOLAND et al., 2004).

Com base nas suas especificações, sistemas LiDAR podem ser divididos pelo tamanho do *footprint* (área amostrada pelo pulso laser), pela maneira como gravam o sinal refletido e pela frequência de amostragem e padrão de escaneamento (DUBAYAH e DRAKE, 2000). O tamanho do *footprint* é aproximadamente circular e depende da topografia e do ângulo de varredura/escaneamento (BALTSAVIAS, 1999). Para um dossel com altura e densidade uniformes, um maior ângulo de escaneamento deve ser previsto para que mais vegetação seja penetrada até o pulso atingir o solo (Figura 3) (JENSEN, 2011).




Figura 3 – Impacto de um ângulo de escaneamento elevado. Fonte: Adaptado de Jensen (2011).

Sistemas que possuem *footprint* pequeno podem não ser ideais para mapeamento de estrutura florestal, podendo amostrar excessivamente parte inferiores da copa, perdendo o seu topo e o solo, além de exigirem que grandes áreas sejam voadas extensivamente (DUBAYAH e DRAKE, 2000). Os autores afirmaram que, em contrapartida, sistemas com *footprint* de aproximadamente um diâmetro médio de copa (10 – 25 metros), possibilitam que a energia alcance o solo mesmo em florestas densas, permitindo que seja mapeado o topo das árvores, proporcionando mapeamentos de amplas áreas.

Sensores LiDAR podem fazer medições de um ou múltiplos retornos para cada pico de sinal por pulso emitido, sendo chamados de retorno discretos ou fornecendo representação da onda completa de um sinal de retorno em intervalos de tempo fixos (DONG e CHEN 2018) (Figura 4). Sistemas de forma de onda completa são mais caros e descrevem informações mais detalhadas da estrutura física do alvo (KERSHAW et al., 2017), sendo utilizados principalmente em aplicações florestais (DONG e CHEN, 2018).




Figura 4 – Princípios de um sistema de onda completa (A) e de retorno discreto (B). Fonte: Adaptado de Chazette et al. (2016).

Pelo fato de conseguir obter múltiplos retornos de diferentes alvos (folhas, galhos, fuste, superfície do solo), a tecnologia LiDAR é útil para aplicações silviculturais, permitindo a derivação de altura de árvores, cobertura de copa e estrutura vertical do povoamento (KÖHL et al., 2006). Além disso, tais sistemas, por serem capazes de extrair a estrutura vertical da formação florestal, permitem estimativas de estoque de carbono em ecossistemas com moderado a alto teor de biomassa, ao contrário dos sensores ópticos ou radar, que tendem a apresentar problemas de saturação (JENSEN, 2011). A Tabela 2 apresenta contribuições do LiDAR para aplicações florestais.

Tabela 2. Potenciais contribuições do sensoriamento remoto LiDAR para aplicações florestais.

Atributo Silvicultural	Derivação LiDAR
Altura de dossel	Consulta direta
Topografia abaixo do dossel	Consulta direta
Distribuição vertical de superfícies interceptadas	Consulta direta
Biomassa acima do solo	Modelado
Área basal	Modelado
Diâmetro médio de fustes	Modelado
Volume de dossel	Modelado
Cobertura de copa, índice de área foliar	Fusão com outros sensores

Fonte: Adaptado de Dubayah e Drake (2000).

Trabalhos têm sido feitos para implementar metodologias de integração de dados multi-sensores remotos, visando extrair parâmetros biofísicos de formações florestais (CHI et al.,

2017; POTAPOV et al., 2019; REIS et al., 2019; BISPO et al., 2020; DUNCANSON et al., 2020; DUNCANSON et al., 2022; SILVA et al., 2021). Reis et al. (2019) testaram a efetividade da integração da idade de plantio com a reflectância espectral de imagens Landsat 8, atributos geomorfológicos do terreno extraídos de um modelo de elevação e coeficientes de retroespalhamento do Sentinel-1, tendo concluído que a abordagem melhorou a acurácia da estimativa volumétrica de madeiras.

Silva et al. (2021) testaram abordagens para a fusão de dados multi-sensores, visando espacializar a estimativa de biomassa em uma floresta mista (coníferas e folhosas) nos Estados Unidos. Os autores utilizaram dados simulados dos LiDAR orbitais ICESat-2 e GEDI para calibrar um modelo regional de biomassa, a partir de dados simulados do NISAR. Foram testadas duas técnicas de fusão das observações do dado LiDAR: em grade regular de 1 ha e em polígonos resultantes de segmentação orientada-a-objeto da imagem NISAR.

3.7. Missão *Global Ecosystem Dynamics Investigation* (GEDI)

Por décadas, agências espaciais internacionais têm apoiado temas relacionados com o presente e o futuro dos ciclos de carbono e da água na Terra, sendo a modelagem tridimensional das florestas e o seu teor de carbono uma das principais lacunas de observação (DUBAYAH et al., 2020). Segundo esses autores, o sensoriamento remoto por LiDAR é a forma mais acurada de investigar a estrutura vertical da vegetação, fazendo com que esforços fossem direcionados nesse sentido ao longo dos últimos anos. Podem-se destacar algumas missões da NASA, como o *Shuttle Laser Altimeter* (SLA), o ICESat, o ICESat2 e o *Global Ecosystem Dynamics Investigation* (GEDI) (DUBAYAH et al., 2020).

O GEDI corresponde a um sensor que opera com sensor de LiDAR de onda completa no comprimento de onda de 1.064 nm (infravermelho próximo), operando a bordo da estação espacial internacional. A missão amostrará cerca de 4% da superfície terrestre, ao longo de dois anos. Seu *footprint* é de 25 m de diâmetro, operando com quatro feixes espaçados de 600 m entre faixas e 60 m ao longo da faixa. Os dados são disponibilizados em diferentes níveis de processamento: desde o *waveform* bruto, altura de copa, perfil vertical, cobertura de copa, altitude do terreno etc. (DUBAYAH et al., 2020). A Tabela 3 mostra as quatro opções de produtos disponibilizados em diferentes níveis de processamento.

Tabela 3. Produtos da missão GEDI disponibilizados em diferentes níveis de processamento.

Nível de processamento	Produto
1A	<i>Waveform</i> bruto
1B	<i>Waveform</i> geolocalizado
2A	Elevação do terreno, altura do topo do dossel, métricas de altura relativa
2B	Fração de cobertura de copa, perfil de cobertura de copa, índice de área foliar

Fonte: Adaptado de Dubayah et al. (2020).

Segundo Healey et al. (2020), os dados coletados por LiDAR orbitais têm potencial para fornecer mensurações de altura de copa satisfatórias o suficiente para treinar modelos de altura regionalmente diferentes. Fayad et al. (2021) usaram diferentes métricas procedentes de observações do GEDI para estimar a altura dominante (HD) e o volume a nível de talhão, em plantios de eucalipto no Brasil. Resultados mostraram que, devido à alta acurácia da estimativa da HD e volume, o GEDI é uma excelente fonte de informação para calibrar, validar e suplementar futuras missões de radar como o satélite BIOMASS, objetivando obter mapas contínuos e de alta resolução das propriedades de ecossistemas florestais.

3.8. Missão Sentinel-1

O Sentinel-1 é uma missão de imageamento por radar de abertura sintética (SAR) que adquire imagens na banda C (comprimento de onda de ~5,55 cm), diurnas e noturnas, sob qualquer condição climática. A sua constelação original é formada por dois satélites heliossincrônicos, Sentinel-1A e Sentinel-1B, lançados em 2014 e 2016, respectivamente, com ciclo de revisita de 12 dias cada, e 6 dias para a constelação completa (ESA, 2022a). O Sentinel-1 tem potencial para mapear todos os continentes, sendo seu principal modo de aquisição o *Interferometric Wide swath* (IW), em três subfaixas, usando a técnica de imageamento *Terrain Observation with Progressive Scanning* SAR (TOPSAR). Cada subfaixa consiste em uma série de *bursts* que são processados como uma imagem SLC separada (ESA, 2022a).

Os produtos são disponibilizados em diferentes níveis de processamento: *Level 0* (dado bruto), *Level 1 Single Look Complex* (SLC), contendo imagens complexas com amplitude e fase; *Level 1 Ground Range Detected* (GRD), contendo somente dados de intensidade, e *Level 2 Ocean* (OCN), contendo parâmetros geofísicos de oceanos. Tais características o torna adequado para aplicações de monitoramento, previsão de colheita/biomassa e detecção de distúrbios no manejo florestal e agrícola (ESA, 2022a).

Em 23 de dezembro de 2021, o satélite Sentinel-1B experienciou uma anomalia nos instrumentos eletrônicos de suprimento de energia, deixando-o inoperante. Apesar dos esforços, tal

satélite foi descomissionado, de modo que o Sentinel-1A continua operacional, e o Sentinel-1C deverá ser lançado em 2023 (ESA, 2022b).

3.9 TerraClimate

O conjunto de dados do *TerraClimate* apresenta grade com ~ 4 km² de resolução espacial e contém agregados mensais de variáveis climáticas para a superfície terrestre global de 1958 até o presente, sendo atualizados anualmente (ABATZOGLOU et al., 2018). Tal base de dados foi construída a partir de três dados climáticos matriciais pré-existentes: *WorldClim*, *Climate Research Unit* (CRU) e *Japanese 55-year Reanalysis* (JRA-55).

A interpolação climatologicamente auxiliada, método para redução da escala que emprega interpolação bilinear, foi empregada para afinar a resolução e sobrepor anomalias mensais do CRU e JRA-55 com as normais climatológicas do *WorldClim* (ABATZOGLOU et al., 2018). Dentre as variáveis disponibilizadas, estão a temperatura mínima, máxima, precipitação pluviométrica e evapotranspiração de referência.

3.10 Missão Shuttle Radar Topography Mission (SRTM)

A missão *Shuttle Radar Topography Mission* (SRTM) resulta de um esforço colaborativo da NASA com a *National Geospatial-Intelligence Agency* (NGA) e participação das agências espaciais alemãs e italianas. O propósito do SRTM foi de gerar, no início do século XXI, um modelo digital de elevação (MDE) da Terra usando interferometria radar, com 30 m de espaçamento de grade e aproximadamente 15 m de acurácia (FARR et al., 2007).

4. Materiais e Métodos

4.1 Área de estudo

O estudo foi desenvolvido em plantios de eucalipto localizados no Litoral Norte, Agreste e Recôncavo do estado da Bahia (Figura 5). As áreas incluem plantios de eucalipto com idade variando de dois a 6,5 anos, em áreas com precipitação pluviométrica média anual variando entre 800 mm e 1.400 mm, aumentando à medida que se aproxima do litoral (SEI, 2003).

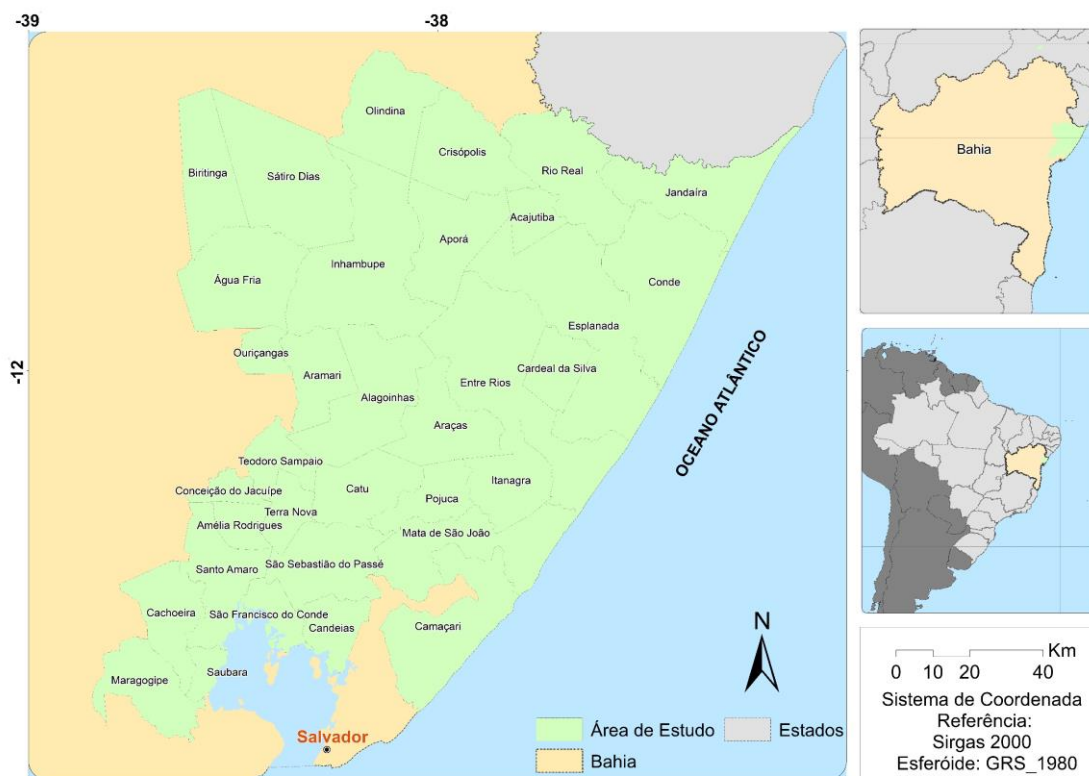


Figura 5 – Localização da área de estudo. Fonte: O autor (2023).

De acordo com a classificação climática de Köppen (ALVARES et al., 2013), o clima da região é tropical, sem estação seca na porção mais próxima ao litoral, apresentando uma faixa de transição com clima tropical de monções, chegando a uma região com estação seca no verão e passando por uma pequena faixa com inverno seco. O mapa de tipologia climática pode ser observado na Figura 6.

Na região, há uma diversidade de solos, sendo predominantes os Argissolos com textura arenosa/média e média/argilosa e os Latossolos, Neossolos, Planossolos e Vertissolos (WAKE et al., 1983) (Figura 7). Com relação à geomorfologia, a região se estende por diferentes domínios morfoestruturais. Na porção mais próxima ao Oceano Atlântico, ocorrem as Planícies Litorâneas e Tabuleiros Costeiros. Mais ao noroeste, ocorrem os Tabuleiros do Rio Real e do Itapicuru, enquanto nas porções a sudoeste, ocorrem os Tabuleiros Interioranos e do Recôncavo e as baixadas do Recôncavo mais ao sul (NOU et al., 1983). Na Figura 8, pode-se observar o mapa geomorfológico da região.

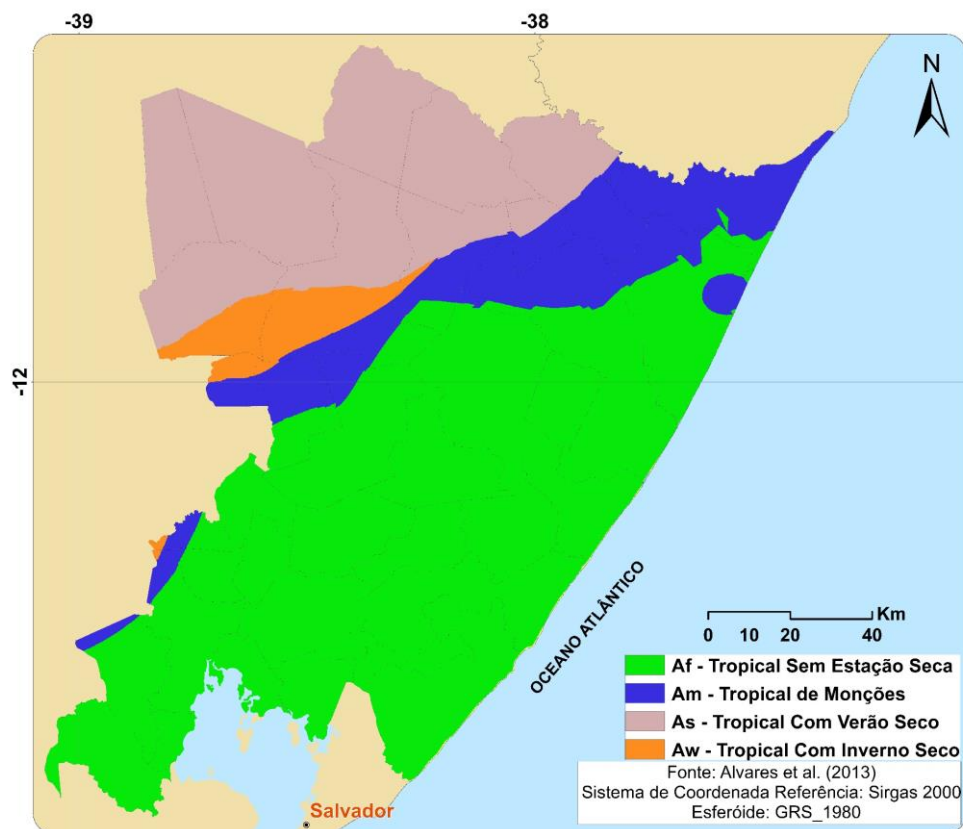


Figura 6 – Classificação climática segundo Köppen. Fonte: Adaptado de Alvares et al. (2013).

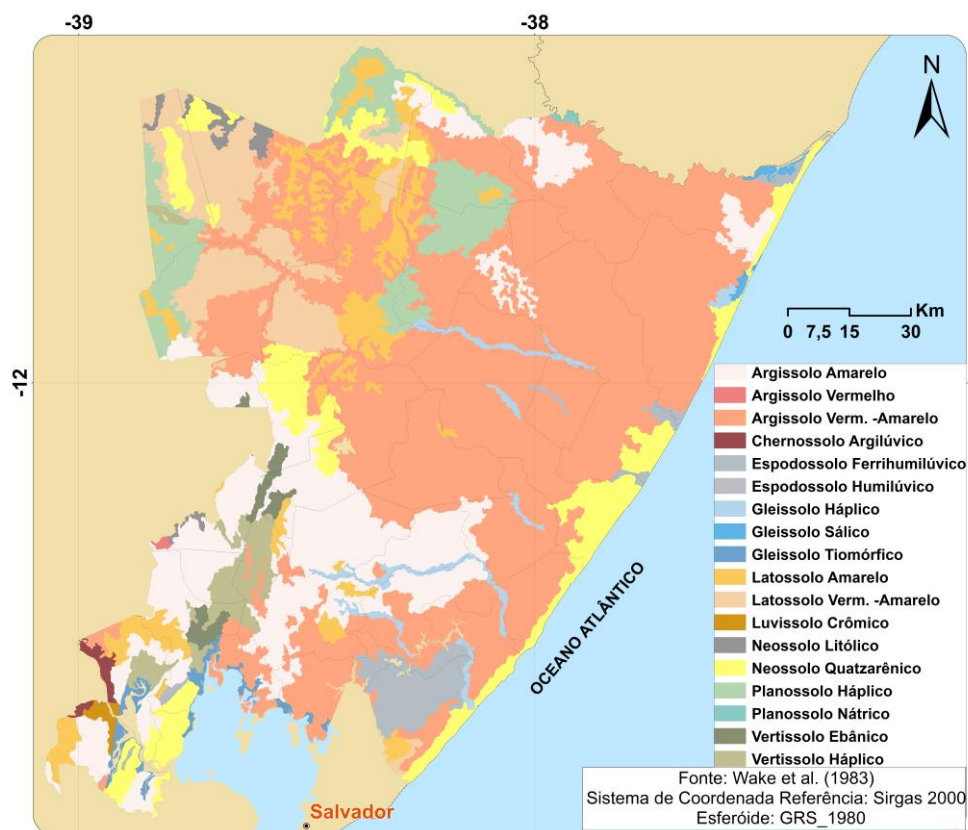


Figura 7 – Mapa de solos. Fonte: Adaptado de Wake et al. (1983).

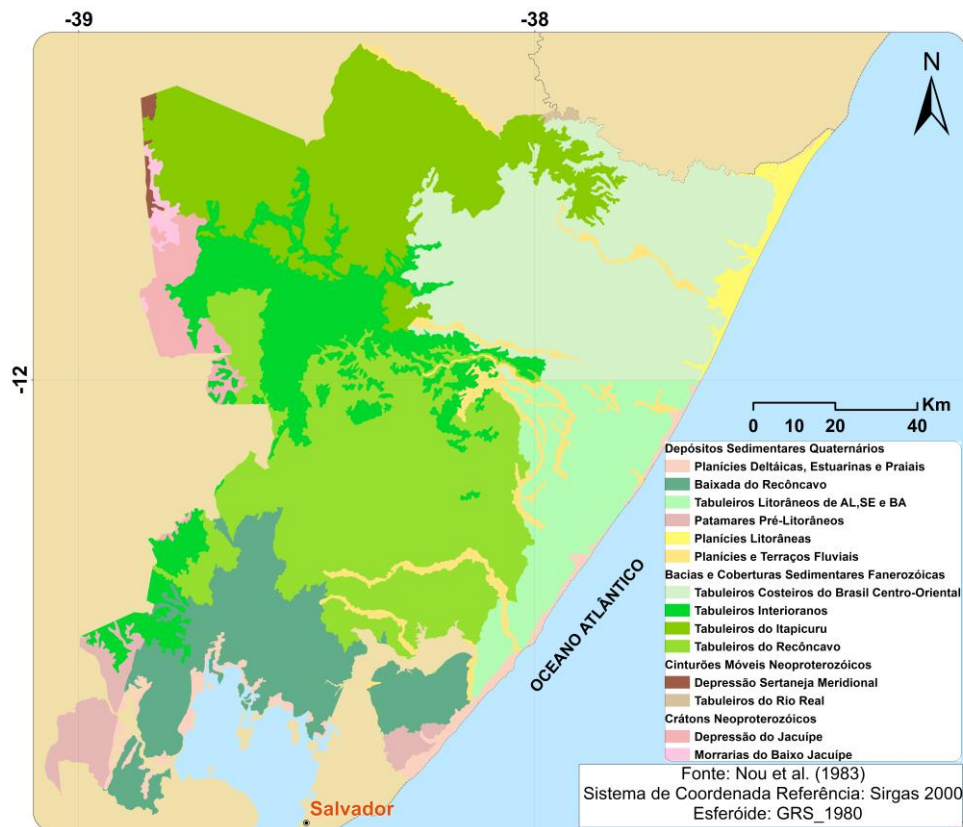


Figura 8 – Mapa geomorfológico. Fonte: Adaptado de Nou et al. (1983).

4.2 Abordagem metodológica

Na Figura 9, é mostrado o fluxograma com as principais etapas da pesquisa. Serão utilizadas cinco fontes de dados para validação das métricas de altura de copa estimadas por meio do sensor GEDI, ajuste dos modelos de regressão para predição volumétrica e espacialização do volume a nível regional. As variáveis empregues e as etapas executadas são descritas nos tópicos subsequentes.

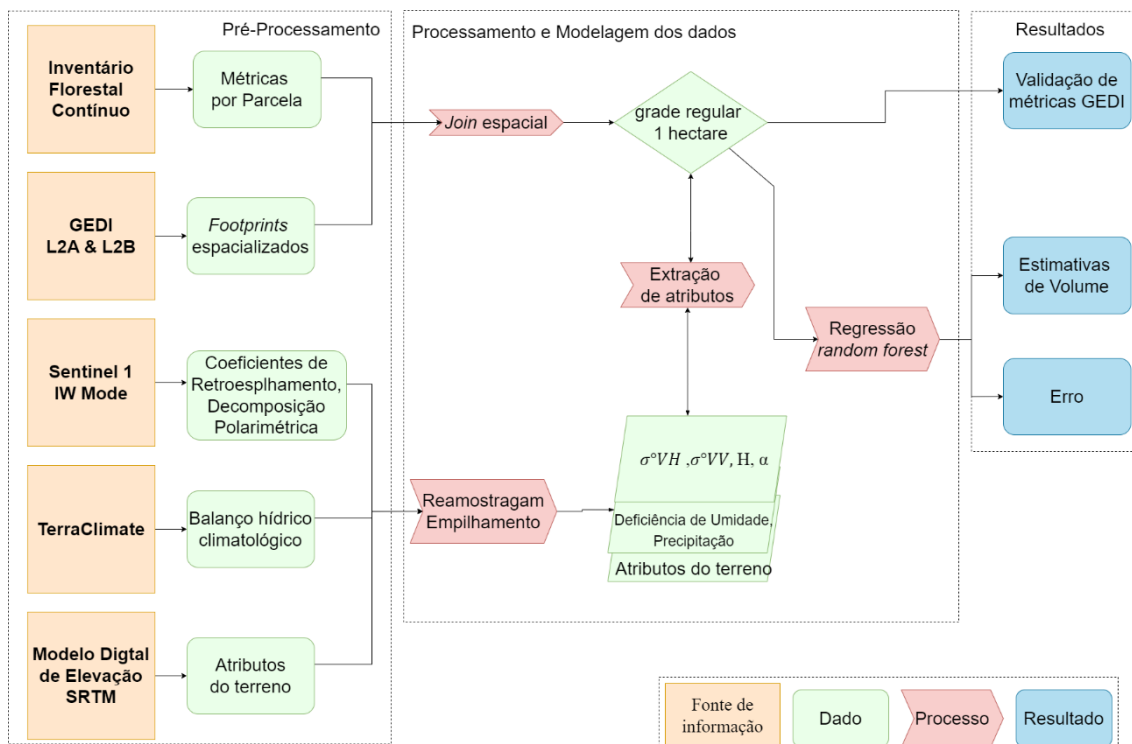


Figura 9 – Fluxograma da metodologia utilizada. Fonte: O autor (2023).

3.2.1 Dados de campo

Os dados de campo foram cedidos por empresa parceira, oriundos do Inventário Florestal Contínuo (IFC), coletados em 412 parcelas, entre abril de 2019 e dezembro de 2020 (coincidente com a observação do GEDI utilizadas), representando 295 talhões, com idades variando entre dois e 6,5 anos.

No IFC, são medidos os povoamentos florestais com idade superior a dois anos, com intensidade amostral de uma parcela para cada 10 hectares. As parcelas têm formato circular e área fixa (com 12,25 m de raio), nas quais são medidos o diâmetro acima do peito (DAP, 1,30 m acima do solo) de todos os fustes com mais de 5 cm de DAP e a altura das 10 primeiras árvores da parcela. A partir dessa observação, é realizada a computação da altura média das árvores da parcela (HT), da altura dominante (HD), sendo equivalente à média de altura das cinco maiores árvores da parcela e a computação da estimativa de volume para a parcela ($m^3 ha^{-1}$), a partir de equações locais de volume.

3.2.2 Dados do sensor GEDI

Dentre os produtos GEDI disponíveis, utilizou-se o nível de processamento 2A (L2A), contendo informações de elevação do terreno, altura do topo da copa e alturas acima do solo para cada quantil de energia no *waveform* recebido pelo sensor – alturas relativas (rh). Também foram considerados os dados do nível de processamento 2B, contendo informações da estrutura

vertical. Dentre elas, estão a fração de cobertura de copa e índice de área de planta (PAI), que incorpora todos os elementos estruturais da copa (fuste, galhos e folhas), sendo calculado a partir da distribuição vertical da probabilidade de falha no dossel (*pagap_theta*), que por sua vez, é a probabilidade de a superfície do solo ser visível por plataformas do sensoriamento remoto, sendo complemento da cobertura de copa.

Os produtos em nível 2B também disponibilizam o perfil vertical da densidade de volume de área de planta (*pavd*) e a diversidade de altura de folhagem normalizada pelo índice de área de planta (*fhd_norm*), que é um índice de estrutura de dossel que descreve a heterogeneidade do perfil de folhagem.

Os dados estão disponibilizados em formato HDF5 no site da *Land Processes Distributed Active Archive Center* (LP DAAC), no qual pode-se gerar uma lista com os arquivos existentes para *download* a partir de um polígono envolvente. Para extração dos *footprints* disponibilizados em formato HDF5, foram utilizados os pacotes *hdf5r* (HOEFLING e ANNAU, 2020) e *rGEDI* (SILVA et al., 2020) e, para intersecção espacial com a área de estudo, o pacote *sf* (PEBESMA, 2018), disponíveis no aplicativo R (R CORE TEAM, 2022).

3.2.3 Dados do satélite Sentinel-1

Os dados do Sentinel-1 foram obtidos a partir do *Copernicus Open Access Hub*, repositório de imagens da ESA. Foram adquiridas imagens coincidentes com a data de observação do GEDI - seis cenas para compor o mosaico do ano de 2019 e seis cenas para compor o mosaico do ano de 2020. Utilizou-se as imagens no modo *Interferometric Wide Swath Mode* (IW), formato *Single Look Complex* (SLC), com uma faixa de imageamento de 250 km, resolução espacial de 5 m x 20 m e geometria em alcance inclinado. A Tabela 4 contém as especificações das imagens Sentinel-1 usadas.

Tabela 4. Características das imagens Sentinel-1 utilizadas.

Caraterística	Descrição
Data de aquisição	19/03/2019, 26/03/2019, 31/03/2019, 07/04/2019, 20/03/2020, 25/03/2020, 01/04/2020, 06/04/2020
Quadro-órbita	633-26404, 628-26404, 633-26506, 628-26579, 633-26579, 633-26681, 633-31756, 633-31829, 628-31829, 633-31931, 628-32004, 633-32004
Modo de Imageamento	<i>Interferometric Wide Swath - IW</i>
Tipo de Órbita	Descendente
Polarizações	VV e VH

Fonte: O autor (2023).

O pré-processamento das imagens SAR foi realizado no aplicativo *Sentinel Application Platform* (SNAP), conforme fluxo de trabalho proposto por Diniz et al. (2020), Harfenmeister

et al. (2021) e Petris et al. (2021). Primeiramente, foi feito recorte das imagens para a área de estudo. Em seguida, para atualizar os metadados da imagem com as informações de posicionamento do satélite durante a aquisição, executou-se a operação *Apply Orbit File* e o *Deburst* para retificar as emendas existentes entre os *bursts* e obter uma imagem contínua. Foi aplicado o filtro *Multilooking* seguido do operador *Lee Filter* (LEE, 1980) para reduzir o ruído *speckle*, melhorar a interpretabilidade e produzir uma imagem com o tamanho de pixel desejado. O *speckle* é um ruído multiplicativo, aleatório, que provoca efeito salpicado em imagens de radar, estando presente por conta da natureza coerente da onda de radar, o que provoca interferências construtivas e destrutivas e, portanto, áreas escuras e claras na imagem. Isso ocorre pelo fato de existirem muitos espalhadores em uma única célula da imagem (JENSEN, 2011).

Para que fosse possível a comparação de imagens de diferentes datas e para que o valor do pixel estivesse diretamente relacionado com o retroespalhamento da superfície analisada, foi realizada a calibração radiométrica, gerando os coeficientes de retroespalhamento (σ°_{VH} e σ°_{VV}). Para obtenção dos atributos da decomposição polarimétrica dos alvos (entropia e ângulo alfa), foi feito o cálculo da matriz de coerência [T2] modificado para dual-pol SAR, conforme proposto por Cloude (2007) em ferramenta disponível no SNAP.

A entropia (H) diz respeito à medida de aleatoriedade do processo de espalhamento dos alvos, apresentando valores entre 0 e 1, em que valores menores indicam que a superfície apresenta um mecanismo de espalhamento dominante, enquanto altos valores indicam que não existe processo de espalhamento definido (LEE e POTTIER, 2017). O ângulo alfa (α) varia de 0 a 90° e descreve o mecanismo de espalhamento dominante. Valores próximos a 0° indicam espalhamento volumétrico, valores próximos a 45° indicam espalhamento superficial e valores próximos a 90° indicam espalhamento *double-bounce* (LEE e POTTIER, 2017).

Por conta das variações na topografia da cena e inclinação do sensor, distâncias podem se apresentar distorcidas na imagem SAR. Para compensar essa característica e para que as representações geométricas da imagem sejam mais próximas da realidade, aplicou-se a correção do terreno *Range Doppler*.

4.2.4 Balanço hídrico climatológico

Com relação às variáveis climáticas oriundas do Terraclimate, foram utilizados os agregados mensais da temperatura mínima, máxima e precipitação no período de 01/01/1990 a 31/12/2020, a partir da qual foi possível criar a média mensal dessas variáveis para o período de 30 anos. A partir dos agregados mensais em formato matricial, foi calculada a evapotranspiração potencial como proposto por Thornthwaite (1948) e o balanço hídrico climatológico (BHC) normal proposto por Thornthwaite-Mather (1955), utilizando-se o pacote *bioclim* (SERRANO-NOTIVOLI et al., 2022) disponível no aplicativo R.

O balanço hídrico é a relação entre capacidade de armazenamento de água do solo, precipitação, evapotranspiração real (ETR) e evapotranspiração potencial (ETP). A deficiência hídrica ocorre quando a evapotranspiração é maior que a precipitação em um dado período, sendo calculado pela diferença entre ETP e ETR. Nesse trabalho, foi utilizado o somatório da deficiência hídrica anual e o somatório da precipitação anual.

Determinou-se a capacidade de armazenamento de água do solo até 200 cm em função dos seus teores de argila e areia, conforme equação desenvolvida por Stape (2002). Os teores de argila e areia foram obtidos a partir de análises de solo georreferenciadas cedidas por empresa parceira e interpoladas por meio de regressão *thin plate spline* com auxílio do pacote *fields* (NYCHKA et al., 2015), disponível no aplicativo R.

4.2.5 Atributos do terreno

Os dados do modelo digital de elevação SRTM são disponibilizados na plataforma *Earth Explorer* do Serviço Geológico dos Estados Unidos (USGS). Foi utilizada versão 3 do produto, com preenchimento de falhas global e pixel de ~30 m (FAAR et al., 2007). A partir do MDE obtido, foram calculadas a declividade, aspecto e plano de curvatura no *software* GRASS GIS (NETELER, 2012).

O aspecto indica a direção (em graus) em que a face de maior declividade está voltada. A curvatura plana é medida na direção perpendicular à máxima declividade da superfície e diz respeito à relação de convergência e divergência dos fluxos ao longo da encosta. A curvatura plana é calculada pelo ajuste da superfície à célula focal e seus vizinhos, de modo que valores negativos indicam áreas lateralmente convexas, valores positivos indicam áreas côncavas (ZEVENBERGEN e THORNE, 1987).

3.2.6 Estrutura de fusão e modelagem

A abordagem utilizada para fusão das métricas do GEDI com as estimativas do IFC foi feita utilizando uma grade regular de 1 hectare, sendo feito o pareamento das observações GEDI e IFC que estiveram contidas na mesma célula da grade e cuja diferença de medição fosse menor que 120 dias, como demonstrado na Figura 10. Silveira et al. (2019) e Silva et al. (2021) utilizaram estratégia semelhante. Só foram considerados os segmentos em que ocorrem, no mínimo, três observações do GEDI, assim como proposto por Silva et al. (2018). Os segmentos tiveram seus atributos preenchidos (união espacial) com o valor médio das estimativas do IFC (altura total, altura dominante e volume comercial), das métricas do GEDI que ocorrem dentro da respectiva fração e das variáveis SAR, BHC e atributos do terreno.

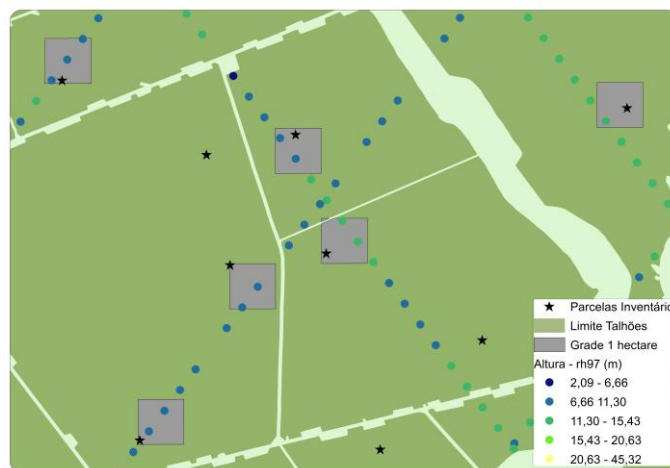


Figura 10 – Pareamento das observações GEDI com IFC em grade de regular de 1 ha. Fonte: O autor (2023).

A etapa descrita acima subsidiou a validação das métricas de altura de copa do GEDI, em que os dados foram submetidos aos testes de Barlett e de Shapiro-Wilk para verificar a homocedasticidade e a normalidade dos dados, respectivamente. Em seguida, procedeu-se ao teste de Kruskal-Wallis para testar a hipótese H_0 - as métricas de altura obtidas pelo GEDI e IFC não diferem estatisticamente entre si a 5% de probabilidade. Por fim, executou-se o teste de Wilcoxon para testar a hipótese H_0 - a diferença entre as médias das métricas de altura é igual a 0.

Foi realizada ainda, a composição temporal dos coeficientes de retroespalhamento (σ^{oVH} e σ^{oVV}) e decomposição polarimétrica (H e α) oriundos do SAR, gerando um mosaico para cada uma das variáveis. A composição temporal dos dados SAR, variáveis do BHC e do terreno foram reamostradas para possuírem a mesma extensão e resolução espacial (30 metros) e, em seguida, empilhadas formando um arquivo matricial multibanda com todas as variáveis.

A importação, tratamento, manipulação e visualização dos dados foram feitas com auxílio da coleção de pacotes *tidyverse* (WICKHAM et al., 2019). Para ajuste dos modelos de regressão, foi utilizado o algoritmo *random forest*, por ser indicado para variáveis complexas e de diferentes fontes (BREIMAN, 2001), implementado no pacote *RandomForest* (LIAW e WIENER, 2002) disponível no R. *Random forest* é uma técnica de aprendizado em conjunto desenvolvida por Breiman (2001) para melhorar o método das árvores de classificação e regressão (CART) pela combinação de um grande conjunto de árvores de decisão, tendo sido usada por cientistas florestais em estudos com dados multi-fonte do sensoriamento remoto (MUTANGA et al., 2010; DUBE e MUTANGA, 2015; REIS et al., 2019; DUNCANSON et al., 2022).

O *random forest* apresenta algumas vantagens, como o fato de poder ser usado para variáveis resposta do tipo categóricas, sendo chamado classificação, ou para variáveis resposta contínuas sendo referido como regressão (CUTLER et al., 2012). Os mesmos autores afirmaram que o *random forest* apresenta vantagens computacionais - rapidez para treinar e prever, dependência de poucos parâmetros para ajuste, erro de generalização embutido, facilidade de imple-

mentação, possibilidade de uso em problemas complexos e vantagens estatísticas – geração de medidas de importância de variáveis, classes de peso diferenciadas, atribuição a valores faltantes, possibilidade de visualização, capacidade de detecção de *outliers* e de aprendizagem não-supervisionada (CUTLER et al., 2012).

Na regressão *random forest*, cada árvore é construída usando um algoritmo determinístico que seleciona um conjunto aleatório de variáveis e uma amostra aleatória dos dados de treino. Três parâmetros são configuráveis: *ntree*, número de árvores de regressão construídas baseado em uma reamostragem com reposição (*bootstrap*) de observações (padrão de 500); *nodesize* tamanho mínimo do nó terminal das árvores (padrão = 1); e *mtry*, número de diferentes preditores testado em cada nó (padrão é 1/3 do número de variáveis) (BREIMAN e CUTLER, 2003).

Medidas de importância das variáveis preditoras são úteis para seleção das mesmas, visando redução da dimensionalidade e melhor interpretação do modelo, sendo aconselhável obter a importância de variáveis diretamente do algoritmo e reajustar o modelo com as mais importantes (CUTLER et al., 2012). No *random forest*, a importância de cada preditor é calculada pela porcentagem de aumento no erro do modelo (%IncMSE) quando se exclui tal variável da calibração, enquanto as outras permanecem imutáveis.

Para definição dos melhores parâmetros para o modelo, eles foram otimizados para encontrar a menor raiz do erro quadrático médio (RMSE), erro médio absoluto (MAE) e porcentagem da variância explicada (%var), de acordo com as Equações 1 a 3, respectivamente. Os melhores resultados foram obtidos com os seguintes parâmetros: *ntree* = 100, *nodesize* = 5, e *mtry* = 1/3 das variáveis entrada.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2} \quad (1)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |P_i - O_i| \quad (2)$$

$$\%var = \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{P})^2} \quad (3)$$

Em que: n = número de observações; O_i = volume observado no inventário florestal ($\text{m}^3 \text{ha}^{-1}$); P_i = volume estimado pelo modelo ($\text{m}^3 \text{ha}^{-1}$); e \bar{P} = média do volume estimado ($\text{m}^3 \text{ha}^{-1}$).

Na abordagem proposta, realizada em duas etapas, foi construído primeiramente um modelo para explicar a relação entre a estimativa volumétrica (variável resposta) e as métricas do GEDI (variáveis preditoras), sendo chamado de Modelo 1. Na segunda etapa, criou-se um modelo para explicar a relação entre o volume estimado pelo Modelo 1 e as variáveis preditoras do SAR (σ°_{vH} , σ°_{vV} , H e α), BHC (precipitação anual e deficiência hídrica anual) e atributos do

terreno, sendo chamado de Modelo 2. Foi criado ainda, o Modelo 3 para explicar a relação entre o volume estimado pelo Modelo 1 e somente dados de clima como variáveis preditoras.

A estimativa volumétrica foi gerada a partir da predição dos modelos, para os 1.570 talhões em que ocorreram observações do GEDI, com idades variando entre 2 e 6 anos. O Modelo 1 foi aplicado nas células da grade regular onde ocorrem observações GEDI. Os Modelos 2 e 3 foram utilizados para gerar uma estimativa volumétrica continuamente espacializada nos locais com ou sem observações do GEDI.

Para a seleção das variáveis, objetivou-se encontrar o menor número de preditores que oferecessem o maior poder de predição e melhor interpretação do modelo (MUTANGA et al., 2010). Buscou-se reduzir a dimensionalidade para evitar também a multicolinearidade (MAACK et al., 2015), de modo que variáveis que apresentassem %IncMSE menor que 3% ou índice de correlação de Pearson (r) maior que 0,6 foram excluídas do modelo final. A Tabela 5 descreve os cenários de modelagem testados.

Tabela 5. Descrição dos cenários de modelagem e variáveis independentes utilizadas.

Denominação	Variáveis independentes	Fonte das Variáveis
Modelo	utilizadas	
1	pai, pavid_0_5, tree_cover, pgap_theta, fhd_norm, Idade, Precip, Def_Umid, altitude, aspecto, plano de curvatura,	GEDI
2	declividade, $\sigma^{\circ_{VH}}$, $\sigma^{\circ_{VV}}$, H, α , Idade	BHC, Sentinel-1 e atributos do terreno
3	Precip, Def_Umidade, Idade	BHC

Em que: pai: índice de área de planta, pavid_0_05: perfil vertical da densidade de volume de área de planta de 0 a 5 metros, tree_cover: porcentagem de cobertura de árvores, pgap_theta: distribuição vertical da probabilidade de falha no dossel, fhd_norm: diversidade de altura de folhagem normalizada pelo índice de área de planta, rh97: altura acima do solo equivalente ao quantil 97, Precip: somatório da precipitação anual, Def_Umid: somatório da deficiência hídrica anual, Altitude: altitude média da célula da grade, Plan_Curv: plana de curvatura, Decliv: declividade, $\sigma^{\circ_{VH}}$: coeficientes de retroespalhamento na polarização VH, $\sigma^{\circ_{VV}}$: coeficientes de retroespalhamento na polarização VV, H: entropia oriunda da decomposição polarimétrica, α : ângulo alfa oriundo da decomposição polarimétrica. Fonte: O autor (2023).

Os dados de referência para o primeiro modelo de regressão, usado para estimar o volume a nível de segmento, foram obtidos pelo IFC, enquanto as métricas verticais do GEDI foram as variáveis independentes. Para o segundo modelo de regressão, usado para estimar o volume a nível regional, o dado de referência foi o volume predito pelo Modelo 1, enquanto os dados do SAR ($\sigma^{\circ_{VH}}$, $\sigma^{\circ_{VV}}$, H e α), BHC (precipitação anual e deficiência hídrica anual) e atributos do terreno corresponderam às variáveis independentes.

Dentre os diferentes modelos testados, foi escolhido o de melhor desempenho, a partir da avaliação da RMSE, erro médio absoluto e validação cruzada. Os dados de predição de vo-

lume a nível de segmento e a nível regional foram submetidos aos testes de Barlett e de Shapiro-Wilk para verificar a homocedasticidade e a normalidade dos dados, respectivamente. Procedeu-se então o teste de Kruskal-Wallis para testar a hipótese H_0 - as estimativas de volume obtidas com dados GEDI e IFC não diferem estatisticamente entre si a 5% de probabilidade. Os modelos também foram ajustados por meio de regressão linear e os coeficientes foram disponibilizados na seção de Resultados.

5. Resultados

5.1 Validação de métricas de altura de copa estimadas com base no GEDI

Foram adquiridas 21.940 observações do GEDI que estiveram compreendidas dentro do limite dos plantios florestais. Devido às variações de órbita da estação espacial internacional, as observações possuem diferentes datas, estando compreendidas entre abril de 2019 a setembro de 2020. A Figura 11 demonstra a distribuição espacial dos *footprints* obtidos para a área de estudo (A), o pareamento dos dados IFC e GEDI (B) e perfil de elevação contendo alturas relativas aos percentis em um transecto (C e D).

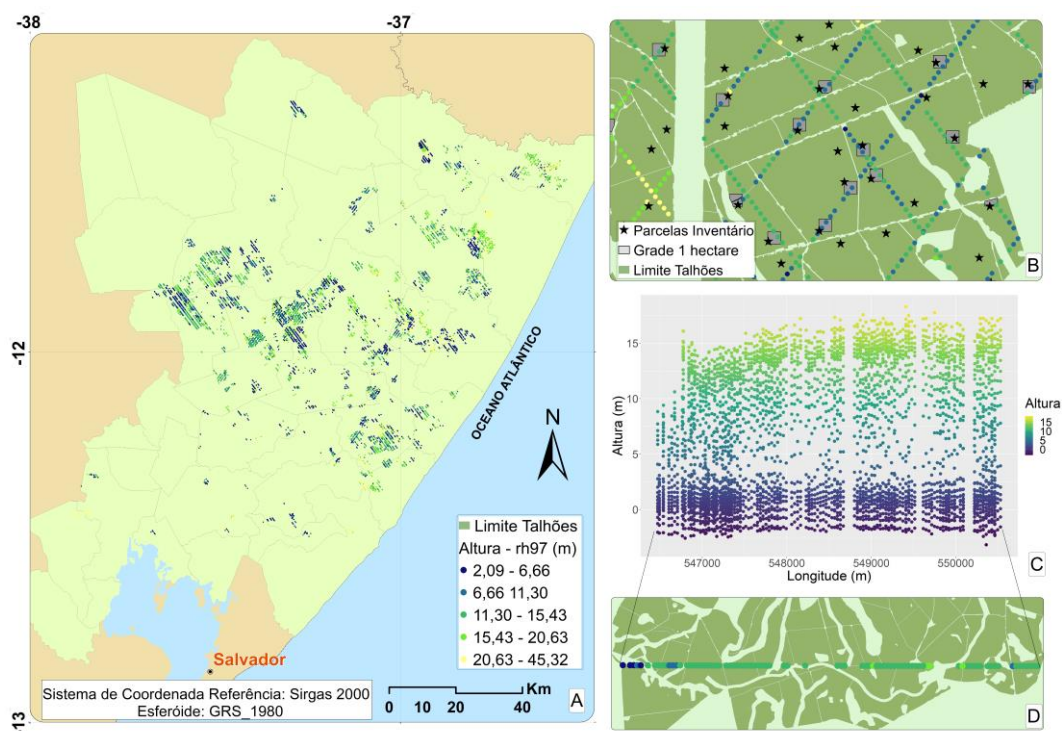


Figura 11 – *Footprints* of GEDI obtidos para área de estudo (A) e sobreposição de observações GEDI e IFC em grade de 1 ha (B) e perfil de elevação com alturas relativas em transecto (C e D). Fonte: O autor (2023).

A partir fusão das métricas do GEDI com as estimativas do IFC em grade regular de 1 ha, foram obtidas 412 observações que podem ser observadas na Figura 12.

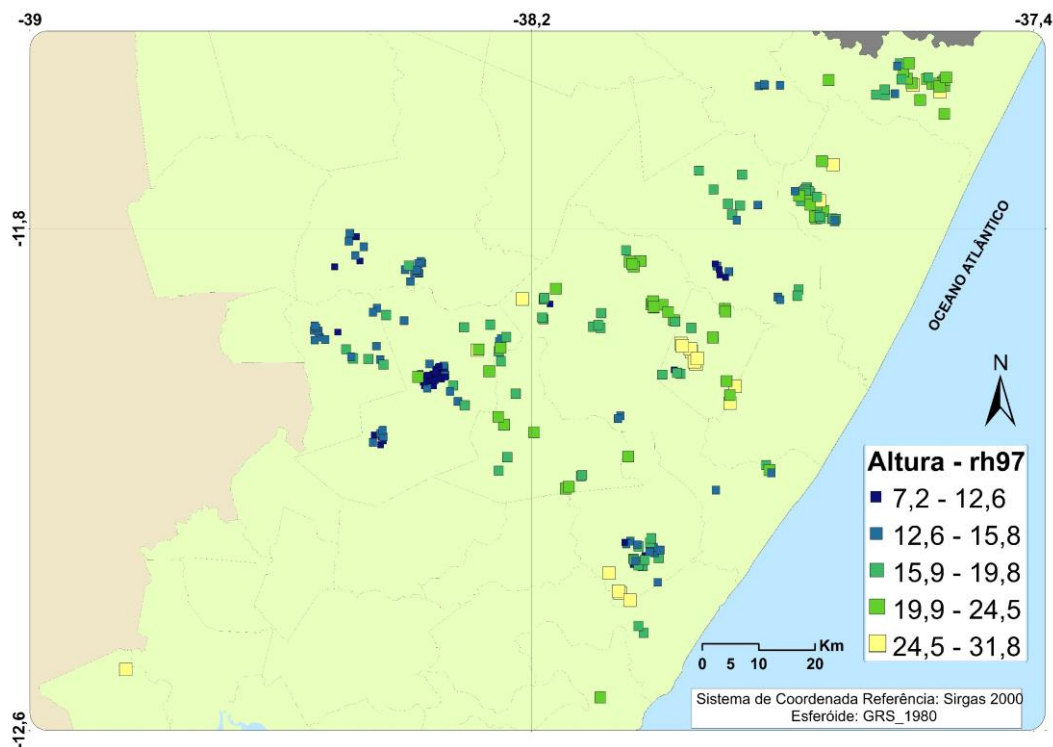


Figura 12 – Células da grade regular de 1 ha nas quais ocorreram medições GEDI e IFC. Fonte: O autor (2023).

A partir da análise do coeficiente de correlação de Pearson entre as métricas de altura obtidas pelo GEDI e aquelas oriundas do IFC, pôde-se perceber que a altura total (HT) do IFC apresentou maior correlação (0,933) com as alturas relativas aos quantis 98 e 97 (rh98 e rh97) do GEDI, enquanto a altura dominante (HD) do IFC apresentou maior correlação com a rh99 e rh98 do GEDI, - 0,935. Na Figura 13, podem-se observar as curvas de densidade, dispersão e coeficientes de correlação de Pearson entre alturas relativas GEDI e alturas do IFC.

Executando-se os testes de Barlett e de Shapiro-Wilk, observou-se a heterocedasticidade e não normalidade dos dados, respectivamente. Desse modo, procedendo-se ao teste de Kruskal-Wallis, concluiu-se que as variâncias das métricas de altura não são equivalentes, havendo diferença significativa entre as médias a 5% de probabilidade. Procedendo-se ao teste de Wilcoxon para comparação das médias, observou-se que não existe diferença significativa a 5% de probabilidade entre a HD do IFC e as alturas relativas rh100 e rh99. Altura total (HT), por sua vez, não apresentou diferenças significativas a 5% de probabilidade com a rh97, rh96 e rh95 (Tabela 6).

Tabela 6. Estatística descritiva de alturas relativas GEDI e alturas do IFC. Min = valor mínimo; Max = valor máximo; SD = desvio-padrão; CV = coeficiente de variação; médias seguidas pela mesma letra não diferem estatisticamente entre si pelo teste de Wilcoxon a 5% de probabilidade.

Métrica	Média (m)	Min (m)	Max (m)	SD (m)	CV (%)
HD	18,5 a	12,0	33,0	4,9	26,3
HT	16,7 b	10,8	29,4	4,2	25,4
rh100	19,1 a	11,5	33,9	5,2	27,1
rh99	18,1 ac	10,8	32,9	5,1	28,2
rh98	17,6 cd	10,4	32,2	5,1	28,9
rh97	17,2 bde	9,8	31,8	5,1	29,6
rh96	16,9 bef	9,3	31,5	5,1	30,2
rh95	16,6 bf	8,8	31,2	5,1	30,9
rh94	16,3 f	8,4	30,9	5,1	31,5

Em que: rhx:: alturas equivalentes ao quantis de energia, HT: altura total, HD: altura dominante. Fonte: O autor (2023).




Figura 13 – Distribuição das alturas relativas GEDI e alturas do IFC observadas na grade regular. rhx: alturas equivalentes ao quantis de energia, HT: altura total, HD: altura dominante. Fonte: O autor (2023).

Na Figura 13, pode-se visualizar a distribuição de alturas obtidas pelas duas fontes de dados. Comparando-se as alturas relativas do GEDI e sua equivalência com as alturas do IFC, melhores resultados foram encontrados para rh96 e HT, com RMSE de 1,92 m, MAE de 1,44 m e r de 0,93 e para rh99 e HD, com RMSE de 1,85 m, MAE de 1,41 m e r de 0,93 (Tabela 7).

Tabela 7. Estatísticas de comparação entre alturas relativas GEDI e alturas do IFC. RMSE: raiz do erro quadrático médio, MAE: erro médio absoluto, r: Coeficiente de correlação.

	rh96 vs HT	rh97 vs HT	rh99 vs HD	rh100 vs HD
RMSE (m)	1,92	1,98	1,85	1,95
MAE (m)	1,44	1,46	1,41	1,44
r	0,93	0,93	0,93	0,93

Em que: rhx: alturas equivalentes ao quantis de energia, HT: altura total, HD: altura dominante. Fonte: O autor (2023).




Figura 14 – Curvas de densidade (diagonal principal), dispersão (painel inferior) e correlação de Pearson (painel superior) entre alturas relativas GEDI e alturas do IFC. rh_x : alturas equivalentes ao quantil de energia, HT: altura total, HD: altura dominante, ***: Correlação significativa a 0,1%, **: Correlação significativa a 1%, *: Correlação significativa 5%, .: Correlação significativa 10% de probabilidade pelo teste t. Fonte: O autor (2023).

5.2 Modelagem dos dados

5.2.1 Modelagem volumétrica com dados GEDI

A partir da análise da correlação de Pearson entre as métricas obtidas pelo GEDI e o volume, observou-se que as variáveis que mais apresentaram similitude foram a altura relativa ao quantil 97 (rh97), a diversidade de altura de folhagem normalizada pelo índice de área de planta (fhd_norm), e a distribuição vertical da probabilidade de falha no dossel (pgap_theta), com coeficientes de correlação de 0,907, 0,824 e -0,432, respectivamente. Além disso, a idade do plantio apresentou alta correlação com o volume (0,817). Na Figura 15, pode-se observar as curvas de densidade, dispersão e coeficientes de correlação de Pearson entre métricas GEDI e volume.

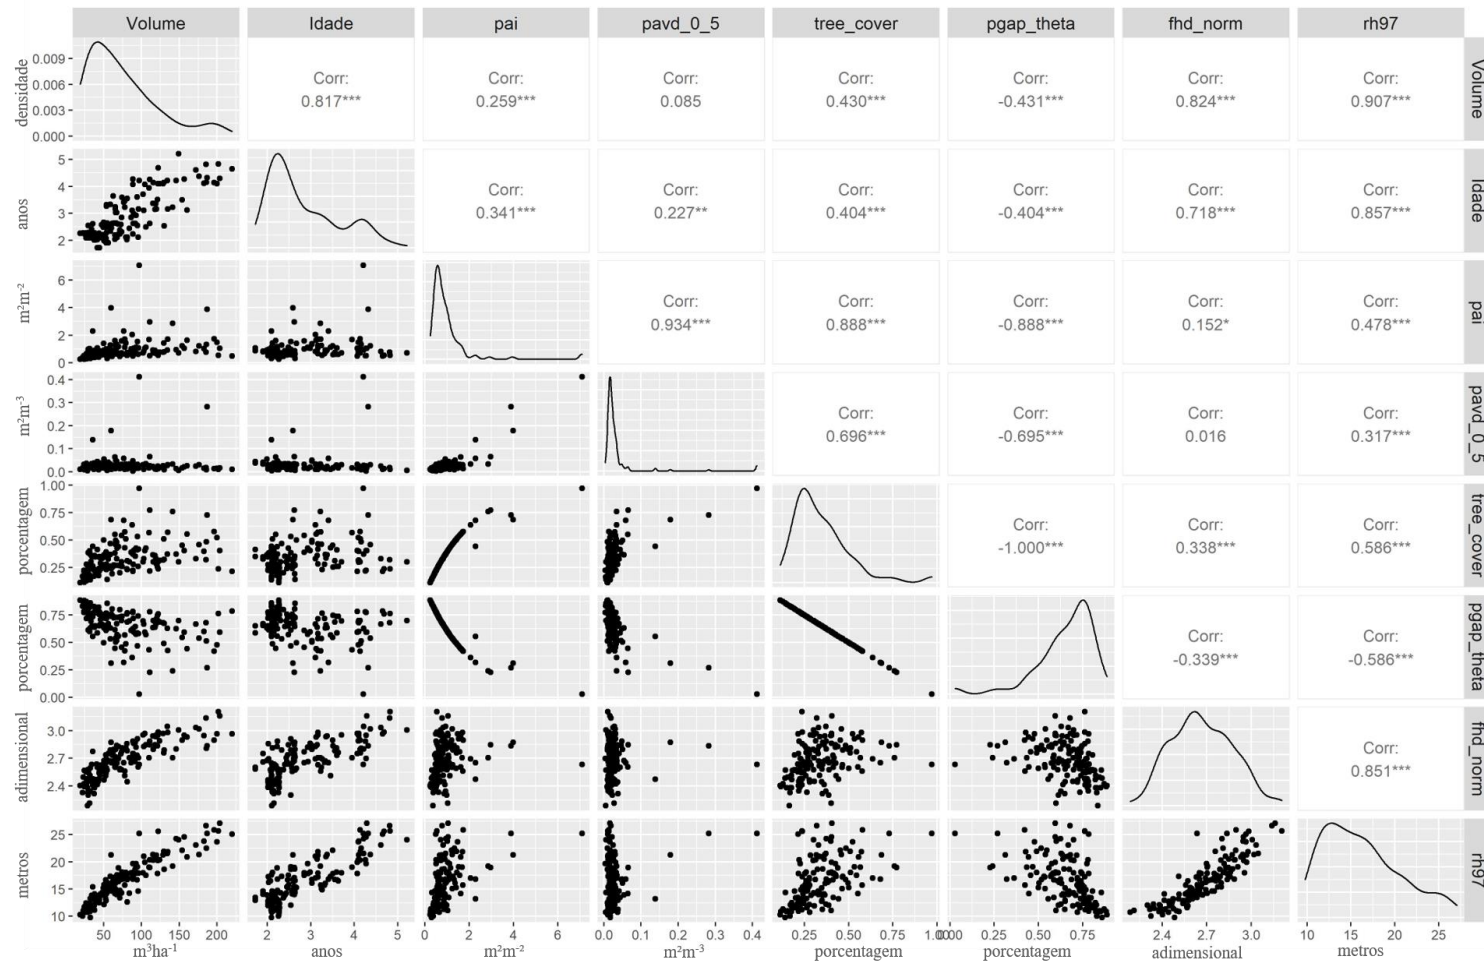


Figura 15 – Curvas de densidade (diagonal principal), dispersão (painel inferior) e correlação de Pearson (painel superior) entre métricas GEDI e volume. Em que: pai: índice de área de planta, pavd_0_05: perfil vertical da densidade de volume de área de planta de 0 a 5 metros, tree_cover: porcentagem de cobertura de árvores, pgap_theta: distribuição vertical da probabilidade de falha no dossel, fhd_norm: diversidade de altura de folhagem normalizada pelo índice de área de planta, rh97: alturas acima do solo equivalente ao quantil 97 de energia, ***: Correlação significativa a 0,1%, **: Correlação significativa a 1%, *: Correlação significativa 5%, : Correlação significativa 10% de probabilidade pelo teste t. Fonte: O autor (2023).

Para a construção do Modelo 1, os melhores resultados foram encontrados utilizando a idade, o rh97 o fhd_norm. e a pgap_theta. Na Figura 16, pode-se visualizar a classificação das variáveis com relação à importância para a acurácia do Modelo 1, sendo que, em conjunto, as variáveis explicaram 87,27% da variância. O Modelo 1 apresentou erro médio absoluto de 10,72 m³ ha⁻¹ e RMSE de 17,37 m³ ha⁻¹ (Tabela 8). Os modelos ajustados por meio de regressão linear podem ser visualizados na Tabela 9.

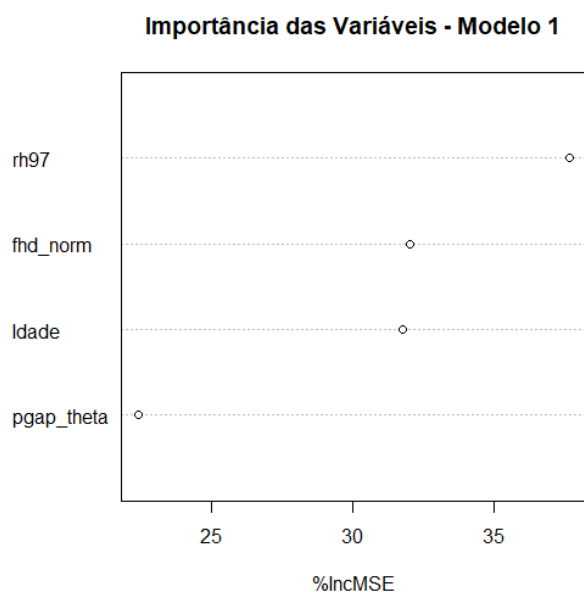


Figura 16 – Classificação por importância para acurácia do Modelo 1. Em que: %IncMSE: porcentagem de aumento no erro do modelo com exclusão da variável, rh97: alturas acima do solo equivalente ao quantil 97 de energia, pgap_theta: distribuição vertical da probabilidade de falha no dossel, fhd_norm: diversidade de altura de folhagem normalizada pelo índice de área de planta, X: longitude do centroide da célula da grade, Y: latitude do centroide da célula da grade. Fonte: O autor (2023).

Tabela 8. Resumo dos cenários de modelagem e variáveis independentes utilizadas.

Denominação Modelo	Variáveis indepen- dentes utilizadas	Fonte das Variáveis	%Var	RMSE (m ³ ha ⁻¹)	MAE (m ³ ha ⁻¹)
1	rh97, pgap_theta, fhd_norm, Idade	GEDI	87,27	17,37	10,72
2	Def_Umid, α , $\sigma^{o_{VH}}$, Idade	Sentinel-1, BHC	73,34	29,51	19,10
3	Def_Umidade, Idade	BHC	82,55	21,95	13,78

Em que: %Var: porcentagem da variância explicada, RMSE: raiz do erro quadrático médio, MAE: erro médio absoluto, rh97: alturas acima do solo equivalente ao quantil 97 de energia, pgap_theta: distribuição vertical da probabilidade de falha no dossel, fhd_norm: diversidade de altura de folhagem normalizada pelo índice de área de planta, Idade: idade do plantio, Def_Umid: deficiência hídrica anual, α : ângulo alfa oriundo da decomposição polarimétrica das imagens Sentinel-1, $\sigma^{o_{VH}}$: coeficientes de retroespalhamento da polarização VH. Fonte: O autor (2023).

Tabela 9. Resumo dos cenários de modelagem com regressão linear e variáveis independentes utilizadas.

Denominação Modelo	Modelo	Fonte das Variáveis	R ²	RMSE (m ³ ha ⁻¹)	MAE (m ³ ha ⁻¹)
1	Vol = -169,14 + 7,94rh97 + 43,15fhd_norm	GEDI	0,83	19,40	14,04
2	Vol = 0,14Def_Umid + 45,51Idade + 0,20α + 1,10σ ^{°_{VH}}	Sentinel-1, BHC	0,91	28,12	21,59
3	Vol = 0,20Def_Umidade + 42,90Idade	BHC	0,91	28,61	21,85

Em que: R²: coeficiente de determinação do modelo, RMSE: raiz do erro quadrático médio, MAE: erro médio absoluto, rh97: alturas acima do solo equivalente ao quantil 97 de energia, fhd_norm: diversidade de altura de folhagem normalizada pelo índice de área de planta, Idade: idade do plantio, Def_Umid: deficiência hídrica anual, α: ângulo alfa oriundo da decomposição polarimétrica das imagens Sentinel-1, σ^{°_{VH}}: coeficientes de retroespalhamento da polarização VH. Fonte: O autor (2023).

4.2.2 Modelagem volumétrica com dados Sentinel-1, balanço hídrico climatológico e atributos do terreno

A partir da análise da correlação entre as variáveis auxiliares a serem empregues na geração do mapa contínuo e o volume, percebeu-se que a deficiência hídrica anual, a precipitação anual, a altitude e a idade apresentaram maior correlação com a variável (0,292, 0,185, -0,124 e 0,817, respectivamente). Na Figura 19, podem-se observar as curvas de densidade, dispersão e coeficientes de correlação de Pearson entre as alturas relativas GEDI e alturas do IFC. No Apêndice A – Variáveis auxiliares, encontram-se visualizações gráficas destes elementos.

Para a construção do Modelo 2, após redução da dimensionalidade, foram utilizadas a idade do povoamento, a deficiência hídrica anual, o coeficiente de retroespalhamento σ^{°_{VH}} e o ângulo α. Na Figura 17, observa-se a classificação das variáveis com relação à importância para a acurácia do Modelo 2, sendo que em conjunto, as variáveis explicaram 73,34% da variância, com erro médio absoluto de 19,10 m³ ha⁻¹ e raiz do erro médio quadrático de 29,51 m³ ha⁻¹ (Tabela 8).




Figura 17 – Classificação por importância das variáveis para acurácia do Modelo 1, em que %IncMSE: porcentagem de aumento no erro do modelo com exclusão da variável, Def_Umid: somatório da deficiência hídrica anual, VH: coeficiente de retroespalhamento na polarização VH, A: ângulo alfa oriundo da decomposição polarimétrica Fonte: O autor (2023).

Para a construção do Modelo 3, foram utilizados somente a idade do povoamento e a deficiência hídrica anual. Na Figura 18, observa-se a classificação das variáveis com relação à importância para a acurácia do Modelo 3, sendo que em conjunto, as variáveis explicaram 82,55% da variância, com MAE de $13,78 \text{ m}^3 \text{ ha}^{-1}$ e RMSE de $21,95 \text{ m}^3 \text{ ha}^{-1}$ (Tabela 8).

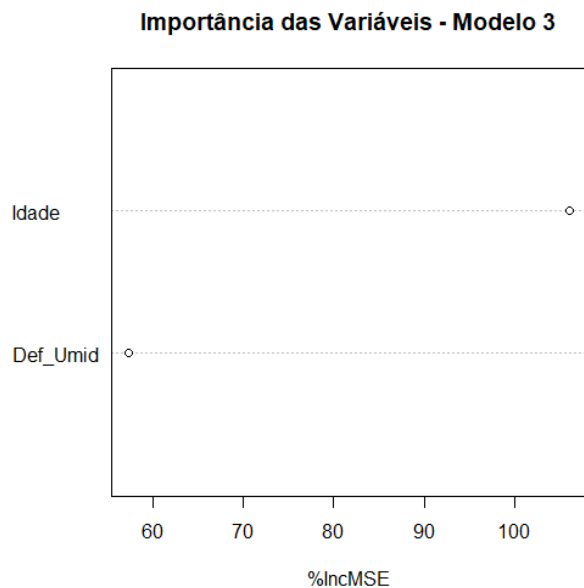


Figura 18 – Classificação por importância das variáveis para acurácia do Modelo 2, em que %IncMSE: porcentagem de aumento no erro do modelo com exclusão da variável, Def_Umid: somatório da deficiência hídrica anual. Fonte: O autor (2023).

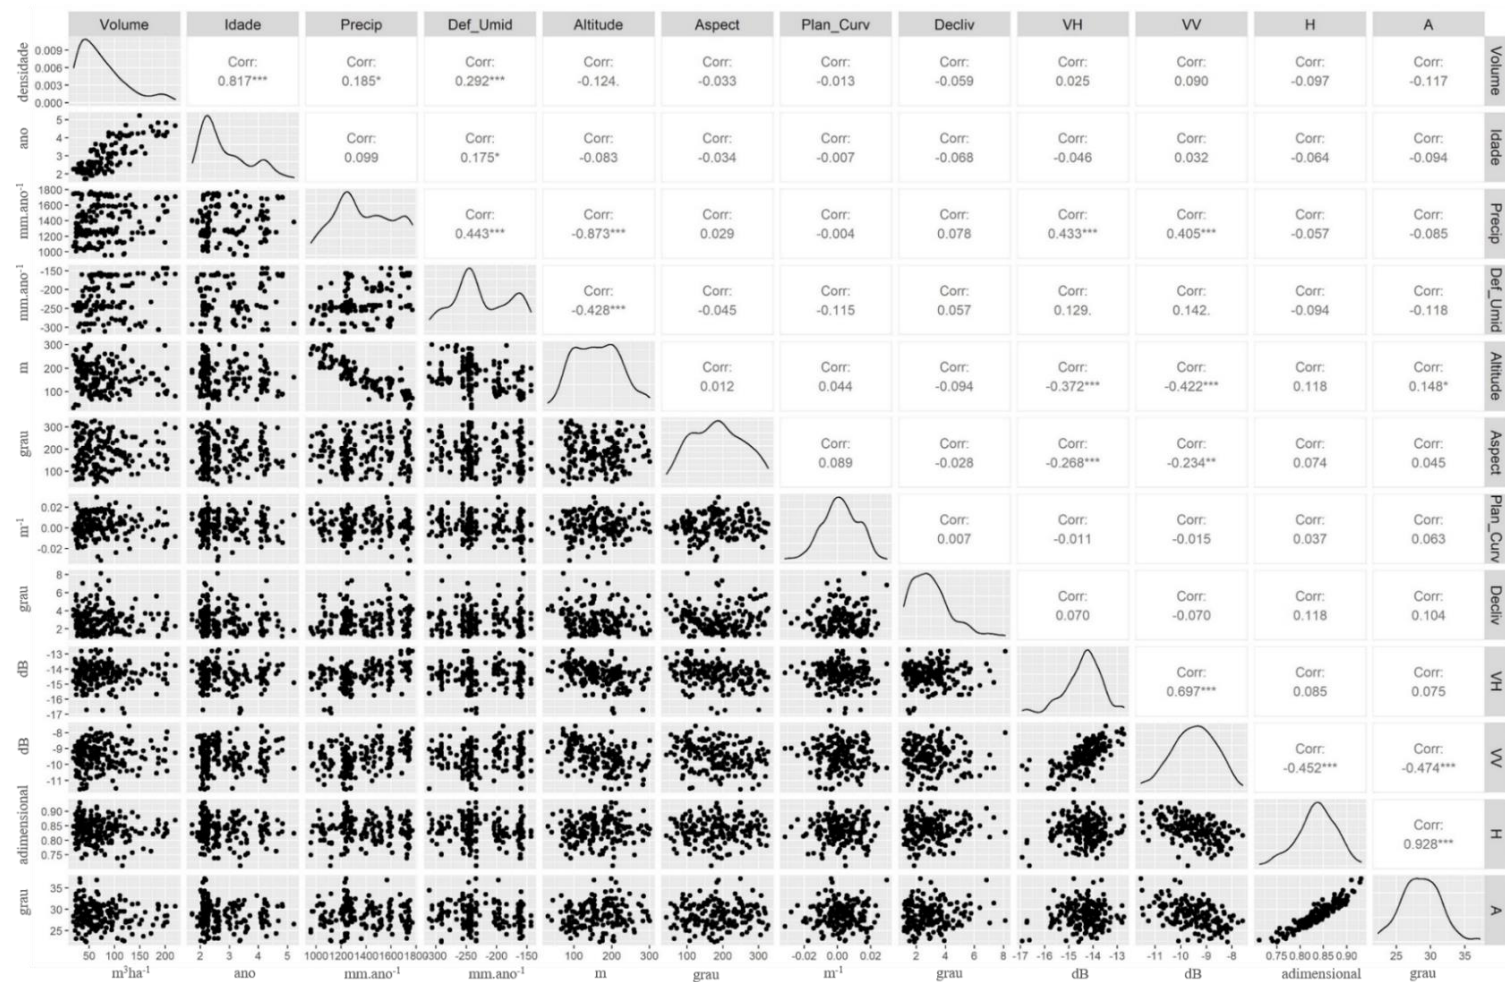


Figura 19 – Curvas de densidade (diagonal principal), dispersão (painel inferior) e correlação de Pearson (painel superior) entre as covariáveis e volume, em que Precip: somatório da precipitação anual, Def_Umid: somatório da deficiência hídrica anual, Altitude: altitude média da célula da grade, Plan_Curv: plana de curvatura, Decliv: declividade, VH: coeficientes de retroespalhamento na polarização VH, VV: coeficientes de retroespalhamento na polarização VV, H: entropia oriunda da decomposição polarimétrica, A: ângulo alfa oriundo da decomposição polarimétrica, ***, Correlação significativa a 0,1%; **, Correlação significativa a 1%; *, Correlação significativa 5%; ., Correlação significativa 10% de probabilidade pelo teste t. Fonte: O autor (2023).

5.2.3 Desempenho dos modelos

Na Figura 20, pode-se visualizar a comparação das estimativas volumétricas derivadas do IFC e predição dos Modelos 1, 2 e 3, para os dados utilizados na validação da modelagem. O Modelo 1 apresentou menor dispersão, enquanto o Modelo 2 apresentou maior dispersão. Todos os modelos tenderam a superestimar a predição para volumes menores que $100 \text{ m}^3 \text{ ha}^{-1}$ e subestimar a predição para volumes maiores que $100 \text{ m}^3 \text{ ha}^{-1}$.

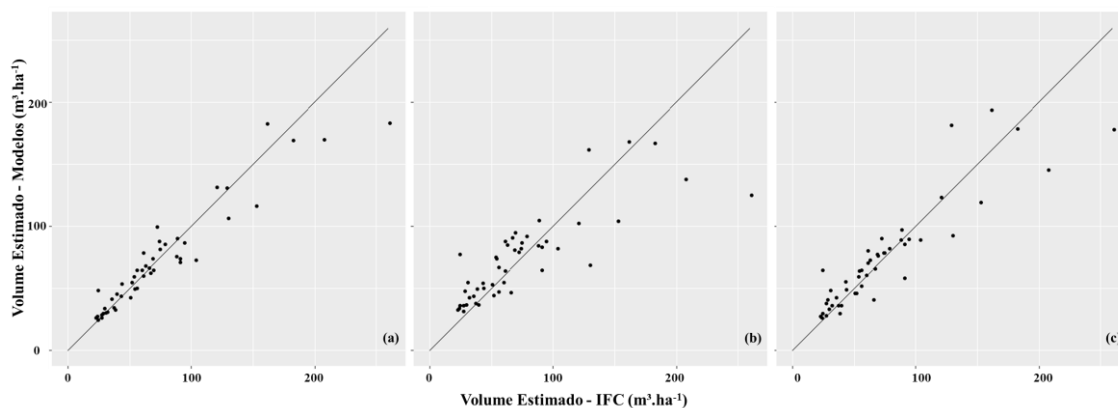


Figura 20 – Dispersão das estimativas de volume obtidas pelo IFC e pelos modelos 1(a), 2 (a) e 3 (c). Linha 1:1 fornecida para referência. Fonte: O autor (2023).

O volume estimado pelo IFC apresentou valores entre $22,9$ e $260 \text{ m}^3 \text{ ha}^{-1}$, com média de $74,21 \text{ m}^3 \text{ ha}^{-1}$. As médias de volume estimadas pelas diferentes técnicas foram próximas, apresentando entre si, diferença menor que $3,0 \text{ m}^3 \text{ ha}^{-1}$. O desvio padrão, o coeficiente de variação e a amplitude das predições dos modelos foram menores que as observadas no IFC (Tabela 10).

Na Figura 21, pode-se visualizar a distribuição das estimativas volumétricas derivadas do IFC e predição dos Modelos 1, 2 e 3, para os dados utilizados na validação da modelagem. Executando-se os testes de Barlett e de Shapiro-Wilk, observou-se a heterocedasticidade e não normalidade dos dados, respectivamente. Desse modo, procedendo-se ao teste de Kruskal-Wallis, concluiu-se que as variâncias das estimativas de volume são equivalentes, não havendo diferença significativa entre as estimativas de volume a 5% de probabilidade (Tabela 10).

Tabela 10. Estatística descritiva das estimativas volumétricas derivadas do IFC e predição do Modelo 1, Modelo 2 e Modelo 3. Min = valor mínimo; Max = valor máximo; SD = desvio-padrão; CV = coeficiente de variação; médias seguidas pela mesma letra não diferem estatisticamente entre si pelo teste de Kruskal-Wallis a 5% de probabilidade.

Fonte	Média ($\text{m}^3 \text{ ha}^{-1}$)	Min ($\text{m}^3 \text{ ha}^{-1}$)	Max ($\text{m}^3 \text{ ha}^{-1}$)	SD ($\text{m}^3 \text{ ha}^{-1}$)	CV (%)
IFC	74,1 a	22,9	260,9	50,9	68,7
Modelo 1	71,5 a	24,7	183,2	41,7	58,3
Modelo 2	74,0 a	31,8	168,1	34,8	47,0
Modelo 3	73,9 a	26,2	194,0	42,6	57,6

Fonte: O autor (2023).




Figura 21 – Distribuição estimativas volumétricas derivadas do IFC e predição do Modelo 1, Modelo 2 e Modelo 3, para os dados de validação. Em que: IFC: Inventário florestal contínuo. Fonte: O autor (2023).

5.3 Estimativas volumétricas na área de estudo

Na Figura 22, pode-se visualizar a distribuição das estimativas volumétricas derivadas da predição dos modelos e na Figura 23, os mapas de volume para os 1.570 talhões em que ocorreram observações do GEDI. Observou-se uma tendência de o Modelo 1 e o Modelo 2 apresentarem estimativas de volume maiores, sendo que o Modelo 3 apresentou distribuição de valores mais semelhante ao Modelo 1. O volume estimado com o Modelo 1 variou entre 25,9 e 191,9 $\text{m}^3 \text{ha}^{-1}$ com média de 75,6 $\text{m}^3 \text{ha}^{-1}$. O volume estimado com o Modelo 2 e o Modelo 3 variou entre 31,7 e 183,9 $\text{m}^3 \text{ha}^{-1}$ e 28,3 e 195,1 $\text{m}^3 \text{ha}^{-1}$ com média de 86,7 $\text{m}^3 \text{ha}^{-1}$ e 93,7 $\text{m}^3 \text{ha}^{-1}$, respectivamente (Tabela 11).

Tabela 11. Estatística descritiva das estimativas volumétricas derivadas da predição do Modelo 1, Modelo 2 e Modelo 3 para os 1570 talhões em que ocorreram observações do GEDI. Min = valor mínimo; Max = valor máximo; SD = desvio-padrão; CV = coeficiente de variação.

Fonte	Média ($\text{m}^3 \text{ha}^{-1}$)	Min ($\text{m}^3 \text{ha}^{-1}$)	Max ($\text{m}^3 \text{ha}^{-1}$)	SD ($\text{m}^3 \text{ha}^{-1}$)	CV (%)
Modelo 1	76,5	25,9	191,9	36,0	47,1
Modelo 2	86,7	31,7	183,9	30,5	35,2
Modelo 3	93,7	28,3	195,1	40,9	43,7

Fonte: O autor (2023).




Figura 22 – Distribuição estimativas volumétricas derivadas da predição do Modelo 1, Modelo 2 e Modelo 3, para os 1570 talhões em que ocorreram observações do GEDI. Fonte: O autor (2023).

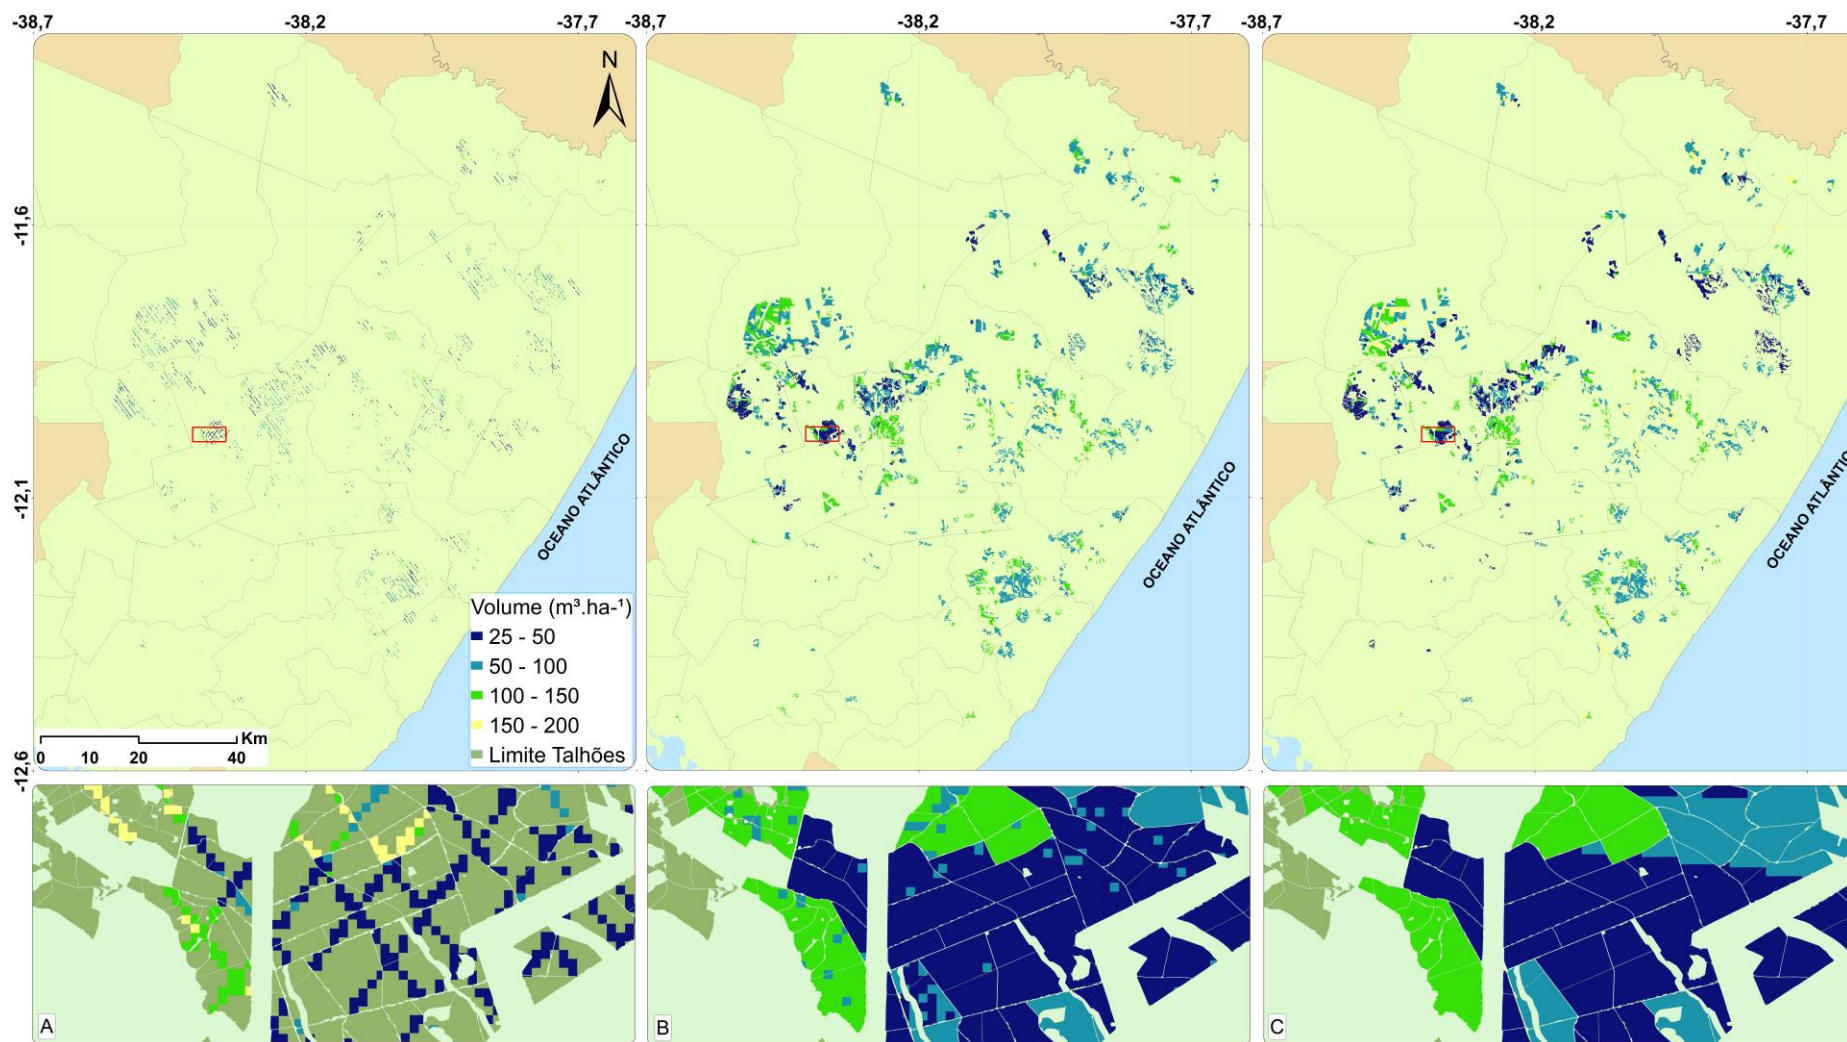


Figura 23 – Mapas de estimativa volumétrica (resolução 100m) obtidos pela predição do Modelo 1 (A), Modelo 2 (B) e Modelo 3 (C) para a área de estudo. Fonte: O autor (2023)

6. Discussão

Os resultados apresentados nesse estudo demonstram que as métricas de altura de copa oriundas do GEDI L2A fornecem uma estimativa confiável de HT e HD em plantios de eucalipto com idade superior a dois anos, podendo embasar estudos relacionados à atividade de manejo florestal.

Os níveis de acurácia encontrados nesse trabalho na fase de validação das métricas de altura GEDI são semelhantes às encontradas por Fayad et al. (2021). Os autores utilizaram as alturas relativas do GEDI para estimar HD em plantios de eucalipto em distintas regiões do Brasil, por meio de regressão linear por *stepwise*, tendo encontrado melhor acurácia ao se utilizar o rh90, rh10, rh80 e rh100, com RMSE de 1,44 m e R^2 de 0,93.

Lang et al. (2022) utilizaram dados de referência obtidos por LiDAR aerotransportado em diferentes locais da América do Norte, Europa, África e Oceania para validade métricas de altura de copa derivadas do GEDI, e encontraram um RMSE de 3,6 m e MAE de 2,1 m.

Potapov et al. (2021), comparando a altura de copas obtida por LiDAR aerotransportado em diferentes tipos de formação florestal nos EUA, Mexico, República do Congo, e Australia, com alturas de diferentes percentis do GEDI, encontraram a maior correlações entre altura do dossel e o rh95, com RMSE, MAE e r de 6,5 m, 4,2 m e 0,71, respectivamente.

Morin et al. (2022) utilizaram dados de referência obtidos por LiDAR aerotransportado em diferentes tipos de formações florestais na França para comparar com as alturas relativas aos diferentes percentis GEDI e encontram melhores equivalência entre rh95 e HD. Os autores identificaram RMSE variando de 3,7 a 5,6 m e R^2 de 0,47 a 0,65, observando que florestas de coníferas que são manejadas como estandes altos e uniformes, são mais fáceis de caracterizar e apresentam menores erros.

Potapov et al. (2021), também observaram maiores erros em formações florestais heterogêneas, como savanas e sistemas agroflorestais. Morin et al. (2022) observaram valores discrepantes na validação de alturas do GEDI, provocados por intervenções silviculturais no período entre a aquisição do dado aerotransportado e GEDI, ou pela diferença de data entre as aquisições. Nesse trabalho, tal efeito não se fez presente, já que não foram utilizados talhões que sofreram intervenções no período entre a medição IFC e GEDI, e que a diferença entre as observações foi limitada a 120 dias.

O processo de modelagem desenvolvido nesse trabalho demonstrou que as métricas de altura e estrutura vertical fornecidas pelo GEDI L2A e L2B, podem ser utilizadas com razoável confiabilidade para estimativa volumétrica em plantios de eucalipto com idade superior a dois

anos. A idade do plantio apresentou grande contribuição para aumento da assertividade dos modelos.

Esse comportamento também foi observado por Fayad et al. (2021), de modo que a idade melhorou o RMSE do modelo em ~7%, melhorando principalmente a predição em pontos discrepantes. Em situações em que a idade do plantio não é uma informação disponível, técnicas têm sido desenvolvidas para derivar tal informação utilizando dados ópticos do sensor MODIS (LE MAIRE et al., 2011) e Landsat (LI et al., 2022) e dos dados de radar do Sentinel-1 (XULU et al., 2020).

As métricas do modelo para estimativa de volume utilizando como preditor somente variáveis do GEDI (Modelo 1), foram semelhantes às encontradas por Fayad et al. (2021). Os autores testaram diferentes modelos para estimar o volume em plantios de eucalipto, em diferentes regiões do Brasil, a partir de estimativas de HD e alturas relativas obtidas com dados GEDI, tendo encontrado melhores resultados com a regressão linear *stepwise*, com RMSE de 24,39 m³ ha⁻¹ e R² de 0,90, seguido da regressão *random forest*, com RMSE de 27,48 m³ ha⁻¹ e R² de 0,88.

Com relação às variáveis utilizadas para gerar os mapas continuamente espacializados de volume, aquelas oriundas do Sentinel-1 e de atributos do terreno extraídas do MDE, apresentaram fraca correlação com a variável resposta e pouca contribuição para a assertividade dos modelos. O somatório da deficiência hídrica anual apresentou elevada importância, principalmente pelo fato de a região de estudo apresentar uma brusca variação desta variável em um curto espaço de distância.

Adrah et al. (2022) examinaram a relação entre alturas de copa oriundas do GEDI e preditores climáticos e topográficos em florestas tropicais da Malásia. Os autores identificaram que a disponibilidade hídrica (P-ETP), a temperatura média anual e gradientes de elevação foram determinantes para a altura de copa na região avaliada, fornecendo maior clareza com relação à variação desta variável na paisagem. Diversos estudos têm sido desenvolvidos para avaliar os efeitos da disponibilidade hídrica e temperatura no crescimento do eucalipto (BINKLEY et al., 2020; ROCHA et al., 2020; QUEIROZ et al., 2020).

A associação de dados do Sentinel-1 à deficiência hídrica anual e à idade proporcionou redução da assertividade do Modelo 2, quando comparado com o Modelo 3, que utilizou somente a deficiência hídrica anual associado à Idade do Plantio. Tal fato se deve à saturação dos dados SAR banda C em baixos níveis de biomassa, podendo também estar associado ao efeito de aleatoriedade presente na imagem SAR manifestado pelo *speckle*.

Nesse sentido, ao se gerar um mapa contínuo de volume por meio do Modelo 2 e Modelo 3, além de tornar o método mais moroso pelo acréscimo de dados que necessitam ser processados, houve uma diminuição da assertividade da estimativa volumétrica.

Diniz et al (2023) utilizaram dados SAR Sentinel-1 (banda C) e ALOS-2/PALSAR-2 (banda L) para estimativa de volume em plantios de eucalipto e Pinus na região sul do Brasil. Os resultados encontrados pelos autores indicaram que a associação da idade do plantio aos dados SAR banda L e banda C apresentaram melhores resultados, enquanto os dados SAR banda C isoladamente apresentaram os piores resultados em termos de RMSE e R^2 .

Morin et al. (2022) encontraram bons resultados (RMSE entre 2,7 e 3,4 m) para espacializar a estimativa de HD obtidas por observações GEDI, a partir da integração de dados Sentinel-1, Sentinel-2 e ALOS-2/PALSAR-2 em florestas manejadas da França. Nesse sentido, em investigações futuras, são recomendados, além de testes com diferentes técnicas para filtro do ruído *speckle*, avaliação de dados SAR de maiores comprimentos de onda para melhores resultados na espacialização das estimativas de volume.

JESUS et al. (2019) afirmam que SAR banda L e banda P, são os mais adequados para estudos em que se pretende estimar biomassa e atributos biofísicos em ambientes florestais ou para mapeamento do desmatamento. Os autores consideram que a textura da imagem SAR, por captar o domínio espacial da copa, é um forte aliado para estudos relacionados à idade e status de conservação da floresta. Nesse sentido, futuras missões como o NISAR (Banda L) e BIOMASS (Banda P), apresentam grande potencial para integração com os dados do GEDI.

Investigações futuras são necessárias para avaliar a capacidade de generalização dos modelos ajustados nesse trabalho para áreas com condições edafoclimáticas diferentes existentes na área de estudo. Fayad et al. (2021) consideraram que parte das incertezas na estimativa de volume está relacionada com o fato de terem calibrado um só modelo para regiões que proporcionam condições de crescimento, e conseqüentemente, estrutura de copa e relações alométricas diferentes. Os autores observaram que modelos treinados para cada região puderam melhorar o erro da estimativa em $12,8 \text{ m}^3 \text{ ha}^{-1}$ (de $24,39 \text{ m}^3 \text{ ha}^{-1}$ para $11,59 \text{ m}^3 \text{ ha}^{-1}$).

6. Conclusões

As métricas de altura obtidas pelo GEDI apresentaram acurácia semelhante aos dados do Inventário Florestal convencional, podendo ser usados para embasar estudos de rotina na atividade de manejo florestal.

A modelagem volumétrica apresentou resultados satisfatórios. O modelo que utilizou somente as métricas de altura e estrutura vertical do GEDI para estimativa volumétrica apresentou melhor acurácia que os demais.

Investigações futuras são necessárias para avaliar a capacidade de generalização dos modelos ajustados nesse trabalho para regiões desconhecidas.

Referências

- ABATZOGLOU, J. T.; DOBROWSKI, S. Z.; PARKS, S. A.; HEGEWISCH, K. C. (2018). Terraclimate, a high-resolution global dataset of monthly climate and climatic water balance from 1958-2015, **Scientific Data**, 5(1): 1-12.
- ADRAH, E.; JAAFAR, W. M. W. S.; OMAR, H.; BAJAJ, S.; LEITE, R. V. et al. (2022). NASA's GEDI Spaceborne LiDAR. **Remote Sensing**, 14(13):3172.
- ALMEIDA, A.; GONÇALVES, F.; SILVA, G.; MENDONÇA, A.; GONZAGA, M. et al. (2021). Individual tree detection and qualitative inventory of a Eucalyptus sp. stand using UAV photogrammetry data. **Remote Sensing**, 13(18), 3655.
- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. D. M.; SPAROVEK, G. (2013). Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, 22(6): 711-728.
- BAGHDADI, N.; LE MAIRE, G.; BAILLY, J. S.; OSÉ, K., NOUVELLON, Y. et al. (2014). Evaluation of ALOS/PALSAR L-band data for the estimation of Eucalyptus plantations aboveground biomass in Brazil. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, 8(8): 3802-3811.
- BALTSAVIAS, E. P. (1999). Airborne laser scanning: Basic relations and formulas. **ISPRS Journal of Photogrammetry and Remote Sensing**, 54(2-3): 199-214.
- BAUMGARTNER, R. J. (2019). Sustainable development goals and the forest sector - A complex relationship. **Forests**, 10(2): 152.
- BINKLEY, D.; CAMPOE, O. C.; ALVARES, C. A.; CARNEIRO, R. L.; STAPE, J. L. (2020). Variation in whole-rotation yield among Eucalyptus genotypes in response to water and heat stresses: The TECHS project. **Forest Ecology and Management**, 462:117953.
- BINKLEY, D.; CAMPOE, O. C.; ALVARES, C.; CARNEIRO, R. L.; CEGATTA, Í (2017). The interactions of climate, spacing and genetics on clonal Eucalyptus plantations across Brazil and Uruguay. **Forest Ecology and Management**, 405: 271-283.
- BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G.; SILVA, A. (2012). Redução dos custos em inventário de povoamentos equiâneos. **Revista Brasileira de Ciências Agrárias**, 8(1): 125-129.
- BINOTI, D. H. B.; LEITE, H. G.; CAMPOS, B. P. F.; SILVA, G. F. D.; MENDONÇA, A. R. D. (2016). Predição da altura total de árvores em diferentes espécies por meio de redes neurais artificiais. **Pesquisa Florestal Brasileira**, 36(88): 375-385.
- BISPO, P. D. C.; RODRÍGUEZ-VEIGA, P.; ZIMBRES, B.; MIRANDA, S. D. C.; CEZARE, C. H. G. et al. (2020). Woody aboveground biomass mapping of the Brazilian savanna with a multi-sensor and machine learning approach. **Remote Sensing**, 12(17): 2685.
- BOLAND, J.; AGER, T.; EDWARDS, E.; FREY, E.; JONES, P. et al. (2004). Cameras and Sensing Systems. **Manual of Photogrammetry**, 8: 581-676.
- BREIMAN, L. (2001). Random Forests. **Machine Learning**, 45(1): 5-32.

- BREIMAN, L.; CUTLER, A. (2003). **Manual—setting up, using, and understanding random forests** V4. 0. 2003. Disponível em: https://www.stat.berkeley.edu/~breiman/Using_random_forests_v4.0.pdf.
- CAMPOS, B. P. F.; SILVA, G. F. da; BINOTI, D. H. B.; MENDONÇA, A. R. de; LEITE, H. G. (2016). Predição da altura total de árvores em diferentes espécies por meio de redes neurais artificiais. **Pesquisa Florestal Brasileira**, 36(88): 375 - 385.
- CARREIRAS, J. M. B.; QUEGAN, S.; LE TOAN, T.; HO TONG, M. D.; SAATCHI, S. et al. (2017). Coverage of high biomass forests by the ESA BIOMASS mission under defense restrictions. **Remote Sensing of Environment**, 196: 154-162.
- CARVER, K.; CIMINO, J. (1988). **SAR Synthetic Aperture Radar—Earth Observing System**. NASA National Aeronautics & Space Administration. Instrument Panel Report. Vol IIf. Radar Imaging From Space.
- CHAZETTE, P.; TOTEMS, J.; HESPEL, L.; BAILLY, J. S. (2016). Principle and physics of the LiDAR measurement. In: **Optical Remote Sensing of Land Surface**, Elsevier, p. 201-247.
- CHI, H.; SUN, G.; HUANG, J.; LI, R.; REN, X.; NI, W.; FU, A. (2017). Estimation of forest aboveground biomass in Changbai Mountain region using ICESat/GLAS and Landsat/TM data. **Remote Sensing**, 9(7): 707.
- CLOUDE, S. (2007). The dual polarization entropy/alpha decomposition: A PALSAR case study. **Science and Applications of SAR Polarimetry and Polarimetric Interferometry**, v. 644, p. 2.
- CORTE, A. P. D.; BROADBENT, E. N.; SANTOS, L. H. O.; KARASINSKI, M. A.; SANQUETA, C. R.; PRATA, G. A.; ALMEIDA, D. R. A.; SILVA, C. A. (2022). **Aplicações do LiDAR para o inventário florestal - Enfoque unidade de área**. 1. ed., v. 1, 118p.
- CUTLER, A.; CUTLER, D. R.; STEVENS, J. R. (2012). **Random forests**. In: Ensemble machine learning. Springer, Boston, MA, p. 157-175.
- DINIZ, J. M. F. D. S.; GAMA, F. F.; REIS, A. A.; OLIVEIRA, C. G.; MARQUES, R. G. (2023). Estimating stem volume of Eucalyptus sp. and Pinus sp. plantations in Brazil, using Sentinel-1B and ALOS-2/PALSAR-2 data. **Journal of Applied Remote Sensing**, 17(1): 014513.
- DINIZ, J. M. F. D. S.; GAMA, F. F.; ADAMI, M. (2020). Evaluation of polarimetry and interferometry of Sentinel-1A SAR data for land use and land cover of the Brazilian Amazon region. **Geocarto International**, 37(5): 1482-1500.
- DONG, P.; CHEN, Q. (2018). **LiDAR remote sensing and applications**. Boca Raton, FL: Taylor & Francis, 210p.
- DUBAYAH, R. O.; DRAKE, J. B. (2000). Lidar remote sensing for forestry. **Journal of Forestry**, 98(6): 44-46.
- DUBAYAH, R.; BLAIR, J. B.; GOETZ, S.; FATOYINBO, L.; HANSEN, M. et al. (2020). The global ecosystem dynamics investigation: High-resolution laser ranging of the Earth's forests and topography. **Science of Remote Sensing**, 1: 100002.
- DUBE, T.; MUTANGA, O. (2015). Evaluating the utility of the medium-spatial resolution Landsat 8 multispectral sensor in quantifying aboveground biomass in uMgeni catchment, South Africa. **ISPRS Journal of Photogrammetry and Remote Sensing**, 101: 36-46.

DUBE, T.; MUTANGA, O. (2016). The impact of integrating WorldView-2 sensor and environmental variables in estimating plantation forest species aboveground biomass and carbon stocks in uMgeni Catchment, South Africa. **ISPRS Journal of Photogrammetry and Remote Sensing**, 119: 415-425.

DUNCANSON, L.; KELLNER, J. R.; ARMSTON, J.; DUBAYAH, R.; MINOR, D. M. et al. (2022). Aboveground biomass density models for NASA's Global Ecosystem Dynamics Investigation (GEDI) lidar mission. **Remote Sensing of Environment**, 270: 112845.

DUNCANSON, L.; NEUENSCHWANDER, A.; HANCOCK, S.; THOMAS, N.; FATOYINBO, T. et al. (2020). Biomass estimation from simulated GEDI, ICESat-2 and NISAR across environmental gradients in Sonoma County, California. **Remote Sensing of Environment**, 242: 111779.

Earth Explorer. (2022). FS; 083-00; Geological Survey (U.S.).

ESA. European Space Agency. (2022a). **Sentinel-1 SAR User Guide**. Disponível em: <https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-1-sar>. Acesso em: 08 jul. 2022.

ESA. European Space Agency. (2022b). **Sentinel-1 SAR User Guide**. Disponível em: https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-1/Mission_ends_for_Copernicus_Sentinel-1B_satellite. Acesso em: 08 jul. 2022.

FAO e UNEP. (2020). **The State of the World's Forests 2020**. Forests, biodiversity and people. Rome. 2020. Disponível em: <https://doi.org/10.4060/ca8642en>.

FARR, T. G.; ROSEN, P. A.; CARO, E.; CRIPPEN, R.; DUREN, R. et al. (2007). The Shuttle Radar Topography Mission. **Reviews of Geophysics**, 45: 2.

FAYAD, I.; BAGHDADI, N. N.; ALVARES, C. A.; STAPE, J. L.; BAILLY, J. S. et al. (2021). Assessment of GEDI's LiDAR data for the estimation of canopy heights and wood volume of eucalyptus plantations in Brazil. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, 14: 7095-7110.

HARFENMEISTER, K.; ITZEROTT, S.; WELTZIEN, C.; SPENGLER, D. (2021). Agricultural monitoring using polarimetric decomposition parameters of Sentinel-1 data. **Remote Sensing**, 13(4): 575.

HEALEY, S. P.; YANG, Z.; GORELICK, N.; ILYUSHCHENKO, S. (2020). Highly local model calibration with a new GEDI LiDAR asset on Google Earth Engine reduces Landsat forest height signal saturation. **Remote Sensing**, 12(17): 2840.

HOEFLING, H.; ANNAU, M. (2020). **HDF5R: Interface to the 'HDF5' Binary Data Format**. R package version 1.3.3. <https://CRAN.R-project.org/package=hdf5r>.

HUSCH, B. (1971). **Planning a forest inventory**. Forest Products Studies 17, FAO, Rome, Italy, 120 p.

IBÁ. Indústria Brasileira de Árvores. (2023). **Relatório Anual 2022**. Disponível em: <https://www.iba.org/datafiles/publicacoes/relatorios/relatorio-anual-iba2022-compactado.pdf>. Acesso em: 23 fev. 2023.

JENSEN, J. R. (2011). **Remote Sensing of the Environment. An Earth Resource Perspective**. Harlow: Person Education Limited, 2 ed. 614 p.

- JESUS, J. B. D.; KUPLICH, T. M. (2020). Applications of sar data to estimate forest biophysical variables in brazil. **Cerne**, 26:88-97
- KERSHAW Jr., J. A.; DUCEY, M. J.; BEERS, T. W.; HUSCH, B. (2017). **Forest mensuration**. Chichester; Hoboken: John Wiley & Sons, 5a ed., 632 p.
- KÖHL, M.; MAGNUSSEN, S.; MARCHETTI, M. (2006). **Sampling methods, remote sensing and GIS multiresource forest inventory**, Berlin: Springer, 2: 373.
- KOHLER, S. V.; FIGUEIREDO FILHO, A.; KOEHLER, H. S.; ARCE, J. E.; RETSLAFF, F. A. S.; SERPE, E. L. (2017). Estratégias de agrupamento de dados para modelagem hipsométrica e seus reflexos na estimativa de volume em plantios de Pinus spp. **Floresta**, 47(3): 307 - 316.
- LANG, N.; KALISCHEK, N.; ARMSTON, J.; SCHINDLER, K.; DUBAYAH, R.; WEGNER, J. D. (2022). Global canopy height regression and uncertainty estimation from GEDI LIDAR waveforms with deep ensembles. **Remote sensing of Environment**, 268: 112760.
- LEBEDYS, A. (2004). **Trends and current status of the contribution of the forestry sector to national economies**. Forest Finance: Working Paper (Electronic Resource), FAO.
- LE MAIRE, G.; MARSDEN, C.; NOUVE LLON, Y.; GRINAND, C.; HAKAMADA, R.; STAPE, J. L.; LACLAU, J. P. (2011). MODIS NDVI time-series allow the monitoring of Eucalyptus plantation biomass. **Remote Sensing of Environment**, 115(10): 2613-2625.
- LEE, J. S. (1980). Digital image enhancement and noise filtering by use of local statistics. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, 2: 165-168.
- LEE, J. S.; POTTIER, E. (2017). **Polarimetric radar imaging: from basics to applications**. CRC Press.
- LEITE, H. G.; ANDRADE, V. C. L. (2003). Importância das variáveis altura dominante e altura total em equações hipsométricas e volumétricas. **Árvore**, 27(3): 301-310.
- LI, D.; LU, D.; WU, Y.; LUO, K. (2022). Retrieval of eucalyptus planting history and stand age using random localization segmentation and continuous land-cover classification based on Landsat time-series data. **GIScience & Remote Sensing**, 59(1): 1426-1445.
- LIAW, A.; WIENER, M. (2002). Classification and regression by randomForest. **R news**, 2(3): 18-22.
- MAACK, J.; KATTENBORN, T.; FASSNACHT, F. E.; ENBLE, F.; HERNÁNDEZ, J.; CORVALÁN, P.; KOCH, B. (2015). Modeling forest biomass using very-high-resolution data—Combining textural, spectral and photogrammetric predictors derived from spaceborne stereo images. **European Journal of Remote Sensing**, 48(1): 245-261.
- MAPBIOMAS. (2020). **Coleção 6 da Série Anual de Mapas de Uso e Cobertura da Terra do Brasil**. Disponível em: <https://mapbiomas.org/>. Acesso em: 10 jul. 2022.
- MARSDEN, C.; LE MAIRE, G.; STAPE, J. L.; SEEN, D. L.; ROUPSARD, O. et al. (2010). Relating MODIS vegetation index time-series with structure, light absorption and stem production of fast-growing Eucalyptus plantations. **Forest Ecology and Management**, 259(9): 1741-1753.
- MARTELLO, M.; ALVARES, C. A.; TAVARES, T. R.; FIORIO, P. R.; CAMPOE, O. C.; CARNEIRO, R. L. (2022). Estimativa de altura de um teste clonal de Eucalyptus em diferentes idades utilizando imagens aéreas de baixa altitude. **Scientia Forestalis**, 50: 1-13.

MOHSIN, A. F. (2021). **Modelling of above ground biomass (AGB), stand volume and carbon stocks of eucalyptus plantations using WorldView-2 imagery in Sabah, Malaysia**. Tese de Doutorado, Universiti Teknologi MARA.

MORIN, D.; PLANELLS, M.; BAGHDADI, N.; BOUVET, A.; FAYAD, I. et al. (2022). Improving heterogeneous forest height maps by integrating GEDI-based forest height information in a multi-sensor mapping process. **Remote Sensing**, 14(9): 2079.

MUTANGA, O.; ADAM, E.; CHO, M. A. (2012). High density biomass estimation for wetland vegetation using WorldView-2 imagery and Random Forest regression algorithm. **International Journal of Applied Earth Observation and Geoinformation**, 18: 399-406.

NETELER, M.; BOWMAN, M. H.; LANDA, M.; METZ, M. (2012). GRASS GIS: A multi-purpose open-source GIS. **Environmental Modelling & Software**, 31: 124-130.

NISAR (2020). NASA-ISRO SAR Mission (NISAR). Disponível em: <https://nisar.jpl.nasa.gov/>. Acesso em: 08 jul. 2021.

NOU, E. A. V.; BEZERRA, L. M. M.; DANTAS, M. (1983). Geomorfologia. In: **RADAMBRASIL**, Folhas SC 24/24 ARACAJU/RECIFE. Rio de Janeiro, MME-SG.

NUTHAMMACHOT, N.; PHAIRUANG, W.; WICAKSONO, P.; SAYEKTININGSIH, T. (2018). Estimating aboveground biomass on private forest using Sentinel-2 imagery. **Journal of Sensors**, 2018: 6745629.

NYCHKA, D.; FURRER, R.; PAIGE, J.; SAIN, S.; NYCHKA, M.D. (2015) **Package 'fields'**. Disponível em: <http://cran.r-project.org/web/packages/fields/fields.pdf>.

PEBESMA, E. (2018). Simple features for R: Standardized support for spatial vector data. **The R Journal**, 10(1): 439.

PETRIS, S.; SARVIA, F.; GULLINO, M.; TARANTINO, E.; BORGOGNO-MONDINO, E. (2021). Sentinel-1 polarimetry to map apple orchard damage after a storm. **Remote Sensing**, 13(5): 1030.

POTAPOV, P.; LI, X.; HERNANDEZ-SERNA, A.; TYUKAVINA, A.; HANSEN, M.C.; KOMMAREDDY, A. (2021). Mapping global forest canopy height through integration of GEDI and Landsat data. **Remote Sensing of Environment**, 253:112165.

POTAPOV, P.; TYUKAVINA, A.; TURUBANOVA, S.; TALERO, Y.; HERNANDEZ-SERNA, A.; HANSEN, M. C.; SAAH, D.; TENNESON, K.; POORTINGA, A.; AEKAKKARARUNGROJ, A. et al. (2019). Annual continuous fields of woody vegetation structure in the Lower Mekong region from 2000–2017 Landsat time-series. **Remote Sensing of Environment**, 232: 111278.

QUEGAN, S.; LE TOAN, T.; CHAVE, J.; DALL, J.; EXBRAYAT, J. F.; MINH, D. H. T. et al. (2019) The European Space Agency BIOMASS mission: Measuring forest above-ground biomass from space. **Remote Sensing of Environment**, 227: 44-60.

QUEIROZ, T. B.; CAMPOE, O. C.; MONTES, C. R.; ALVARES, C. A.; CUARTAS, M. Z. et al. (2020). Temperature thresholds for Eucalyptus genotypes growth across tropical and subtropical ranges in South America. **Forest Ecology and Management**, 472: 118248

R Core Team (2022). **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria. Disponível em: <https://www.R-project.org/>.

REIS, A. A.; CARVALHO, M. C.; MELLO, J. M.; GOMIDE, L. R.; FERRAZ FILHO, A. C.; ACERBI JUNIOR, F. W. (2018). Spatial prediction of basal area and volume in Eucalyptus stands using Landsat TM data: An assessment of prediction methods. **New Zealand Journal of Forestry Science**, 48(1): 1-17.

REIS, A. A.; FRANKLIN, S. E.; MELLO, J. M.; ACERBI JÚNIOR, F. W. (2019). Volume estimation in a Eucalyptus plantation using multi-source remote sensing and digital terrain data: A case study in Minas Gerais State, Brazil. **International Journal of Remote Sensing**, 40(7): 2683-2702.

ROCHA, S. M. G.; VIDAURRE, G. B.; PEZZOPANE, J. E. M.; ALMEIDA, M. N. F.; CARNEIRO, R. L. et al. (2020). Influence of climatic variations on production, biomass and density of wood in eucalyptus clones of different species. **Forest Ecology and Management**, 473: 118290.

SEI. **Mapa de Pluviometria do Estado da Bahia (2003)**. In: Superintendência de Estudos Econômicos e Sociais da Bahia. Disponível em: http://www.inema.ba.gov.br/servicos/mapas-tematicos/?dl_page=2 Acesso em: 18 jul. 2021.

SERRANO-NOTIVOLI, R.; LONGARES, L. A.; CÁMARA, R. (2022). Bioclim: An R package for bioclimatic classifications via adaptive water balance. **Ecological Informatics**, 71: 101810.

SILVA, C. A.; SAATCHI, S.; GARCIA, M.; LABRIERE, N.; KLAUBERG, C. et al. (2018). Comparison of small-and large-footprint lidar characterization of tropical forest aboveground structure and biomass: a case study from Central Gabon. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, 11(10): 3512-3526.

SILVA, C. A.; HAMAMURA, C.; VALBUENA, R.; HANCOCK, S.; CARDIL, A. et al. (2020). **rGEDI: NASA's Global Ecosystem Dynamics Investigation (GEDI) data visualization and processing**. R package, <https://CRAN.R-project.org/package=rGEDI>.

SILVA, C.A.; DUNCANSON, L.; HANCOCK, S.; NEUENSCHWANDER, A.; THOMAS, N.; et al. (2021). Fusing simulated GEDI, ICESat-2 and NISAR data for regional aboveground biomass mapping. **Remote Sensing of Environment**, 253: 112234.

SILVA, V. S.; SANO, E. E.; ALMEIDA, T. D.; MESQUITA JÚNIOR, H. N. (2021). Discriminação de classes de cobertura vegetal em uma região de transição Amazônia/Cerrado no estado de Mato Grosso por meio de imagens do satélite ALOS-2/PALSAR-2. **Revista Brasileira de Cartografia**, 73.


SILVEIRA, E. M. O.; SILVA, S. H. G.; ACERBI-JUNIOR, F. W.; CARVALHO, M. C.; CARVALHO, L. M. T.; SCOLFORO, J. R. S.; WULDER, M. A. (2019). Object-based random forest modelling of aboveground forest biomass outperforms a pixel-based approach in a heterogeneous and mountain tropical environment. **International Journal of Applied Earth Observation and Geoinformation**, 78: 175-188.

SOARES, C. P. B.; PAULA NETO, F.; SOUZA, A. L. (2011). **Dendrometria e Inventário Florestal**. Viçosa; Editora UFV, 2: 272.

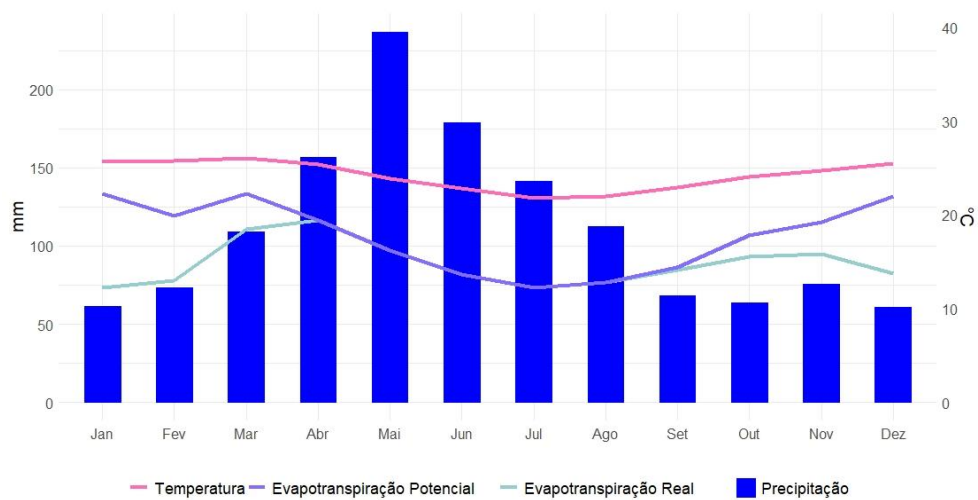
SOUZA, C. M.; SHIMBO, J. Z.; ROSA, M. R.; PARENTE, L. L.; ALENCAR, A. A. et al. (2020). Reconstructing three decades of land use and land cover changes in Brazilian biomes with Landsat archive and Earth Engine. **Remote Sensing**, 12 (17): 2737.

- SPURR, S. H. (1952-1953). Aerial photographs in forest management. **Photogrammetria**, 9: 33-41.
- STAPE, J. L. (2002). **Production ecology of clonal Eucalyptus plantations in Northeastern Brazil** (tese de doutorado), ESALQ, Piracicaba; Colorado State University, Fort Collins, EUA.
- TADDESE, H.; ASRAT, Z.; BURUD, I.; GOBAKKEN, T.; ØRKA, H. O.; DICK, Ø. B.; NÆSSET, E. (2020). Use of remotely sensed data to enhance estimation of aboveground biomass for the dry afro-montane forest in South-Central Ethiopia. **Remote Sensing**, 12(20): 3335.
- THORNTHWAITE, C. W. (1948). An approach toward a rational classification of climate. **Geographical Review**, 38(1): 55-94.
- THORNTHWAITE, C. W.; MATHER, J. R. (1955). **The water balance**. Centerton, NJ: Drexel Institute of Technology - Laboratory of Climatology, 104 p. (Publications in Climatology, vol. VIII, n.1).
- USGS. U.S. Geological Survey (2016). **Landsat—Earth observation satellites**. Fact Sheet 2015–3081, 4 p. Disponível em: <https://doi.org/10.3133/fs20153081>.
- VAN LAAR, A.; AKÇA, A. (2007). **Forest mensuration**. Springer Science & Business Media, 13: 383.
- VERMA, N. K.; LAMB, D. W.; REID, N.; WILSON, B. (2016). Comparison of canopy volume measurements of scattered Eucalypt farm trees derived from high spatial resolution imagery and LiDAR. **Remote Sensing**, 8(5): 388.
- WAKE, M.; SOUZA, C. G.; VIANA, C. D. B. V.; FERNANDES, P. B.; CORREA, P. R. S.; COSTA, V. S.; et al. (1983). **Pedologia**. In: RADAMBRASIL, Folhas SC 24/24 Aracaju/Recife. MME-SG. Rio de Janeiro.
- WICKHAM, H.; AVERICK, M.; BRYAN, J.; CHANG, W.; MCGOWAN, L. et al. (2019). Welcome to the tidyverse. **Journal of Open Source Software**, 4(43): 1686.
- XULU, S.; MBATHA, N.; PEERBHAY, K.; GEBRESLASIE, M. (2020). Detecting harvest events in plantation forest using Sentinel-1 and 2 data via Google Earth Engine. **Forests**, 11(12): 1283.
- ZEVENBERGEN, L.W.; THORNE, C.R. (1987). Quantitative analysis of land surface topography. **Earth Surface Processes and Landforms**, 12: 47–56.

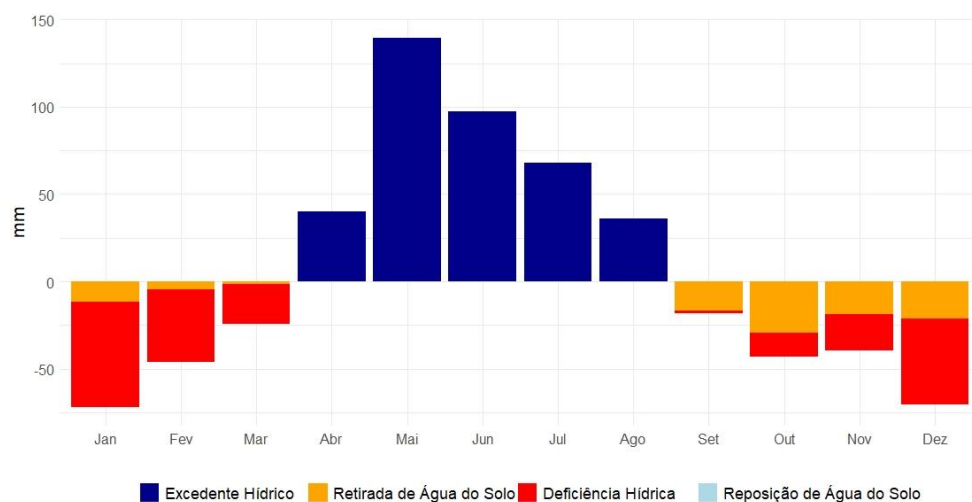
APÊNDICE A – Variáveis auxiliares



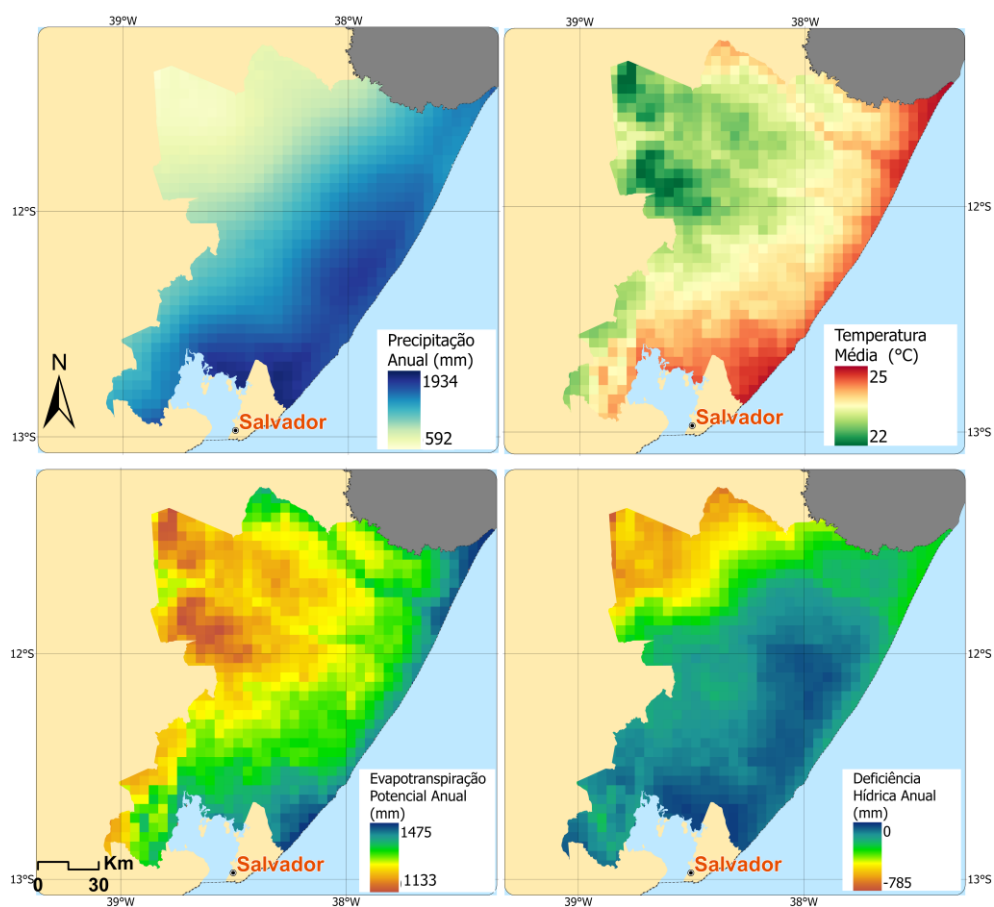
Variáveis oriundas do SAR Sentinel-1 para talhões de eucalipto. Em que: $\sigma^{\circ}VH$: coeficiente de retroespalhamento na polarização VH, $\sigma^{\circ}VV$: coeficiente de retroespalhamento na polarização VV, H: entropia oriunda da decomposição polarimétrica, α : ângulo alfa oriundo da decomposição polarimétrica. Fonte: O autor (2023).



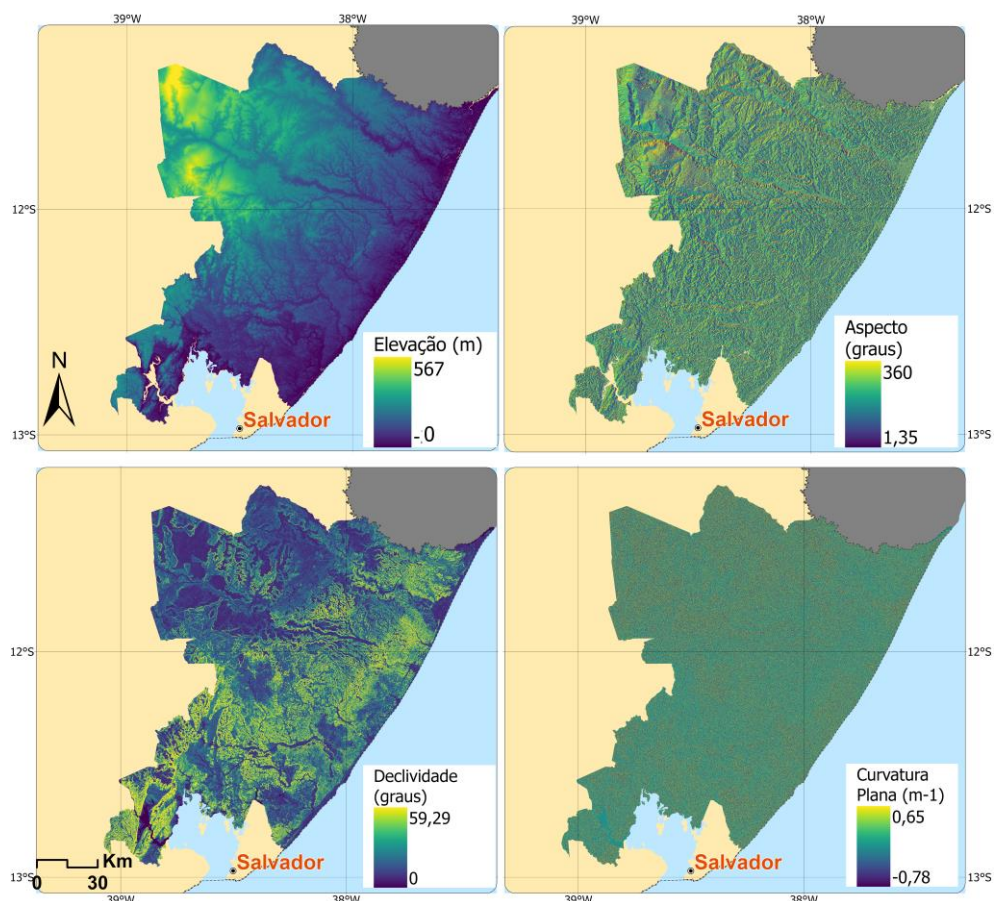
Caracterização climática da região de estudo (média de 1990 a 2020). Fonte: O autor (2023).



Balço hídrico climatológico para a região de estudo (média de 1990 a 2020). Fonte: O autor (2023).



Distribuição espacial das variáveis climáticas para a região de estudo (média de 1990 a 2020). Fonte: O autor (2023).



Distribuição espacial dos atributos do terreno para a área de estudo. Fonte: O autor (2023).