

UNIVERSIDADE FEDERAL DE SANTA MARIA  
CENTRO DE CIÊNCIAS RURAIS  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA FLORESTAL

Mateus Sabadi Schuh

**ESTIMATIVA DA BIOMASSA ACIMA DO SOLO EM FLORESTA DE  
TERRA FIRME NA AMAZÔNIA COM DADOS LIDAR  
AEROTRANSPORTADO E *UPSCALING* COM IMAGENS ORBITAIS**

Santa Maria, RS  
2023



**Mateus Sabadi Schuh**

**ESTIMATIVA DA BIOMASSA ACIMA DO SOLO EM FLORESTA DE TERRA  
FIRME NA AMAZÔNIA COM DADOS LIDAR AEROTRANSPORTADO E  
*UPSCALING* COM IMAGENS ORBITAIS**

Tese apresentada ao Curso de Doutorado do Programa de Pós-Graduação em Engenharia Florestal, área de Concentração em Manejo Florestal, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para a obtenção do grau de **Doutor em Engenharia Florestal**.

Orientador: Prof. Dr. Rudiney Soares Pereira

Santa Maria, RS  
2023

This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Finance Code 001

Schuh, Mateus

Estimativa da biomassa acima do solo em floresta de terra firme na Amazônia com dados LiDAR aerotransportado e upscaling com imagens orbitais / Mateus Schuh.- 2023.  
119 p.; 30 cm

Orientador: Rudiney Soares Pereira  
Coorientadores: Jorge Antonio de Farias, Fernando Coelho Eugenio  
Tese (doutorado) - Universidade Federal de Santa Maria, Centro de Ciências Rurais, Programa de Pós Graduação em Engenharia Florestal, RS, 2023

1. Carbono Florestal 2. Multiescala 3. Sensoriamento Remoto 4. Inteligência Artificial I. Soares Pereira, Rudiney II. Farias, Jorge Antonio de III. Coelho Eugenio, Fernando IV. Título.

Sistema de geração automática de ficha catalográfica da UFSM. Dados fornecidos pelo autor(a). Sob supervisão da Direção da Divisão de Processos Técnicos da Biblioteca Central. Bibliotecária responsável Paula Schoenfeldt Patta CRB 10/1728.

Declaro, MATEUS SCHUH, para os devidos fins e sob as penas da lei, que a pesquisa constante neste trabalho de conclusão de curso (Tese) foi por mim elaborada e que as informações necessárias objeto de consulta em literatura e outras fontes estão devidamente referenciadas. Declaro, ainda, que este trabalho ou parte dele não foi apresentado anteriormente para obtenção de qualquer outro grau acadêmico, estando ciente de que a inveracidade da presente declaração poderá resultar na anulação da titulação pela Universidade, entre outras consequências legais.

**Mateus Sabadi Schuh**

**ESTIMATIVA DA BIOMASSA ACIMA DO SOLO EM FLORESTA DE TERRA  
FIRME NA AMAZÔNIA COM DADOS LIDAR AEROTRANSPORTADO E  
UPSCALING COM IMAGENS ORBITAIS**

Tese apresentada ao Curso de Doutorado do Programa de Pós-Graduação em Engenharia Florestal, área de Concentração em Manejo Florestal, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para a obtenção do grau de **Doutor em Engenharia Florestal**.

**Aprovado em 31 de julho de 2023:**

---

**Rudiney Soares Pereira, Dr. (UFSM)**  
(Presidente/Orientador)

---

**Emanuel Araújo Silva, Dr. (UFRPE)**

---

**Franciele Francisca Marmentini Rovani, Dr<sup>a</sup>. (UFSM)**

---

**Fábio de Jesus Batista, Dr. (UFRA)**

---

**Lúcio de Paula Amaral, Dr. (UFSM)**

Santa Maria, RS  
2023



## AGRADECIMENTOS

À minha família, em especial meus pais Luiz e Marlei, pelo amor e dedicação incondicional de sempre. Agradeço pelos ensinamentos e incentivo na busca de aperfeiçoamento pessoal e intelectual;

À Gabriela, pelo amor, companheirismo, incentivo e suporte dedicados, especialmente nos momentos de dificuldade;

Ao meu orientador, Prof. Dr. Rudiney Soares Pereira, a quem dirijo respeito e admiração como profissional e ser humano. Agradeço pela oportunidade e confiança ao reabrir as portas do Laboratório de Sensoriamento Remoto, viabilizando meu ingresso e continuidade na Pós-Graduação;

Aos meus amigos e colegas de LABSERE: Alisson, Cristina, Dionatas, Edmar, Elisiane, Guilherme, Helena, Juliana, Matheus, Roberta e Rodrigo. Mesmo para os quais o tempo de convivência foi menor nesse período, agradeço pela participação direta na pesquisa ou indireta ao propiciarem um ambiente agradável e construtivo, tornando mais leve a rotina do trabalho;

Aos membros da banca examinadora, Emanuel Araújo Silva, Franciele Francisca Marmentini Rovani, Fábio de Jesus Batista e Lúcio de Paula Amaral pela disponibilidade e tempo dispendido para enriquecimento do trabalho;

À Universidade Federal de Santa Maria, ao Programa de Pós-Graduação em Engenharia Florestal, pela estrutura física e de corpo docente, componente basilar para minha formação acadêmica;

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES, pela bolsa de estudos disponibilizada;

Enfim, à todas as pessoas que de alguma forma contribuíram para a realização do trabalho.



*“Essentially, all models are wrong,  
but some are useful.”*

(BOX, 1979, p.202)

*“Understanding patterns in terms of the processes that  
produce them is the essence of science...”*

(LEVIN, 1992, p.1944)



## RESUMO

### ESTIMATIVA DA BIOMASSA ACIMA DO SOLO EM FLORESTA DE TERRA FIRME NA AMAZÔNIA COM DADOS LIDAR AEROTRANSPORTADO E *UPSCALING* COM IMAGENS ORBITAIS

AUTOR: Mateus Sabadi Schuh  
ORIENTADOR: Rudiney Soares Pereira

A alta concentração de biomassa viva estocada nas suas diferentes formações vegetais confere protagonismo à floresta amazônica nas discussões sobre ciclagem de carbono e monitoramento climático. O estudo detalhado da dinâmica do carbono florestal passa pelo aprimoramento da mensuração da biomassa estocada, uma vez que os métodos tradicionalmente empregados são onerosos e de alcance espacial limitado. Nesse sentido, o estudo abordou o desenvolvimento de um protocolo de *upscaling* que associou dados de sensor aerotransportado LiDAR (*Light Detection and Ranging*), imagens OLI/Landsat-8 e informações de campo, para modelagem e mapeamento da biomassa acima do solo (AGB) em região de Floresta Ombrófila Densa do bioma amazônico. A pesquisa foi executada considerando três abordagens: (1) Modelar via o estoque de AGB presente em parcelas inventariadas utilizando dados LiDAR e espacializar as estimativas ao longo da área de estudo (Fazenda Cauaxi, município de Paragominas/PA); (2) Realizar o mesmo procedimento utilizando como preditores dados de imagem OLI/Landsat-8; (3) Utilizar o mapa de AGB via LiDAR como referência de calibração em estimativas com imagens OLI/Landsat-8. A modelagem foi implementada utilizando o algoritmo de aprendizado de máquina *Support Vector Machine* (SVM). Dados de AGB derivados de observações a campo foram tomados como referência para validação dos modelos. Por fim, os mapas de AGB foram submetidos a um processo de análise da incerteza associada às estimativas dos pixels. Os resultados das três abordagens revelam mapas com estimativas dentro do intervalo de confiança da AGB referência, tanto no valor por hectare ( $229,6 \pm 18,2 \text{ Mg.ha}^{-1}$ ), quanto para o total da população ( $289.256,5 \pm 22.851,2 \text{ Mg}$ ). A nível de parcela, as estimativas apresentaram-se válidas pelo teste de *Wilcoxon*. O modelo LiDAR apresentou a maior correlação de *Spearman* ( $\rho=0,89$  e  $p\text{-valor}<0,0001$ ), menor RMSE ( $32,8 \text{ Mg.ha}^{-1}$ ) e menor erro padrão (14,5%), em relação aos demais. Por outro lado, a abordagem OLI/Landsat-8 apresentou fraca correlação entre os preditores derivados das imagens e a AGB nas parcelas, o que determinou o pior desempenho ( $\rho=0,13$  e  $p\text{-valor}=0,2642$ , RMSE= $87,2 \text{ Mg.ha}^{-1}$ , erro padrão=38,4%). Já o método *upscaling* trouxe ganho de performance ao combinar o mapa de AGB via LiDAR com imagens OLI/Landsat-8 na modelagem ( $\rho=0,31$  e  $p\text{-valor}=0,0699$ , RMSE= $79,2 \text{ Mg.ha}^{-1}$ , erro padrão=34,9%). A análise de incerteza revelou a dificuldade dos modelos baseados em variáveis espectrais reproduzirem toda amplitude da AGB presente na área de estudo. Mesmo com o ganho de performance, a abordagem *upscaling* apresentou incerteza média de  $108 \text{ Mg.ha}^{-1}$ . Os resultados da pesquisa reforçam o potencial emprego da combinação de sensores remotos na estimativa de atributos florestais. A calibração de modelos espectrais com mapas prévios de AGB, via dados LiDAR, pode ajudar a compensar a saturação de dados ópticos e melhorar as predições, especialmente em regiões com alta densidade de AGB e elevada complexidade estrutural, características da floresta tropical amazônica.

**Palavras-chave:** Carbono Florestal. Multiescala. Sensoriamento Remoto. Inteligência Artificial.



## ABSTRACT

### ABOVEGROUND BIOMASS ESTIMATION IN TERRA FIRME AMAZONIAN RAINFOREST WITH AIRBORNE LIDAR DATA AND UPSCALING WITH ORBITAL IMAGES

AUTHOR: Mateus Sabadi Schuh  
ADVISOR: Rudiney Soares Pereira

The high concentration of living biomass stored in its different vegetation formations gives the Amazon forest a leading role in discussions on carbon cycling and climate monitoring. The detailed study of the dynamics of forest carbon involves improving the measurement of stored biomass, since the traditionally employed methods are costly and with limited spatial range. In this sense, the study addressed the development of an upscaling protocol that associated data from an airborne LiDAR (Light Detection and Ranging) sensor, OLI/Landsat-8 images and field information, for modeling and mapping above ground biomass (AGB) in a region of Dense Ombrophylous Forest of the Amazon biome. The research was carried out considering three approaches: (1) Model via the AGB stock present in inventoried plots using LiDAR data and spatialize the estimates throughout the study area (Fazenda Cauaxi, municipality of Paragominas/PA); (2) Perform the same procedure using OLI/Landsat-8 image data as predictors; (3) Use the AGB map via LiDAR as a calibration reference in estimations with OLI/Landsat-8 images. The modeling was implemented using the Support Vector Machine (SVM) algorithm. AGB data derived from field observations were taken as reference for model validation. Finally, the AGB maps were submitted to an uncertainty analysis process associated with the pixel estimates. The results of the three approaches reveal maps with estimates within the reference AGB confidence interval, both in value per hectare ( $229,6 \pm 18,2 \text{ Mg.ha}^{-1}$ ), and for the total area ( $289.256,5 \pm 22.851,2 \text{ Mg}$ ). At the plot level, the estimates were shown to be valid by the Wilcoxon Rank Sum Test. The LiDAR model showed the highest Spearman's correlation ( $\rho=0,89$  and  $p\text{-value}<0,0001$ ), lowest RMSE ( $32,8 \text{ Mg.ha}^{-1}$ ), and lowest standard error (14,5%) compared to the others. On the other hand, the OLI/Landsat-8 approach showed a weak correlation between image-derived predictors and AGB in plots, which determined the worst performance ( $\rho=0,13$  and  $p\text{-value}=0,2642$ ,  $\text{RMSE}=87,2 \text{ Mg.ha}^{-1}$ , standard error=38,4%). The upscaling method brought performance gains by combining the AGB map via LiDAR with OLI/Landsat-8 images in the modeling ( $\rho=0,31$  and  $p\text{-value}=0,0699$ ,  $\text{RMSE}=79,2 \text{ Mg.ha}^{-1}$ , standard error=34,9%). The uncertainty analysis revealed the difficulty for models based on spectral variables to reproduce the full amplitude of the AGB present in the study area. Even with the performance gain, the upscaling approach presented an average uncertainty of  $108 \text{ Mg.ha}^{-1}$ . The research results reinforce the potential use of the combination of remote sensors in estimating forest attributes. The calibration of spectral models with previous AGB maps via LiDAR data can help compensate for the optical data saturation and improve predictions, especially in regions with high AGB density and structural complexity, characteristics of the Amazon rainforest.

**Keywords:** Forest Carbon. Multiscale. Remote sensing. Artificial Intelligence.



## LISTA DE FIGURAS

Figura 1 - Representação do espectro eletromagnético e suas faixas espectrais utilizadas por diferentes sistemas de sensoriamento remoto .....	33
Figura 2 - Janelas atmosféricas adequadas para observação terrestre a partir de plataformas orbitais, juntamente com os principais gases responsáveis pela absorção da energia eletromagnética .....	35
Figura 3 - Padrão de reflectância foliar considerando os principais fatores responsáveis pelo comportamento espectral da vegetação.....	37
Figura 4 - Classificação geral dos sistemas sensores remotos quanto à fonte e à forma de registro da radiação eletromagnética.....	38
Figura 5 - Mecanismo operacional básico de um sensor óptico para aquisição de imagens aéreas e orbitais: A) Sistema de varredura <i>Pushbroom</i> (ao longo da faixa orbital); B) Sistema de varredura <i>Whiskbroom</i> (através da faixa orbital) .....	41
Figura 6 - Representação esquemática dos componentes do sistema ALS - <i>Airborne Laser Scanning</i> .....	47
Figura 7 - Ilustração do efeito do ângulo de divergência do pulso <i>laser</i> sobre a dimensão da área iluminada na superfície terrestre ( <i>footprint</i> ) (A) e ilustração dos atributos inerentes ao processo de escaneamento <i>laser</i> aéreo (B).....	48
Figura 8 - Representação dos diferentes sistemas ALS ( <i>Airborne Laser Scanning</i> ): (A) sistema de pulsos ou de retornos discretos ( <i>discrete-return</i> ) e (B) sistema de ondas contínuas ( <i>full-waveform</i> ) .....	49
Figura 9 - Representação da área de estudo, localizada na fazenda Cauaxi, município de Paragominas, Pará.....	54
Figura 10 - Distribuição das unidades amostrais inventariadas ao longo da área de estudo da fazenda Cauaxi, município de Paragominas/PA, e sua divisão aleatória entre as classes de treinamento e validação para o processo de modelagem da AGB via dados de sensoriamento remoto.....	56
Figura 11 - Fluxograma com o método utilizado para o <i>upscaling</i> e mapeamento da biomassa acima do solo em região de Floresta Amazônica, a partir da associação entre dados de campo, nuvens de pontos LiDAR e imagens OLI/Landsat-8.....	58
Figura 12 – Representação esquemática das etapas 4 ( <i>classify_ground</i> ), 5 ( <i>grid_terrain</i> ) e 6 ( <i>normalize_height</i> ) do processamento das nuvens de pontos LiDAR por meio das ferramentas do pacote <i>lidR</i> .....	61

Figura 13 - Representação dos valores de AGB obtidos nas 85 UA inventariadas na fazenda Cauaxi, Paragominas/PA, no ano de 2014. A) Distribuição dos valores de AGB em cada UA. B) Histograma dos valores de AGB distribuídos em classes de 50 Mg.ha <sup>-1</sup> .....	70
Figura 14 - A) Espacialização da métrica de elevação média (em metros), utilizada como variável preditora no modelo de estimativa de AGB via LiDAR, B) Espacialização da AGB (em Mg.ha <sup>-1</sup> ) média das 500 iterações do modelo SVM treinado, C) Espacialização do desvio padrão associado à média de AGB (em Mg.ha <sup>-1</sup> ), Dispersão dos valores médios (D) e do desvio padrão (E) associado a AGB estimada para área de estudo .....	73
Figura 15 - A) Espacialização das variáveis preditoras selecionadas para comporem o modelo de estimativa de AGB na abordagem OLI/Landsat-8 B) Espacialização da AGB (em Mg.ha <sup>-1</sup> ) média das 500 iterações do modelo SVM treinado, C) Espacialização do desvio padrão associado à média de AGB (em Mg.ha <sup>-1</sup> ), Dispersão dos valores médios (D) e do desvio padrão (E) associado a AGB estimada para área de estudo .....	76
Figura 16 – A) Espacialização das variáveis preditoras selecionadas para comporem o modelo de estimativa de AGB na abordagem <i>Upscaling</i> , B) Espacialização da AGB (em Mg.ha <sup>-1</sup> ) média das 500 iterações do modelo SVM treinado, C) Espacialização do desvio padrão associado à média de AGB (em Mg.ha <sup>-1</sup> ), Dispersão dos valores médios (D) e do desvio padrão (E) associado a AGB estimada para área de estudo .....	79
Figura 17 - Distribuição dos valores de referência da biomassa acima do solo e seu comparativo com as estimativas pelos diferentes métodos em 24 unidades amostrais de floresta de Terra Firme na fazenda Cauaxi, Paragominas, Pará .....	81
Figura 18 – Dispersão e curvas de distribuição da biomassa referência e estimada pelos diferentes métodos nas unidades amostrais de validação em um trecho de floresta de Terra Firme na Fazenda Cauaxi, Paragominas, Pará.....	82
Figura 19 - Espacialização da incerteza associada a predição de AGB (Mg.ha <sup>-1</sup> ), pelos modelos LiDAR (A), OLI/Landsat-8 (B) e <i>Upscaling</i> (C). D) distribuição dos valores de incerteza para as três abordagens.....	87

## LISTA DE TABELAS

Tabela 1 - Características gerais da série de satélites da missão Landsat .....	43
Tabela 2 - Características das bandas espectrais dos sensores <i>Operational Land Imager</i> (OLI) e <i>Thermal Infrared Sensor</i> (TIRS) a bordo do satélite Landsat-8 .....	44
Tabela 3 – Característica das unidades de manejo florestal da fazenda Cauaxi, Paragominas/PA, sob regime de extração de impacto reduzido.....	55
Tabela 4 – Síntese sobre os dados de voo, características do sensor utilizado e os atributos das nuvens de pontos resultantes do aerolevanteamento LiDAR realizado na fazenda Cauaxi, Paragominas, Pará .....	57
Tabela 5 – Ferramentas do pacote <i>lidR</i> utilizadas nas etapas de processamento das nuvens de pontos LiDAR em linguagem de programação R.....	60
Tabela 6 – Atributos da coleção presente no catálogo da plataforma <i>Google Earth Engine - GEE</i> que fornece dados de reflectância de superfície do sensor OLI/Landsat-8 ..	62
Tabela 7 - Índices de vegetação adaptados às bandas do sensor OLI/Landsat-8 que compuseram a base de dados para modelagem da biomassa acima do solo na fazenda Cauaxi, município de Paragominas-PA .....	64
Tabela 8 – Composição das três abordagens utilizadas para modelagem da biomassa acima do solo na fazenda Cauaxi via associação entre dados de campo e de sensores remotos .....	66
Tabela 9 – Configuração dos hiperparâmetros de cada modelo de aprendizado de máquina usado na modelagem da biomassa acima do solo de um trecho de Floresta de Terra firme na fazenda Cauaxi, Paragominas, Pará, pelo algoritmo <i>Support Vector Machine</i> – SVM.....	67
Tabela 10 – Síntese dos valores da distribuição diamétrica (medição direta) e da biomassa acima do solo estimada a partir do inventário florestal realizado na fazenda Cauaxi, Paragominas/PA, no ano de 2014.....	70
Tabela 11 – Dados descritivos e estatísticos da estimativa da biomassa acima do solo, considerando a probabilidade de 95%, de um trecho de floresta de Terra Firme na fazenda Cauaxi, Paragominas, Pará, obtidos em 2014.....	71
Tabela 12 - Relação de preditores selecionados pelo teste correlação para construção do modelo de estimativa de biomassa acima do solo em um trecho de floresta de Terra Firme na Amazônia paraense, pela abordagem OLI/Landsat-8.....	74

Tabela 13 – Relação de preditores selecionados pelo teste correlação para construção do modelo de estimativa de biomassa acima do solo em um trecho de floresta de Terra Firme na Amazônia paraense, pela abordagem <i>upscaling</i> .....	77
Tabela 14 - Comparativo das estimativas de biomassa acima do solo em relação aos dados de referência para a média e o total da população em trecho de floresta de Terra Firme na Fazenda Cauaxi, Paragominas, Pará .....	80
Tabela 15 – Estatísticas de precisão nas estimativas de biomassa acima do solo pelos diferentes modelos preditivos nas unidades amostrais de validação da área de estudo, localizada em um trecho de floresta de Terra Firme na Fazenda Cauaxi, Paragominas, Pará .....	83
Tabela 16 - Síntese dos resultados em estudos similares de predição da AGB florestal com auxílio de dados de sensoriamento remoto para a mesma tipologia florestal .....	84

## LISTA DE EQUAÇÕES

Equação 1 .....	36
Equação 2 .....	47
Equação 3 .....	59
Equação 4 .....	68
Equação 5 .....	68
Equação 6 .....	68
Equação 7 .....	69



## LISTA DE ABREVIATURAS E SIGLAS

AGB	<i>Above-Ground Biomass</i>
ALS	<i>Airbourne Laser Scanner</i>
ASCII	<i>American Standard Code for Information Interchange</i>
ASPRS	<i>American Society for Photogrammetry and Remote Sensing</i>
BGB	<i>Below-ground Biomass</i>
BOA	<i>Bottom-Of-Atmosphere reflectance</i>
CO <sub>2</sub>	Dióxido de carbono
COP13	13 <sup>a</sup> Conferência das Partes das Nações Unidas
COP21	21 <sup>a</sup> Conferência das Partes das Nações Unidas
DAP	Diâmetro à altura do peito
DETER	Detecção de Desmatamento em Tempo Real
DNs	<i>Digital Numbers</i>
ECV	<i>Essential Climate Variable</i>
EIR	Exploração de Impacto Reduzido
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
ERTS 1	<i>Earth Resource Technological Satellites</i>
ESA	<i>European Space Agency</i>
ETM	<i>Enhanced Thematic Mapper</i>
ETM+	<i>Enhanced Thematic Mapper Plus</i>
GEE	<i>Google Earth Engine</i>
GEDI	<i>Global Ecosystem Dynamics Investigation</i>
GMES	<i>Global Monitoring for Environment and Security</i>
GNSS	<i>Global Navigation Satellite System</i>
GPS	<i>Global Position System</i>
IAF	Índice de Área Foliar
IBGE	Instituto Brasileiro de Geografia e Estatística
INPE	Instituto Nacional de Pesquisas Espaciais
ICESat	<i>Cloud, and land Elevation Satellite</i>
ICESat2	<i>Cloud, and land Elevation Satellite 2</i>
IFOV	<i>Instantaneous Field of View</i>
IMU	<i>Inertial Measurement Unit</i>

INS	<i>Inertial Navigation System</i>
LAS	<i>LASer file</i>
LASER	<i>Light Amplification by Stimulated Emission of Radiation</i>
LiDAR	<i>Light Detection and Ranging</i>
MDE	Modelo Digital de Elevação
MDT	Modelo Digital de Terreno
MDS	Modelos Digitais de Superfície
Mg	Megagrama ( $10^6$ gramas, equivalente a uma tonelada)
ML	<i>Machine Learning</i>
MMA	Ministério do Meio Ambiente
MODIS	<i>Moderate Resolution Imaging Spectroradiometer</i>
MRV	<i>Measurement, Reporting and Verification</i>
MSI	<i>Multispectral Instrument</i>
MSS	<i>Multispectral Scanner System</i>
NASA	<i>National Aeronautics and Space Administration</i>
ND	Nível Digital
OLCI	<i>Ocean and Land Color Instrument</i>
OLI	<i>Operational Land Imager</i>
Pixel	<i>Picture element</i>
PRODES	Programa de Cálculo do Desflorestamento da Amazônia
RADAR	<i>Radio Detection and Ranging</i>
RBV	<i>Return Beam Vidicon</i>
REDD+	<i>Reducing Emissions from Deforestation and Forest Degradation</i>
REM	Radiação Eletromagnética
RF	<i>Random Forest</i>
RMSE	<i>Root Mean Square Error</i>
SAR	<i>Synthetic Aperture Radar</i>
Syx	Erro Padrão da Estimativa
SLSTR	<i>Sea and Land Surface Temperature Radiometer</i>
SVM	<i>Support Vector Machine</i>
TIRS	<i>Thermal Infrared Sensor</i>
TLS	<i>Terrestrial Laser Scanning</i>
TM	<i>Thematic Mapper</i>

TOA	<i>Top-Of-Atmosphere</i>
TROPOMI	<i>TROPOspheric Monitoring Instrument</i>
UA	Unidade amostral
UNFCCC	<i>United Nations Framework Convention on Climate Change</i>
USGS	<i>United States Geological Survey</i>
UTM	<i>Universal Transversa de Mercator</i>
UVN	<i>Ultraviolet, Visible, Near-Infrared</i>
UVNS	<i>Ultraviolet, Visible, Near-Infrared, Short-Infrared</i>



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	25
1.1	HIPÓTESES DA PESQUISA .....	29
1.2	OBJETIVOS.....	29
<b>1.2.1</b>	<b>Objetivos específicos</b> .....	29
<b>2</b>	<b>REFERENCIAL TEÓRICO</b> .....	30
2.1	FLORESTA AMAZÔNICA .....	30
2.2	SENSORIAMENTO REMOTO.....	32
<b>2.2.1</b>	<b>Interação da REM com a atmosfera</b> .....	33
<b>2.2.2</b>	<b>Interação da REM com a vegetação</b> .....	36
<b>2.2.3</b>	<b>Sistemas Sensores</b> .....	37
<b>2.2.4</b>	<b>Sensoriamento Remoto Óptico Orbital</b> .....	39
2.2.4.1	Imageadores ópticos .....	40
2.2.4.2	Satélites Landsat.....	42
<b>2.2.5</b>	<b>Sensoriamento Remoto LiDAR</b> .....	45
2.2.5.1	Airborne Laser Scanning (ALS).....	46
2.2.5.2	Produtos derivados de levantamento ALS .....	50
2.3	MONITORAMENTO DOS ESTOQUES DE BIOMASSA VEGETAL .....	51
<b>2.3.1</b>	<b>Métodos empregados na estimativa de biomassa vegetal</b> .....	51
<b>2.3.2</b>	<b>Integração de bases e Upscaling</b> .....	52
<b>3</b>	<b>MATERIAIS E MÉTODOS</b> .....	54
3.1	ÁREA DE ESTUDO .....	54
3.2	BASE DE DADOS .....	55
3.3	MODELAGEM E UPSCALING DA AGB.....	57
<b>3.3.1</b>	<b>Pré-processamento dos dados</b> .....	59
3.3.1.1	Dados de inventário florestal.....	59
3.3.1.2	Dados LiDAR aerotransportado .....	59
3.3.1.3	Dados OLI/Landsat-8 .....	62
<b>3.3.2</b>	<b>Composição e implementação dos modelos</b> .....	66
<b>3.3.3</b>	<b>Validação e análise de incerteza</b> .....	68
<b>4</b>	<b>RESULTADOS E DISCUSSÕES</b> .....	70
4.1	INVENTÁRIO FLORESTAL – AGB REFERÊNCIA .....	70
4.2	MODELO AGB LiDAR.....	72
4.3	MODELO AGB OLI/LANDSAT-8 .....	74

4.4	MODELO AGB UPSCALING .....	77
4.5	COMPARATIVO DAS ABORDAGENS .....	80
4.5.1	Análise a nível de paisagem.....	80
4.5.2	Validação nas unidades amostrais.....	80
4.5.3	Análise da incerteza .....	86
5	CONCLUSÃO .....	89
	REFERÊNCIAS BIBLIOGRÁFICAS .....	90
	<b>APÊNDICE A - PROTOCOLO DESENVOLVIDO EM LINGUAGEM R COM AS ETAPAS DE PROCESSAMENTO DAS NUVENS DE PONTOS LIDAR .....</b>	<b>110</b>
	<b>APÊNDICE B - PROTOCOLO EM LINGUAGEM JAVASCRIPT PARA PROCESSAMENTO DE IMAGENS OLI/LANDSAT-8 NA PLATAFORMA GOOGLE EARTH ENGINE.....</b>	<b>112</b>
	<b>APÊNDICE C - PROTOCOLO DESENVOLVIDO EM LINGUAGEM R PARA MODELAGEM E MAPEAMENTO DA AGB FLORESTAL A PARTIR DA ASSOCIAÇÃO ENTRE DADOS DE CAMPO E DE SENSORES REMOTOS .....</b>	<b>115</b>
	<b>ANEXO A – PROCESSAMENTO INVENTÁRIO FLORESTAL.....</b>	<b>118</b>

## 1 INTRODUÇÃO

As florestas constituem o maior ecossistema terrestre responsável pela captura e armazenamento do carbono atmosférico (DE FREITAS et al., 2020). O processo fotossintético resulta na fixação do dióxido de carbono (CO<sub>2</sub>) nos tecidos da planta, compondo a biomassa vegetal. Compreender a dinâmica da biomassa associada a processos naturais e/ou antrópicos, é essencial para avaliar a influência das formações florestais no ciclo do carbono e, os impactos deste sobre o equilíbrio dos ecossistemas (KUMAR; MUTANGA, 2017; LEITOLD et al., 2015; LI et al., 2020; LU, 2006; NGUYEN et al., 2020; SILVA et al., 2018). A biomassa acima do solo, do inglês *Above-Ground Biomass* (AGB) concentra a maior parte do carbono imobilizado pelas árvores (RODRÍGUEZ-VEIGA et al., 2017), o que na floresta tropical amazônica representa entre 70% e 89% da Produtividade Primária Líquida<sup>1</sup> (MALHI et al., 2009).

Presente em nove países da América do Sul, a Amazônia representa um dos maiores remanescentes de floresta tropical do planeta, com aproximadamente seis milhões de km<sup>2</sup>, dos quais, 67% encontram-se em território brasileiro (SANTOS et al., 2007). O bioma amazônico é reconhecido pela vital relevância na dinâmica global do carbono estocado pelas florestas (FEARNSIDE, 2018; GLOOR et al., 2009; MOURA et al., 2020; SIST et al., 2014), fato que o coloca no centro das discussões sobre políticas de controle ao avanço do desmatamento e degradação florestal. No Brasil, entre os anos de 1985 e 2020, o bioma Amazônia perdeu 45,2 milhões de hectares de cobertura florestal (MAPBIOMAS, 2021). Ainda segundo o levantamento, 82,1% do bioma possui cobertura vegetal nativa, sendo que 62% desse total está localizado em Áreas Protegidas. Dados compilados pelo Sistema de Alerta de Desmatamento (SAD), do Instituto do Homem e Meio Ambiente da Amazônia (IMAZON, 2023), revelam que, apenas para o ano de 2022, a Amazônia Legal<sup>2</sup> brasileira registrou 10.573 km<sup>2</sup> de área desmatada.

O mecanismo REDD+ (*Reduc Emissions from Deforestation and Forest Degradation*) é um incentivo desenvolvido no âmbito da Convenção-Quadro das Nações Unidas sobre Mudança do Clima (UNFCCC - *United Nations Framework Convention on Climate Change*), que prevê a compensação financeira a países em desenvolvimento por seus resultados positivos

---

<sup>1</sup> Balanço entre o CO<sub>2</sub> absorvido pelas plantas durante a fotossíntese e a parcela liberada pelas mitocôndrias durante a respiração (CHAPIN e EVINER, 2014).

<sup>2</sup> Corresponde à área de atuação da Superintendência de Desenvolvimento da Amazônia – SUDAM, delimitada em consonância ao Art. 2º da Lei Complementar n. 124, de 03/01/2007, abrange uma área de 5.015.145,99 km<sup>2</sup>, equivalente a 58,93% do território brasileiro (IBGE, 2022).

no controle das emissões de carbono relacionadas à exploração e a degradação florestal (MMA, 2016a). Esse instrumento, formalizado durante a 13ª Conferência das Partes – COP13 (UNFCCC, 2007), vem sendo discutido e atualizado durante as convenções sobre clima e ganhou protagonismo após o “Acordo de Paris”, assinado na COP21 (UNFCCC, 2015), no qual os países membros consentiram em diminuir a emissão de gases do efeito estufa, no objetivo de conter o aumento da temperatura global (GIOSTRI; NASCIMENTO, 2016). No âmbito do REDD+, países em desenvolvimento elegíveis a receber “pagamentos por resultados”, devem passar por um processo rigoroso de avaliação, denominado Mensuração, Relato e Verificação (*Measurement, Reporting and Verification - MRV*), definido no âmbito das ações da UNFCCC, com vistas a garantia da integridade e transparência dos processos (MMA, 2017).

O Brasil possui extensas áreas de vegetação nativa e apresenta grande potencial como beneficiário dos mecanismos de compensação. Além da manutenção da floresta primária, parte do balanço positivo de carbono pode ser alcançado pela regeneração natural de florestas secundárias em terras abandonadas, que já estão crescendo em cerca de 20% das terras desmatadas na Amazônia (NUNES et al., 2020). As florestas secundárias tropicais sequestram carbono até 20 vezes mais rápido do que as florestas maduras (HEINRICH et al., 2021). Ainda assim, a mensuração dos resultados de programas REDD+ figura como desafio, pela necessidade de informações consistentes sobre a dinâmica da cobertura florestal e a estimativa do carbono estocado por unidade de área medida (MMA, 2016b).

Para Bustamante et al. (2016) e Morton (2016), o aprimoramento dos orçamentos globais de carbono está condicionado à determinação mais precisa dos impactos causados pela exploração florestal sobre a dinâmica dos estoques em ambiente tropical. Mapas de biomassa pantropicais são amplamente usados por governos e por projetos que visam reduzir o desmatamento usando compensações de carbono, mas podem conter vieses regionais significativos (MITCHARD et al., 2014).

No contexto ecológico, a AGB é referida como Variável Climática Essencial (*Essential Climate Variable - ECV*), cujos mapas, especialmente contínuos, constituem insumos importantes para diminuir as incertezas no ciclo global do carbono (DUNCANSON et al., 2021). Contudo, técnicas tradicionais para determinação da biomassa envolvem processos destrutivos, com a mobilização de equipes junto a locais muitas vezes de difícil acesso, o que torna a prática dispendiosa e viável para áreas relativamente pequenas (MUTANGA et al., 2012). Por outro lado, de acordo com Lu et al. (2014), o emprego do sensoriamento remoto na estimativa de biomassa em ambientes florestais vem atingindo papel de destaque, de modo que nas últimas três décadas, pesquisas substanciais foram conduzidas.

O mecanismo REDD+ moveu a comunidade do sensoriamento remoto no sentido de aprimorar e desenvolver produtos geoespaciais a serem empregados por países nas avaliações e no monitoramento dos recursos florestais em escalas variadas (CALDERS et al., 2020). Além do sensoriamento remoto, as demandas inerentes aos projetos de REDD+ estão intimamente ligadas ao gerenciamento de dados espaciais e a modelagem computacional (HAJEK et al., 2011). Para Calders et al. (2020), ainda há uma necessidade urgente de compreender melhor as opções e limitações de produtos e técnicas disponíveis para esse tipo de aplicação.

A plena realização do potencial do sensoriamento remoto como fonte de informações ambientais requer uma capacidade de generalização no espaço e no tempo (FOODY et al., 2003). Os desafios incluem a elaboração de mapas e análise de incertezas (DUNCANSON et al., 2019; MCROBERTS et al., 2010), aplicação de abordagens estatísticas corretas para produzir resultados de monitoramento confiáveis e a incorporação da ciência de dados nos processos de modelagem, caracterizando melhor a dinâmica das florestas tropicais vinculada às condições e perturbações ambientais (MISIUKAS et al., 2021). Além disso, conforme mencionado por Réjou-Méchain et al. (2019), as fontes de vieses espacialmente estruturados que se propagam diretamente em modelos de sensoriamento remoto precisam ser melhor diagnosticadas e contabilizadas ao extrapolar as estimativas de carbono florestal.

Escalonar a biomassa florestal partindo de medições individuais das árvores para nível de paisagem local, ou mesmo escalas maiores (por exemplo, regiões, países), depende de uma série de modelos estatísticos que podem propagar grandes erros (RÉJOU-MÉCHAIN et al., 2019). Imagens de sensoriamento remoto orbital são alternativas para analisar os padrões espaço-temporais e as tendências de mudança da biomassa florestal (LI et al., 2021). Em essência, essa técnica consiste em relacionar a refletância, os índices espectrais e a textura das imagens, com a biomassa obtida via inventário florestal e utilizar os modelos ajustados para expandir as estimativas (KELSEY; NEFF, 2014; PANDIT et al., 2018). Contudo, existem advertências ao associar parcelas de campo e imagens cobrindo grandes áreas (RÉJOU-MÉCHAIN et al., 2019). Sagang et al. (2020), mencionam que o custo de aquisição dos dados de campo, pode limitar a amostragem, o que naturalmente leva a uma calibração deficiente dos modelos de predição de AGB, o que produz estimativas distorcidas, especialmente em mosaicos complexos da vegetação.

Devido à sua capacidade de caracterizar com precisão a estrutura tridimensional da vegetação, o sistema LiDAR aerotransportado emergiu como a tecnologia referência para mapear variações de AGB de vegetação em escalas de paisagem (ADHIKARI et al., 2017; ASNER; MASCARO, 2014; JHA et al., 2020; JIANG et al., 2020; SAGANG et al., 2020).

Apesar de seus pontos fortes para resgatar a estrutura florestal detalhada, o LiDAR aerotransportado é dispendioso e cobre apenas extensões espaciais relativamente limitadas (FAGUA et al., 2019). Segundo os mesmos autores, os sistemas LiDAR embarcados em plataformas orbitais, embora disponíveis globalmente, não fornecem cobertura contínua na superfície, tampouco densas séries temporais.

No intuito de contornar a baixa sensibilidade das imagens ao retratar a amplitude de variação da AGB, Réjou-Méchain et al. (2019), recomendam uma abordagem híbrida, realizada em etapas, denominada *upscaling*. Nessa linha, existe consenso em usar dados LiDAR para fornecer mapas de AGB em escala intermediária, os quais são adotados como referência para calibrar modelos que usam imagens multiespectrais orbitais, com ampla cobertura na superfície (BACCINI; ASNER, 2013; JIANG et al., 2020; ORDWAY; ASNER, 2020; RÉJOU-MÉCHAIN et al., 2019; URBAZAEV et al., 2018). A consolidação da abordagem *upscaling* traz consigo alguns desafios a serem superados. Réjou-Méchain et al. (2019), apontam a necessidade de compreender melhor as interações entre diferentes tipos de sinais eletromagnéticos em contextos variados, por exemplo, RADAR, LiDAR e sistemas ópticos passivos, para avaliar totalmente o potencial de fusão de dados multissensores. Em paralelo, há espaço para o refinamento dos modelos estatísticos (DE ALMEIDA et al., 2019), assim como a promoção de mecanismos de calibração e validação robustos que proporcionem estimativas de erro e extrapolação confiáveis (HERNÁNDEZ-STEFANONI et al., 2020; JHA et al., 2021; PLOTON et al., 2020). Nesse sentido, a análise da propagação do erro ao longo das etapas do escalonamento assume particular relevância na elaboração de mapas de incerteza (BISPO et al., 2020; URBAZAEV et al., 2018).

Investir esforços no aprimoramento da abordagem multissensor constitui o estado da arte da aplicação do sensoriamento remoto em levantamentos de biomassa e carbono florestal, especialmente em ambientes de elevada complexidade estrutural/fisionômica como é o caso das florestas tropicais. Diante do protagonismo da floresta amazônica na dinâmica do carbono, torna-se matéria essencial o desenvolvimento de protocolos que adotem as melhores práticas ao longo da cadeia de processamento e assegurem estimativas consistentes, com incertezas quantificadas, de modo a instrumentalizar usuários nas mais diferentes esferas, tanto no meio acadêmico, quanto na sociedade civil em seus diversos arranjos institucionais.

## 1.1 HIPÓTESES DA PESQUISA

- ✓ Estimativas de AGB com imagens OLI/Landsat-8 são mais precisas quando calibradas com mapas prévios de AGB modelados via LiDAR, do que quando construídos pela associação direta aos dados amostrados à campo.
- ✓ O método de *upscaling* envolvendo dados LiDAR e OLI/Landsat-8 permite a construção de mapas de AGB precisos, capazes de retratar as irregularidades locais do mosaico da vegetação em região de floresta amazônica de terra firme.

## 1.2 OBJETIVOS

O trabalho teve como objetivo geral desenvolver um protocolo de *upscaling* que relacionou dados de campo, LiDAR aerotransportado e imagens OLI/Landsat-8, para modelagem e mapeamento da biomassa acima do solo (AGB) em área de Floresta Ombrófila Densa da Amazônia paraense.

### 1.2.1 Objetivos específicos

- ✓ Modelar, a partir de dados LiDAR, o estoque de AGB presente nas parcelas inventariadas e mapear as estimativas para toda área de estudo;
- ✓ Modelar, a partir de dados OLI/Landsat-8, o estoque de AGB presente nas parcelas inventariadas e mapear as estimativas para toda área de estudo;
- ✓ Utilizar o mapa de AGB via LiDAR como referência de calibração em estimativas com imagens OLI/Landsat-8;
- ✓ Identificar e mensurar os erros propagados ao longo da cadeia de escalonamento permitindo compor índices de incerteza vinculados aos mapas de AGB.

## 2 REFERENCIAL TEÓRICO

### 2.1 FLORESTA AMAZÔNICA

A Floresta Amazônica é considerada a maior floresta tropical do planeta, cobre aproximadamente uma área de sete milhões de km<sup>2</sup>, estendendo-se por nove países: Brasil, Colômbia, Peru, Venezuela, Equador, Bolívia, Guiana, Suriname e Guiana Francesa (SAATCHI et al., 2007). Cerca de 60% (4,2 milhões de km<sup>2</sup>) da Floresta Amazônica pertencem ao território do Brasil (SCHULMAN et al., 2007), região categorizada como Bioma Amazônia (IBGE, 2004). Essa área corresponde aproximadamente a 49,3% do território brasileiro e concentra a maior rede hidrográfica do planeta, responsável por acumular 15% do volume de água doce superficial não congelada do globo (SFB, 2019a).

O Bioma Amazônia é considerado a maior reserva de diversidade biológica do mundo, resultado da interação das variadas condições geoclimáticas predominantes na sua extensão (IBGE, 2004). A região abriga cerca de 2.500 espécies arbóreas (o que representa um terço de toda a madeira tropical do mundo) e 30 mil espécies vegetais, além de recursos não madeireiros como grandes estoques de borracha, castanha, peixe e minérios (MMA, 2021). Além disso, o bioma tem papel fundamental na dinâmica do carbono global estocado pelas florestas (FEARNSIDE, 2018; GLOOR et al., 2009; MOURA et al., 2020; SIST et al., 2014). Estimativas do Serviço Florestal Brasileiro apontam para o ano de 2015, valores de 91,7 bilhões de m<sup>3</sup> de madeira, que correspondem a 104,7 bilhões de toneladas de biomassa e 68,6 bilhões de toneladas de carbono estocados na Amazônia brasileira (SFB, 2019b).

A amazônica abrange uma grande variedade de paisagens e tipos de vegetação, que incluem formações florestais e não florestais (PERIGOLO et al., 2017). Formações florestais de biomassa relativamente densa cobrem a maior parte da região e são classificadas em duas grandes categorias: florestas de terra firme e florestas inundadas (PIRES; PRANCE, 1985). A floresta de terra firme é caracterizada pela alta densidade de biomassa acima do solo e apresenta uma estratificação complexa ao longo do perfil vertical, com indivíduos de grande porte dominando o dossel (MYSTER, 2016). Por sua vez, as florestas inundadas ocupam áreas adjacentes aos principais rios e podem ser classificadas como várzea ou igapó (PERIGOLO et al., 2017). As florestas de várzea são periodicamente inundadas por rios que carregam sedimentos ricos em argila, enquanto as florestas de igapó estão associadas a rios pobres em sedimentos (PIRES; PRANCE, 1985). Como consequência, as florestas de várzea apresentam maior fertilidade do

solo e riqueza de espécies, enquanto as florestas de igapó são menos diversificadas (JUNK et al., 2011).

A tipologia florestal predominante no bioma Amazônia é a Floresta Ombrófila Densa, caracterizada, segundo Veloso et al. (1991), por fanerófitos, lianas e epífitas em abundância e está condicionada a ocorrência de temperaturas elevadas, em média 25°C, altas precipitações, bem distribuídas durante o ano, cujo período seco varia de zero a 60 dias. Em termos de extensão, é seguida pela Floresta Ombrófila Aberta e pela Floresta Estacional Semidecidual, ligada a transição climática de úmido a seco, além da Floresta Estacional Decidual, cuja ocorrência se encontra vinculada a Neossolos Litólicos (IBGE, 2004).

Na sua estrutura horizontal, as florestas tropicais úmidas bem preservadas são mosaicos dinâmicos de manchas com diferentes históricos de perturbação natural, conhecidas como ecounidades ou “facetar” (do inglês *patch*), que correspondem a distintas trajetórias sucessionais e altura do dossel (PUIG, 2008). Ao longo do perfil vertical, essas formações podem ser divididas em três estratos principais: o estrato superior que corresponde à vegetação sucessional tardia (emergentes bem iluminados, árvores altas e lianas), o estrato médio formado por árvores de sucessão intermediária e o sub-bosque que compreende indivíduos tolerantes à sombra e jovens emergentes (LAFRANKIE et al., 2006; SMITH et al., 2019). Por outro lado, as florestas degradadas e em estágios iniciais de sucessão não apresentam uma estrutura vertical complexa (HADI et al., 2017).

Do ponto de vista ecológico, Lapola et al. (2023), retratam a floresta amazônica como um *hotspot* de biodiversidade ameaçado pela contínua degradação e conversão de terras em diferentes padrões de uso e cobertura. Conversão em pastagens e áreas de cultivo, abertura de estradas, incêndios, extração de madeira e minério têm sido historicamente as principais causas do desmatamento nessa região (SOLAR et al., 2016). Segundo dados do sistema de Detecção de Desmatamento em Tempo Real – DETER (INPE, 2023), para o ano de 2023<sup>3</sup>, na Amazônia legal foram registrados 9.593 avisos de desmatamento, que correspondem a 2.648,72 km<sup>2</sup> de áreas perturbadas, especialmente por incêndio florestal, corte raso, exploração seletiva e mineração. Já pelo Programa de Cálculo do Desflorestamento da Amazônia – PRODES, em 2022 foram registrados 11.568 km<sup>2</sup> de área desmatada, dos quais o estado do Pará representa 36%, com 4.141 Km<sup>2</sup> (INPE, 2022).

A região amazônica apresenta fragilidades socioambientais, com baixos índices socioeconômicos, baixa densidade demográfica e crescente urbanização MMA (2021). O local

---

<sup>3</sup> Dados consolidados disponíveis para o intervalo de 01/01/2023 a 30/06/2023.

ainda abriga expressivo conjunto de povos indígenas e populações tradicionais, o que demanda a implantação de políticas de apoio ao desenvolvimento humano (IBGE, 2004). Ademais, de toda a biomassa estimada para a região amazônica (73 bilhões de toneladas de carbono), 58% encontram-se dentro de territórios indígenas e áreas protegidas (WALKER et al., 2020), o que reforça a importância estratégica dessas unidades sob proteção.

## 2.2 SENSORIAMENTO REMOTO

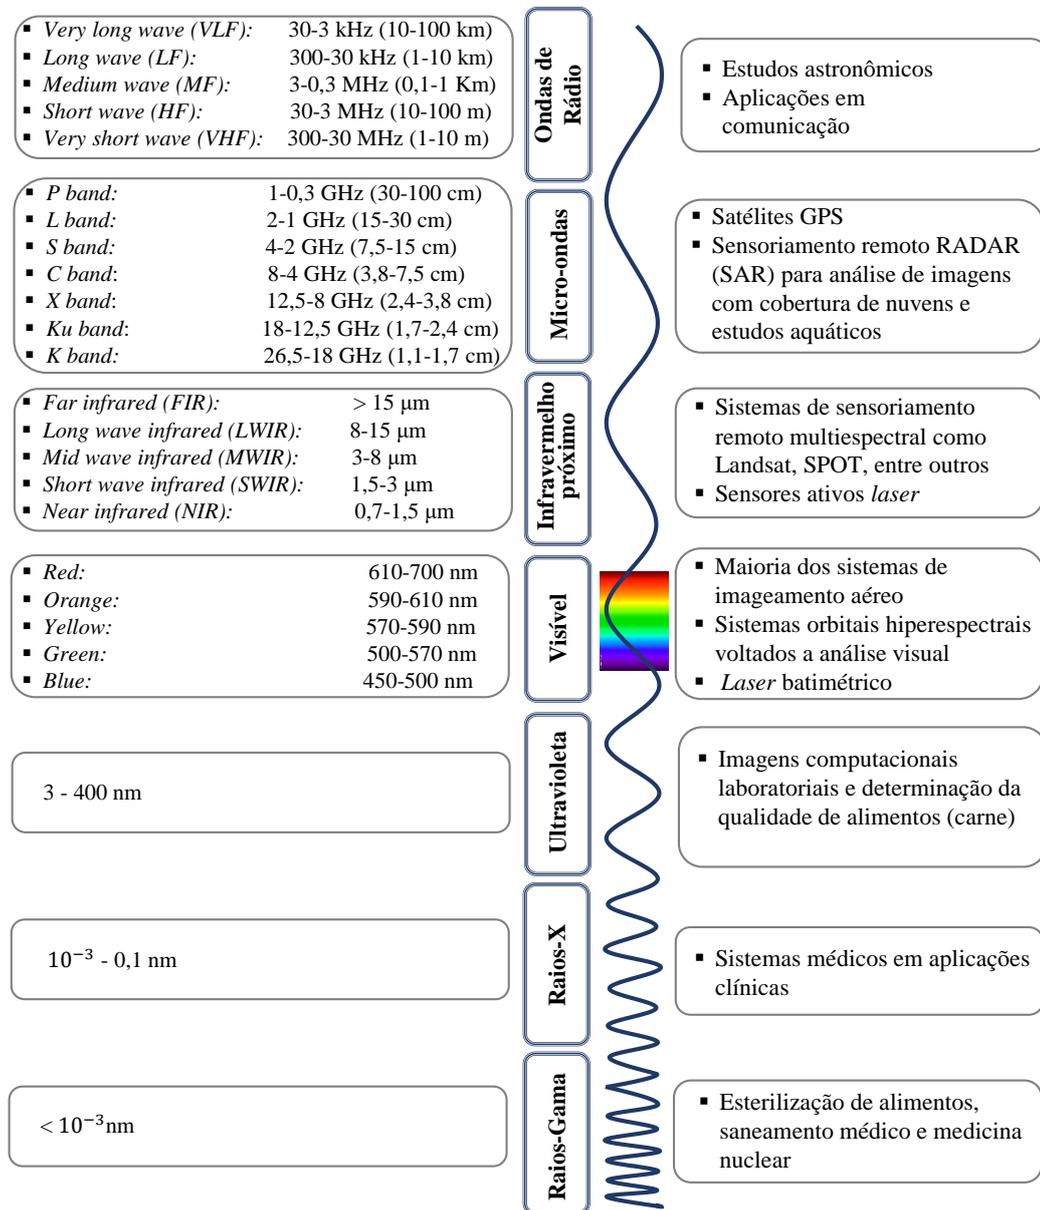
Ao observarem a natureza, cientistas testam suas hipóteses por meio da coleta de dados diretamente a campo (coleta *in situ*), ou à alguma distância dos alvos, abordagem comumente referida como sensoriamento remoto do ambiente (JENSEN, 2016). Nesse sentido, o sensoriamento remoto é definido como a aquisição de informações sobre um objeto sem estar em contato físico com ele (ELACHI; ZYL, 2006; JENSEN, 2009; PONZONI; SHIMABUKURO, 2009). Tais informações podem incluir a observação de perturbações que determinado objeto imprime aos campos de força que o circundam, sejam eles eletromagnéticos, acústicos ou potenciais elétricos, no entanto, o termo "sensoriamento remoto" é mais comumente associado a técnicas eletromagnéticas de aquisição de informações (ELACHI; ZYL, 2006). De forma mais abrangente, Novo (2010, p.28), define o sensoriamento remoto como:

Utilização conjunta de sensores, equipamentos para o processamento de dados, equipamentos de transmissão de dados colocados a bordo de aeronaves, espaçonaves, ou outras plataformas, com o objetivo de estudar eventos, fenômenos e processos que ocorrem na superfície do planeta Terra a partir do registro e análise das interações entre a radiação eletromagnética e as substâncias que o compõe em suas mais diversas manifestações.

A radiação eletromagnética – REM é a base de todos os princípios em que se fundamenta essa tecnologia (JENSEN, 2009). A REM pode ser codificada em termos de frequência, intensidade e polarização da onda eletromagnética, e como essa se propaga à velocidade da luz, quanto maior sua frequência, menor seu comprimento de onda (SILVA, 2007). De acordo com Moreira (2011), o espectro eletromagnético compreende todo o intervalo de REM existente e pode ser segmentado em ordem crescente de frequências, começando pelas ondas de rádio, até a radiação gama (Figura 1). Os fenômenos que descrevem o processo de interação entre a REM e os alvos da superfície terrestre estão estreitamente ligados as propriedades físico-químicas dos objetos, desse modo, na aplicação das técnicas de sensoriamento remoto é possível explorar diferentes escalas de trabalho, as quais são dependentes da natureza dos estudos pretendidos (PONZONI; SHIMABUKURO, 2009).

Algumas aplicações de sensoriamento remoto em função das diferentes porções do espectro eletromagnético podem ser observadas na Figura 1.

Figura 1 - Representação do espectro eletromagnético e suas faixas espectrais utilizadas por diferentes sistemas de sensoriamento remoto



Fonte: Adaptado de Thenkabail (2016).

### 2.2.1 Interação da REM com a atmosfera

Ao interagir com moléculas gasosas e o material particulado suspenso na atmosfera, a REM pode sofrer alteração na intensidade do fluxo radiante, distribuição espectral e direção dos raios incidentes, de modo que a interferência atmosférica tem papel fundamental no

contexto do sensoriamento remoto de alta altitude ou orbital (MENESES; ALMEIDA, 2012). Como resultado dessa interação, o sinal observado pelos sensores embarcados em plataformas orbitais é atenuado, sejam eles sistemas termiais, que registram a emissividade da cobertura terrestre, ou multiespectrais/hiperespectrais, que captam a radiação solar refletida pelos objetos (JENSEN, 2009; MOREIRA, 2001; NOVO, 2010). A atenuação da REM na atmosfera terrestre ocorre basicamente em função dos fenômenos de espalhamento e absorção (REDDY, 2008).

O espalhamento é um fenômeno físico relacionado ao tamanho das partículas presentes na atmosfera e sua interação com comprimentos de onda específicos, cuja ocorrência é responsável por alterações aleatórias na direção de propagação das ondas eletromagnéticas (ELACHI; ZYL, 2006). Como consequência do espalhamento, a radiância registrada pelo campo instantâneo de visada IFOV (*Instantaneous Field of View*) do sensor orbital, pode conter fluxo difuso proveniente de fora do pixel em observação, ou seja, energia que chega ao satélite sem ter interagido com o alvo (LORENZZETTI, 2015). Conforme relato de Moreira (2001), em função do diâmetro das partículas, podem ocorrer três tipos de espalhamento: *Rayleigh* ou molecular, o espalhamento de *Mie* e o espalhamento *Não-seletivo*.

O espalhamento *Rayleigh* está associado a moléculas de gases atmosféricos, dessa forma é também denominado de espalhamento molecular. Conforme relato de Jensen (2009), ocorre quando o diâmetro das moléculas de ar, como oxigênio e nitrogênio é muitas vezes menor ( $<0,1$ ) quando comparadas ao comprimento de onda da REM incidente. Esse fenômeno é responsável pela percepção azul do céu ao longo do dia e avermelhada durante o nascer e pôr-do-sol (LILLESAND et al., 2004). Pode ser considerado o tipo de espalhamento mais comum, e seu efeito mais prejudicial em imagens ocorre no início do espectro visível (MENESES; ALMEIDA, 2012).

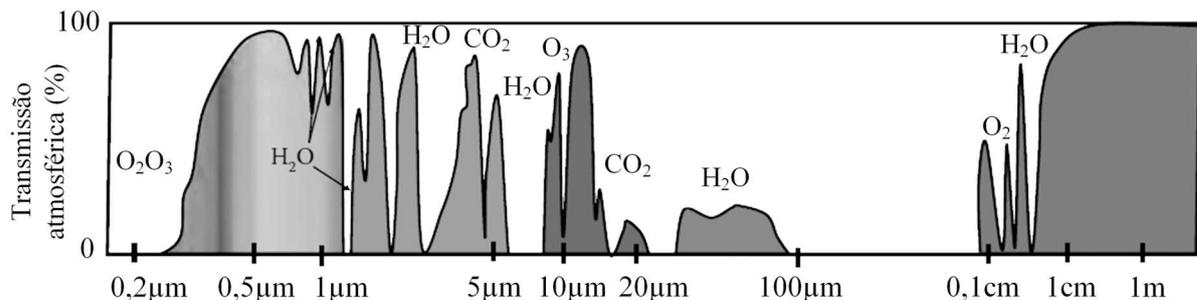
Outro fenômeno e dispersão atmosférica é o espalhamento de *Mie*, que ocorre quando os diâmetros das partículas são essencialmente iguais aos comprimentos de onda da energia incidente (LILLESAND et al., 2004). Os principais agentes responsáveis por esse tipo de espalhamento são partículas esféricas de vapor d'água, poeira, fumaça e demais elementos cujo tamanho varia de décimos a vários micrômetros (JENSEN, 2009). Este tipo de dispersão tende a influenciar comprimentos de onda mais longos em comparação com a dispersão de *Rayleigh* (LILLESAND et al., 2004). Embora a dispersão de *Rayleigh* tenda a dominar na maioria das condições atmosféricas, a dispersão de *Mie* é significativa em condições ligeiramente nubladas (LILLESAND et al., 2015), o que determina perda de contraste entre alvos da imagem quando a atmosfera está mais densa (MENESES; ALMEIDA, 2012).

Por sua vez, o espalhamento *não-seletivo* ocorre quando os diâmetros das partículas são muito maiores do que os comprimentos de onda da energia que está sendo detectada (LILLESAND et al., 2015). Nesse caso, temos grandes partículas de poeira, gotas d'água, cristais de gelo, entre outros elementos interagindo e espalhando energia em diferentes comprimentos de onda (LORENZZETTI, 2015). Nos comprimentos de onda visíveis, quantidades iguais de luz azul, verde e vermelha são espalhadas, daí a neblina e as nuvens parecerem brancas (JENSEN, 2009).

Em contraste com o espalhamento, a absorção atmosférica resulta na perda efetiva de energia para os constituintes atmosféricos, em razão da absorção de energia em determinados comprimentos de onda (LILLESAND et al., 2004). Os absorvedores de radiação solar mais eficientes nesse aspecto são o vapor d'água, o dióxido de carbono e o ozônio (LILLESAND et al., 2015). A presença desse fenômeno limita as regiões espectrais que podem ser usadas para observar a superfície subjacente (ELACHI; ZYL, 2006).

Nessa linha, surge o conceito de “janelas atmosféricas”, que são regiões do espectro eletromagnético de menor interação com os componentes atmosféricos e propiciam a observação da superfície terrestre por sensores remotos orbitais (NOVO, 2010). Seguindo esse conceito, a sensibilidade espectral dos sensores é ajustada para focar em determinadas regiões, sendo as principais (1) Visível e infravermelho próximo: localizadas entre 0,4 e 1,35  $\mu\text{m}$ ; (2) Infravermelho de ondas curtas e médias: de 1,5 a 1,8  $\mu\text{m}$ , 2,0 a 2,4  $\mu\text{m}$ , 2,9 a 4,2  $\mu\text{m}$  e 4,5 a 5,5  $\mu\text{m}$ ; (3) Infravermelho termal: entre 8 e 14  $\mu\text{m}$ ; e (4) Micro-ondas:  $>1$  cm, onde a atmosfera é praticamente transparente (CHUVIECO, 2016). Na Figura 2 é possível visualizar uma representação dessas faixas espectrais em conjunto com os principais elementos atmosféricos que absorvem a radiação eletromagnética.

Figura 2 - Janelas atmosféricas adequadas para observação terrestre a partir de plataformas orbitais, juntamente com os principais gases responsáveis pela absorção da energia eletromagnética



Fonte: Adaptado de Chuvieco (2016).

### 2.2.2 Interação da REM com a vegetação

Ao entrar em contato com alvos na superfície terrestre, o fluxo radiante de energia em determinada faixa de comprimento de onda é decomposto em três processos: Fluxo radiante refletido, fluxo radiante absorvido e fluxo radiante transmitido (LORENZZETTI, 2015). Jensen (2009) menciona que essas grandezas podem ser determinadas em função do balanço de energia, descrito pela Equação 1:

$$\Phi_{\lambda} = \Phi_{\rho} + \Phi_{\alpha} + \Phi_{\tau} \quad (1)$$

Em que:  $\Phi_{\lambda}$  = Fluxo radiante total;  $\Phi_{\rho}$  = Fluxo radiante refletido;  $\Phi_{\alpha}$  = Fluxo radiante absorvido;  $\Phi_{\tau}$  = Fluxo radiante transmitido.

Em termos de vegetação, segundo Moreira (2011), o principal órgão absorvedor da radiação eletromagnética é a folha, e a energia absorvida, transmitida e refletida pode ser quantificada através de sensores em laboratório, campo, aerotransportados ou orbitais. No entanto, conforme relato de Meneses e Almeida (2012), a parcela de energia refletida é mais importante, tendo em vista que a maioria das aplicações de sensoriamento remoto utilizam sensores que armazenam informações com valores digitais de reflectância.

Ponzoni e Shimabukuro (2009), estratificam a resposta espectral da vegetação em três regiões características (visível, infravermelho próximo e infravermelho médio de ondas curtas), cujo padrão de reflectância é característico e varia segundo diversos fatores (Figura 3). Meneses e Netto (2001, p.168), mencionam os principais aspectos relacionados ao comportamento espectral da folha em cada uma dessas regiões:

*Visível (400 a 700nm):* nesta região os pigmentos existentes nas folhas dominam a reflectância espectral. Estes pigmentos, geralmente, encontrados nos cloroplastos são: clorofila (65%), xantofilas (29%) e carotenos (6%). Os pigmentos predominantes absorvem radiação na região azul (próximo a 445nm), mas somente a clorofila absorve na região do vermelho (645nm). Essa proporção pode variar em função da espécie;

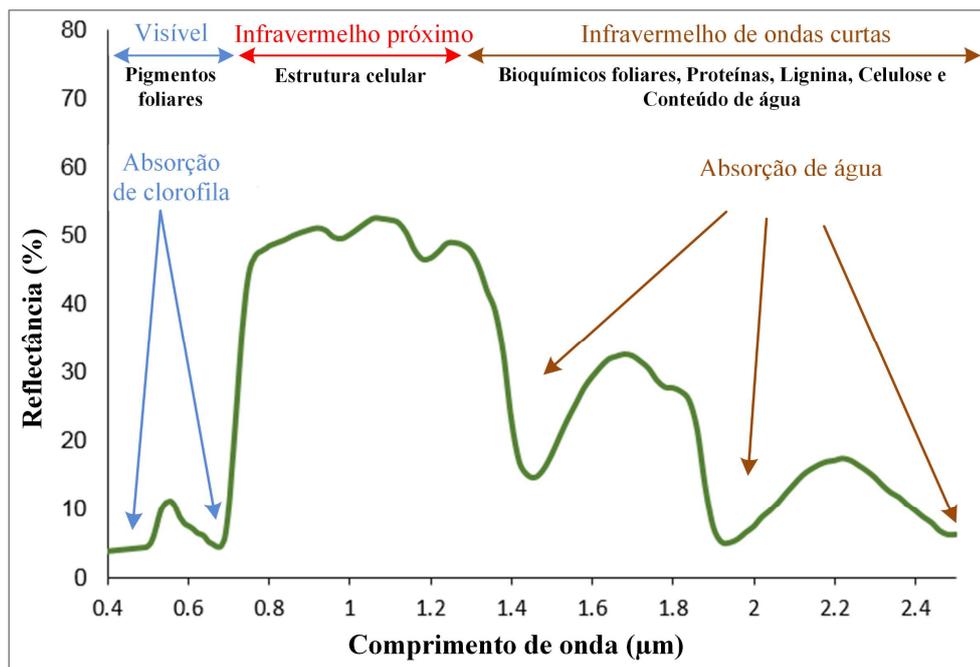
*Infravermelho próximo (700 a 1.300nm):* nesta região existe absorção pequena da REM e considerável espalhamento interno da folha. A absorção da água é geralmente baixa nessa região e a reflectância espectral é quase constante;

*Infravermelho de ondas curtas (1.300 a 2.600nm):* a absorção devido à água líquida predomina na reflectância espectral das folhas. Em termos mais pontuais, a absorção de água ocorre suavemente em 1.100nm e fortemente em 1.450nm, 1.950nm.

A grande reflectância da vegetação no infravermelho próximo faz com que essa região seja utilizada em praticamente todos os sensores remotos orbitais desenhados para monitorar a vegetação (LORENZZETTI, 2015). Medições espectrais de dosséis vegetais apresentam formas muito semelhantes a curva de reflectância de uma folha verde sadia, dessa forma pode-

se prever os padrões de reflectância apresentados pelos dosséis em imagens multiespectrais (PONZONI, 2002). No entanto, conforme apontado por Jensen (2009), diversos fatores podem interferir no padrão de reflectância do dossel, como a própria característica da vegetação (arquitetura do dossel, copas, troncos, folhas), iluminação (geometria e característica espectrais), tipo de sensor e características do solo e substratos.

Figura 3 - Padrão de reflectância foliar considerando os principais fatores responsáveis pelo comportamento espectral da vegetação



Fonte: Adaptado de Roman e Ursu (2016).

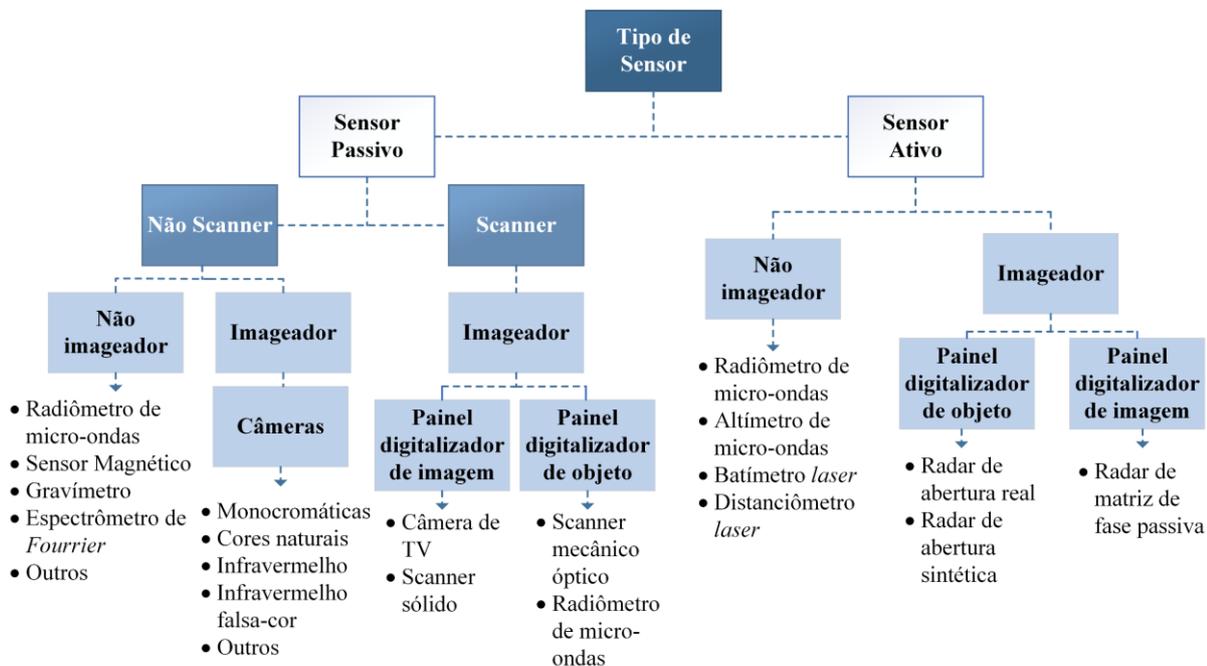
### 2.2.3 Sistemas Sensores

Os sistemas sensores são dispositivos que operam em determinadas faixas do espectro eletromagnético e são capazes de detectar a energia proveniente dos alvos de interesse e convertê-la em sinais elétricos para registro (DI MAIO et al., 2008). De acordo com Novo (2010), no processo de conversão e registro da energia, essa se encontra sujeita a um conjunto de transformações radiométricas, geométricas e espaciais, de modo que se permita extrair de forma adequada as feições da superfície.

Para Chuvieco (2016), das maneiras mais comuns de classificar os sistemas sensores está baseada no seu mecanismo principal para detectar a energia eletromagnética, aonde são estabelecidos dois grandes grupos (Figura 4): (1) sensores passivos, que coletam radiações derivadas de fontes externas; e (2) sensores ativos, nos quais o sistema sensor emite sua própria

energia para o alvo e posteriormente coleta o reflexo desse fluxo para caracterizar as áreas observadas. Após esse primeiro nível de classificação, existe uma variedade de sensores, distribuídos de acordo com seu mecanismo de operação (THENKABAIL, 2016).

Figura 4 - Classificação geral dos sistemas sensores remotos quanto à fonte e à forma de registro da radiação eletromagnética



Fonte: Adaptado de Thenkabail (2016).

Segundo Lorenzetti (2015), a escolha do sistema sensor a ser utilizado depende fundamentalmente da natureza do problema e do tipo de informação que se deseja obter. No âmbito florestal, o uso de imageadores ópticos orbitais constitui-se em um método indireto e não destrutivo para estimativa de variáveis biofísicas como Índice de Área Foliar – IAF e biomassa (SHIRATSUCHI et al., 2014), assim como monitoramento da cobertura florestal em diferentes escalas. Destacam-se o *Moderate Resolution Imaging Spectroradiometer* (MODIS), a bordo dos satélites TERRA e AQUA (ALMEIDA et al., 2018; SHIRATSUCHI et al., 2014; SIMOES et al., 2020), *Operational Land Imager* (OLI) a bordo do satélite Landsat-8 (ALBA et al., 2020; PHIRI; MORGENROTH, 2017; SANTOS et al., 2019), e *Multispectral Instrument* (MSI), embarcado na plataforma Sentinel-2 (CHEN et al., 2018; LIMA et al., 2019; PELLETIER et al., 2016). Sistemas ativos (RADAR, LiDAR, entre outros) são independentes da energia solar e menos afetados pelos constituintes atmosféricos, algo que proporciona grandes benefícios para o sensoriamento remoto em regiões como ambientes tropicais, onde nuvens e chuva são eventos climáticos frequentes e interferem nos sistemas ópticos/passivos

tradicionais (THENKABAIL, 2016). Por outro lado, se informações espectrais puras, ou seja, com o mínimo de interferência de outros alvos são o principal interesse, recomenda-se utilizar espectrômetros, também chamados hiperespectrais, ou mesmo espectrorradiômetros (LORENZZETTI, 2015).

#### 2.2.4 Sensoriamento Remoto Óptico Orbital

No monitoramento da cobertura terrestre via satélite é comum o uso de imageadores ópticos, definidos por Novo (2010), como sensores passivos, que operam na detecção da reflectância e/ou emitância da superfície do globo, por meio de um sistema de espelhos, prismas e lentes em sua configuração. Para Watzlawick et al. (2007), a imagem formada nesses sistemas é nada mais do que o registro gráfico da intensidade da energia eletromagnética que alcança o sensor a partir de uma direção em um determinado tempo particular. Essa tecnologia remonta aos primeiros voos espaciais tripulados na década de 1960 e ao lançamento, no ano de 1972, do programa *Earth Resource Technological Satellites – ERTS 1*, também denominado Landsat 1 (FERREIRA et al., 2008). O constante aperfeiçoamento dessa tecnologia tem propiciado grande avanço no emprego de imagens digitais por profissionais de múltiplas áreas (JUNIOR, 2006).

Esses dispositivos registram a radiância refletida/emitida pela superfície terrestre e armazenam essa informação discretizando-a em DN's (*Digital Numbers*), cuja amplitude varia em função da resolução radiométrica do sensor, em geral de oito a 16 bits (PONZONI; SHIMABUKURO, 2009). Conforme relato de Reddy (2008), DN's podem ser usados para classificar estatisticamente os tipos de cobertura em uma cena ou cenas contínuas, no entanto, seus valores não representam quantitativamente qualquer característica física real, como radiância e reflectância. Embora a radiância represente a grandeza física efetivamente registrada por sensor, seus valores absolutos são influenciados por fatores como mudanças na iluminação da cena, condições atmosféricas, geometria da visada e as próprias características do instrumento (LILLESAND et al., 2015). Nesse sentido, a reflectância é tida como a grandeza radiométrica que melhor retrata as propriedades espectrais dos objetos, já que em razão dos seus valores adimensionais e relativizados, permite a comparação de alvos considerando diferentes sensores e datas (CHUVIECO, 2016).

Os valores de DN's das imagens podem ser convertidos em radiância e reflectância “aparente” mediante a aplicação de coeficientes de calibração dos sensores que as geraram (PONZONI; DOS SANTOS, 2008). O termo “aparente” é utilizado uma vez que os efeitos atmosféricos continuam incorporados e mascaram a resposta espectral dos objetos (PONZONI;

SHIMABUKURO, 2009). O produto dessa primeira conversão radiométrica é também referido como radiância e ou reflectância no topo da atmosfera (*Top-Of-Atmosphere* – TOA) (HE et al., 2017; STERCKX; WOLTERS, 2019).

A reflectância de topo da atmosfera (TOA) é convertida em reflectância de superfície (*Bottom-Of-Atmosphere reflectance* - BOA), por meio de um processo de correção atmosférica, frequentemente fundamentado em modelos de transferência radiativa (PONZONI; SHIMABUKURO, 2009). A correção atmosférica e a consequente obtenção da reflectância de superfície (BOA) são considerados processos essenciais no sensoriamento remoto orbital com foco nas propriedades físicas, químicas e biológicas dos alvos, tendo em vista as distorções causadas pela atenuação atmosférica sobre as características espectrais intrínsecas dos objetos na superfície terrestre (BAKKER et al., 2004; FUJIWARA; TAKEUCHI, 2020; GAIDA et al., 2020).

Outro aspecto fundamental é a qualidade geométrica das cenas. A correção geométrica tem como objetivo remover ou reduzir erros geométricos presentes nas imagens, os quais são influenciados pela atitude do satélite em órbita (HORNING et al., 2010). Esse processo envolve a correção de distorções, a reamostragem das imagens e a atribuição correta das coordenadas geográficas a cada pixel (MACHADO; QUINTANILHA, 2008). Essas correções são fundamentais para garantir a precisão espacial das imagens e possibilitar a sobreposição, comparação e análise precisa das características da superfície terrestre.

Conforme relato de Weaver (2014), dados de imagem bruta e radiância/reflectância calibradas no topo da atmosfera (TOA) são comumente referidos em sensoriamento como dados *Level 0* e *Level 1*, respectivamente, enquanto dados *Level 2*, consistem em variáveis físicas calibradas radiometricamente e geolocalizadas, como reflectância de superfície (BOA). Poucos sistemas e serviços de sensoriamento remoto oferecem produtos *Level 2*, de modo que os usuários devem realizar esse trabalho de processamento por si próprios, usando um *software* de análise de imagem ou em colaboração com a indústria privada (THENKABAIL, 2016).

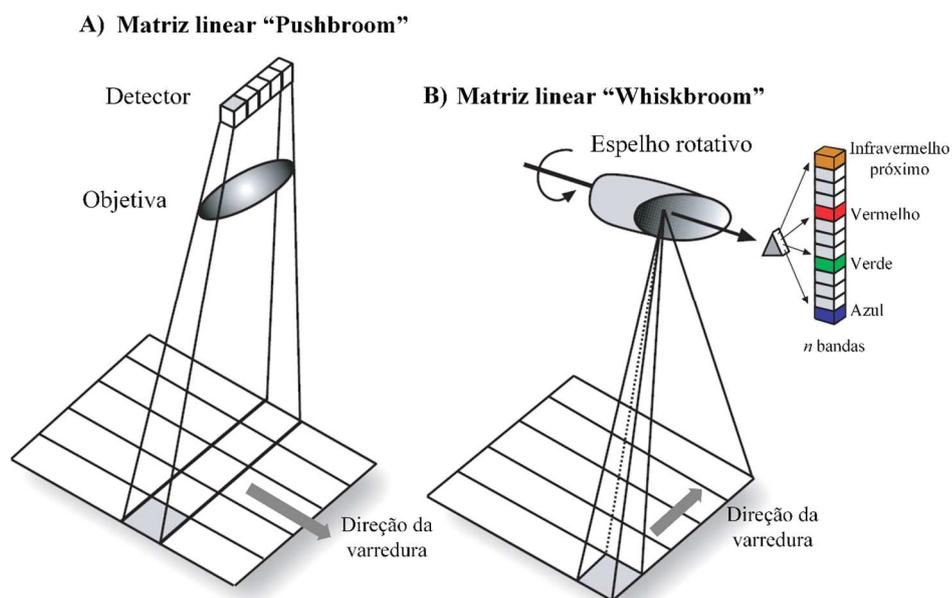
#### 2.2.4.1 Imageadores ópticos

Imageadores multiespectrais do tipo *scanner* têm sido usados em sensoriamento remoto desde 1972, quando o primeiro satélite Landsat foi lançado, cujas aplicações são principalmente o mapeamento da cobertura da terra, vegetação, mineralogia de superfície e águas superficiais (BAKKER et al., 2004). De acordo com Lillesand et al. (2015), são conhecidos dois modos de

aquisição de imagens por meio desses sensores: a varredura transversal (*whiskbroom*) e a varredura longitudinal (*pushbroom*), ambos representados na Figura 5.

Sistemas do tipo *whiskbroom* registram um único píxel, ou elemento espacial por vez (FOWLER, 2014). Seu mecanismo conta com um espelho rotativo que executa uma varredura perpendicular ao sentido de deslocamento do satélite (Figura 5B). Exemplos desse sistema são os instrumentos Landsat *Multispectral Scanner - MSS*, *Thematic Mapper-TM* e o *Enhanced Thematic Mapper Plus-ETM+* (ELACHI; ZYL, 2006). Já o sistema *pushbroom* (Figura 5A), detecta todo o campo de visada do sensor de uma só vez, usando uma matriz linear de detectores, de modo que a varredura é longitudinal a trajetória orbital (CHUVIECO, 2016).

Figura 5 - Mecanismo operacional básico de um sensor óptico para aquisição de imagens aéreas e orbitais: A) Sistema de varredura *Pushbroom* (ao longo da faixa orbital); B) Sistema de varredura *Whiskbroom* (através da faixa orbital)



Fonte: Adaptado de Jensen (2016).

Como os sensores *pushbroom* não requerem um espelho de varredura móvel para adquirir as imagens, pode-se esperar que esses dispositivos exibam uma vida operacional mais longa (ELACHI; ZYL, 2006). Ademais, segundo os autores, dispensar o sistema mecânico de varredura, permite elevar o tempo de exposição dos detectores e aumentar a sensibilidade do sistema, o que possibilita diminuir a largura de cada banda de observação. Por outro lado, esses dispositivos podem apresentar mais problemas de calibração, já que possuem mais matrizes de detectores. Por essa razão, os *scanners pushbroom* são mais difíceis de calibrar no infravermelho térmico, já que podem ser afetados pelo aquecimento de outros detectores;

portanto, a maioria dos *scanners* térmicos ainda é baseada em sistemas *wiskbroom* (CHUVIECO, 2016).

Dispositivos *pushbroom* são hoje, os sensores mais comuns para satélites de observação da terra. Sistemas de alta resolução espacial incluem *scanners pushbroom*, como as câmeras a bordo dos sistemas QuickBird, IKONOS, GeoEye, WorldView e RapidEye (CHUVIECO, 2016). Imageadores orbitais de média resolução espacial, a exemplo do MSI - Sentinel 2, OLI/Landsat 8-9 e Cbers 4B, também fazem uso desse padrão de varredura na tomada das imagens (WMO, 2022).

#### 2.2.4.2 Satélites Landsat

O programa Landsat (*Landsat Remote Sensing Satellite*) é um sistema orbital de observação da terra desenvolvido e lançado pela Administração Nacional da Aeronáutica e Espaço (*National Aeronautics and Space Administration* - NASA), enquanto sua operação, gerenciamento, armazenamento e distribuição de seus dados está a cargo do Serviço Geológico dos Estados Unidos (*United States Geological Survey* - USGS) (NASA, 2023; USGS, 2023a).

O primeiro sistema Landsat teve seu lançamento em meados da década de 1970, com o objetivo de fornecer dados de sensoriamento remoto em aplicações de monitoramento e pesquisa sobre os recursos naturais (EMBRAPA, 2023). A Tabela 1 apresenta uma síntese das missões dos satélites do Landsat.

Tabela 1 - Características gerais da série de satélites da missão Landsat

Satélite	Lançamento (vida útil)	Resolução temporal	Sistema sensor
Landsat - 1	23/07/1972 06/01/1978 (6 anos)	18 dias	RBV e MSS
Landsat - 2	20/01/1975 25/02/1982 (7 anos)	18 dias	RBV e MSS
Landsat - 3	05/03/1978 31/03/1983 (5 anos)	18 dias	RBV e MSS
Landsat - 4	16/07/1982 Ano de 1993 (1 ano)	16 dias	MSS e TM
Landsat - 5	01/03/1984 22/11/2011 (27 anos)	16 dias	MSS e TM
Landsat - 6	05/10/1993 (05/10/1993) (Falhou em atingir a órbita)	16 dias	ETM
Landsat - 7	15/04/1999 Ativo (Interrompeu a recepção no Brasil em 31/05/2003)	16 dias	ETM+
Landsat - 8	11/02/2013 (Ativo)	16 dias	OLI e TIRS
Landsat - 9	27/09/2021 (Ativo)	16 dias	OLI 2 e TIRS 2

Nota: RBV - (*Return Beam Vidicon*); MSS (*Multispectral Scanner System*); TM (*Thematic Mapper*); ETM (*Enhanced Thematic Mapper*); ETM+ (*Enhanced Thematic Mapper Plus*); OLI - (*Operational Land Imager*); TIRS (*Thermal Infrared Sensor*).

Fonte: Adaptado de EMBRAPA (2023).

Em resposta aos desafios enfrentados pelos sensores a bordo das missões anteriores da série Landsat e com o objetivo de garantir a continuidade na obtenção de dados, o programa *Landsat Data Continuity Mission* (LDCM) da NASA lançou em fevereiro de 2013 o Landsat-8 (NASA, 2023). Essa nova missão introduziu os sensores *Operational Land Imager* (OLI) com nove bandas espectrais e o *Thermal Infrared Sensor* (TIRS) com duas bandas no infravermelho termal, conforme descritos na Tabela 2.

Uma das principais melhorias do sensor OLI foi o incremento significativo na resolução radiométrica. Enquanto as missões anteriores operavam com 8 bits de resolução, o OLI introduziu uma capacidade de 12 bits, cujos produtos são disponibilizados aos usuários em 16 bits (GERACE et al., 2013). Essas melhorias no sensor OLI/Landsat-8 contribuíram significativamente para a qualidade e a confiabilidade dos dados coletados, possibilitando uma melhor interpretação e análise das imagens, impulsionando diversos campos de estudo, desde predições de biomassa (DOS SANTOS et al., 2019; HENTZ et al., 2014), monitoramento de

incêndios (PEREIRA et al., 2017), estimativa de produtividade (CLARINDO et al., 2022), entre outras aplicações. Em fevereiro de 2021, foi lançado o satélite Landsat-9, que representa a continuidade da série. O Landsat-9 aprimora os dois instrumentos principais para a captura de imagens: o *Operational Land Imager 2* (OLI-2) e o *Thermal Infrared Sensor 2* (TIRS-2) (NASA, 2023).

Tabela 2 - Características das bandas espectrais dos sensores *Operational Land Imager* (OLI) e *Thermal Infrared Sensor* (TIRS) a bordo do satélite Landsat-8

Sensor	Bandas espectrais	Comprimento de onda central ( $\mu\text{m}$ )	Resolução espacial	Resolução temporal	Aplicações Gerais
OLI	B1 Costal	0,433 – 0,453	30 m	16 dias	Análises costeiras, qualidade da água, detecção de aerossóis na atmosfera.
	B2 Azul	0,450 – 0,515			Distinguir o solo da vegetação.
	B3 Verde	0,525 – 0,600			Análise de vegetação, monitoramento da cobertura vegetal, uso da terra, estudos agrícolas e análises ambientais.
	B4 Vermelho	0,630 – 0,680			Aplicações relacionadas à vegetação e ao uso da terra.
	B5 Infravermelho próximo	0,845 – 0,885			Monitoramento da qualidade da água, detecção de vazamentos de petróleo, estudos de umidade do solo, mapeamento de vegetação aquática e análise da cobertura do solo em áreas úmidas.
	B6 Infravermelho médio	1,560 – 1,660			Diferenciar solo seco de úmido e geologia, saúde da vegetação, avaliação da qualidade da água, entre outros.
	B7 Infravermelho médio	2,100 – 2,300			Diferenciar solo seco de úmido e geologia, saúde da vegetação, avaliação da qualidade da água, entre outros.
	B8 Pancromático	0,500 – 0,680			15 m
	B9 Cirrus	1,360 – 1,390	30 m		Detecção de nuvens, correção atmosférica.
TIRS	B10 <i>Thermal Infrared</i> (TIRS) 1	10,30 – 11,30	100 m	-	
	B11 <i>Thermal Infrared</i> (TIRS) 2	11,50 – 12,50		-	

Fonte: Adaptado de USGS (2023b).

### 2.2.5 Sensoriamento Remoto LiDAR

A tecnologia *laser* (*light amplification by stimulated emission of radiation* – amplificação de luz por emissão estimulada de radiação), remonta à década de 1950 quando Schawlow; Townes (1958), utilizando uma cavidade de ressonância centimétrica, determinaram os pilares para obtenção de luz amplificada com emissão estimulada de radiação nas regiões do visível e infravermelho próximo do espectro eletromagnético. Apesar de a emissão de pulsos *laser* não ser uma tecnologia nova, sua utilização na aquisição de dados geográficos é mais recente (GIONGO et al., 2010). De acordo com Gorgens et al. (2014), na década de 1970, pesquisadores soviéticos começaram avaliar a possibilidade de usar distanciômetros *laser* para medir árvores, enquanto cientistas americanos concentravam o uso da tecnologia em aplicações submarinas e canadenses mediam o topo do dossel florestal com estereofotos e radares. Ainda segundo os autores, nessas primeiras experiências na área florestal, os soviéticos já acenaram com a obtenção de perfis relativamente precisos do dossel florestal, os quais, no futuro poderiam dar suporte a um processo computacional e automatizado de obtenção dos índices de custo do manejo de talhões florestais.

A tecnologia LiDAR (*Light Detection and Ranging* – Detecção de Luz e Distância) é baseada nos mesmos conceitos utilizados no sistema de RADAR (*Radio Detection and Ranging* - Detecção e Alcance de Rádio), todavia, enquanto o sistema RADAR emprega ondas de rádio para localizar os objetos de interesse, o LiDAR utiliza pulsos *laser* (GIONGO et al., 2010). Em linhas gerais, um sistema LiDAR compreende três subsistemas principais: um transmissor óptico, um receptor/detector óptico e uma unidade eletrônica de temporização e controle (DIAZ et al., 2013). O princípio do funcionamento do LiDAR consiste na emissão de um pulso de *laser* na direção de uma superfície ou objeto, ao atingir o alvo, a luz é refletida na direção contrária e retorna ao sistema *laser* (D'OLIVEIRA et al., 2014; MCMANAMON, 2019). Baseado no período de tempo transcorrido entre a emissão e o retorno dos pulsos, o sistema calcula e registra o espaço existente entre o dispositivo e os alvos na superfície terrestre (YADAV, 2016). No mapeamento topográfico e em aplicações florestais, o comprimento de onda dos pulsos LiDAR compreendem a região do infravermelho próximo do espectro eletromagnético, normalmente entre 1.040 e 1.065 nm (GATZIOLIS; ANDERSEN, 2008).

Os níveis de aquisição dos dados LiDAR estão relacionados ao veículo ou sistema de suporte para operação do sensor. A técnica pode ser empregada a partir de uma plataforma terrestre fixa ou móvel, cuja referência corresponde as iniciais em inglês TLS - *Terrestrial Laser Scanning* (ANDERSON et al., 2016). Quando se objetiva mapear a estrutura

tridimensional de extensas superfícies, a partir de uma perspectiva distante acima do solo, pelo uso de aeronaves, nos referimos ao sistema utilizando a sigla ALS - *Airborne Laser Scanning* (GORGENS et al., 2014). Por fim, plataformas orbitais (*space-borne* LiDAR) fornecem informações exclusivas de vários parâmetros da atmosfera, assim como da superfície terrestre em escala global, como é caso das missões *Ice, Cloud, and land Elevation Satellite* - ICESat (2003), ICESat2 (2018) (FOULADINEJAD et al., 2019), e *Global Ecosystem Dynamics Investigation* – GEDI (2018), esta última, a bordo da estação espacial internacional (MARSELIS et al., 2020).

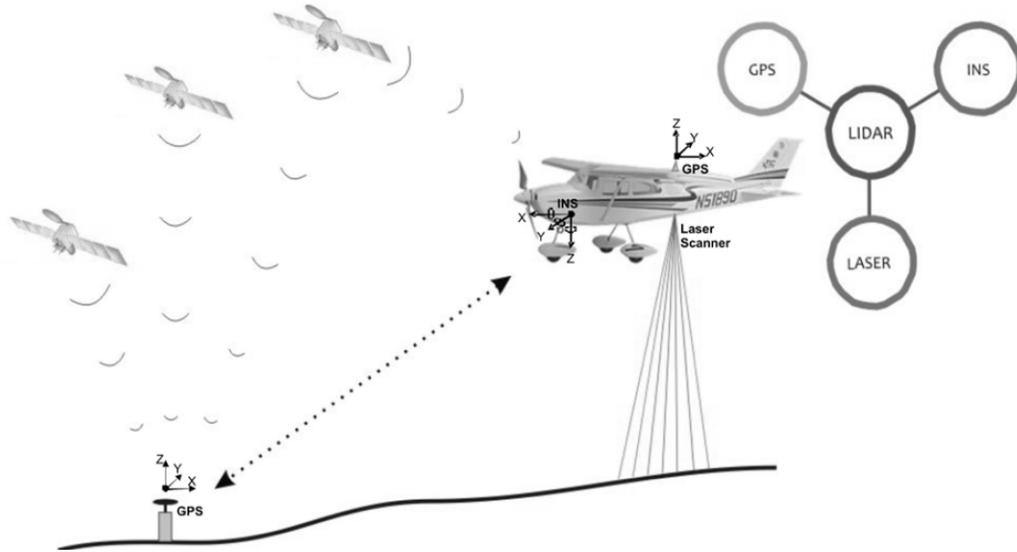
De acordo com Gorgens et al. (2014), em linhas gerais, a tecnologia LiDAR pode ser considerada a solução mais rápida e precisa para o mapeamento tridimensional de grandes áreas, tendo em vista as seguintes vantagens: alta densidade amostral; a superfície pode ser analisada dentro do contexto dos objetos que compõem a cena, como prédios, dossel vegetal, linhas de transmissão de energia, entre outros; sensível a pequenas variações no terreno; e penetração considerável mesmo em vegetações mais densas.

#### 2.2.5.1 Airborne Laser Scanning (ALS)

Para Giongo et al. (2010), o sistema LiDAR aerotransportado é composto de três principais componentes (Figura 6). O *laser scanner* realiza a emissão dos pulsos e registro dos retornos, enquanto o componente GPS (*Global Position System*) é responsável pelo posicionamento da plataforma que comporta o sistema (VOSELMAN; MASS, 2010). Por sua vez, o Sistema de Navegação Inercial (*Inertial Navigation System* – INS), utiliza uma Unidade de Medição Inercial (*Inertial Measurement Unit* – IMU) para determinar a orientação da plataforma (GIONGO et al., 2010).

Dessa forma, o sistema GPS/IMU documenta a localização exata da plataforma no espaço, assim como os movimentos de *roll*, *pitch* e *yaw* (rolamento, arfagem e guinada) da aeronave nos instantes em que o pulso de laser é enviado e recebido (JENSEN, 2009). Como resultado da combinação desses elementos, o levantamento ALS produz densas nuvens de pontos georreferenciadas que retratam a superfície terrestre de forma tridimensional (YADAV, 2016).

Figura 6 - Representação esquemática dos componentes do sistema ALS - *Airborne Laser Scanning*



Legenda: GPS-Global Position System; INS-Inertial Navigation System; LiDAR-Light Detection and Ranging; LASER-Light Amplification by Stimulated Emission of Radiation

Fonte: Adaptado de Giongo et al. (2010).

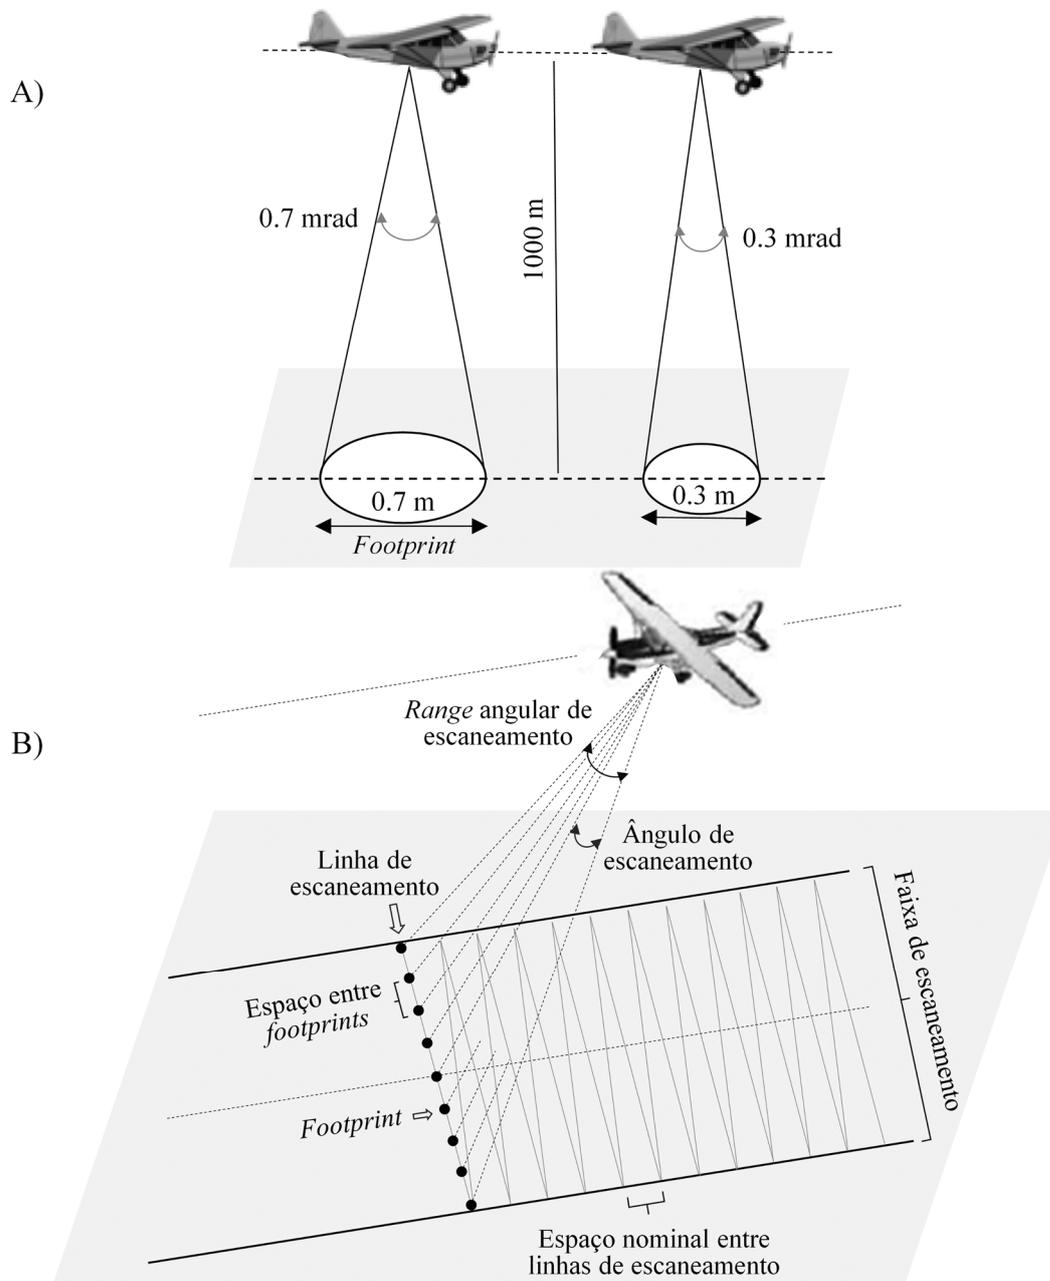
No processo de varredura aérea, cada pulso emitido pelo instrumento irá iluminar no terreno uma área com formato aproximado de um círculo, denominada de área de cobertura *laser* instantânea (*instantaneous laser footprint*) (JENSEN, 2009). De acordo com Gorgens et al. (2014), o diâmetro desse *footprint* ( $D_f$ ) pode ser obtido a partir do diâmetro do laser ao sair do equipamento emissor ( $D$ ), altura de voo ( $h$ ) e divergência do laser ( $\gamma$ ) (Equação 2). A Figura 7(A), traz uma representação esquemática do efeito desses parâmetros sobre a área iluminada pelo pulso emitido.

$$D_f = D + 2 \cdot h \cdot \tan\left(\frac{\gamma}{2}\right) \quad (2)$$

Em que:  $D_f$  = diâmetro do *footprint* (m), correspondente a área no terreno iluminada pelo pulso;  $D$  = diâmetro (m) do *laser* ao sair do equipamento emissor;  $h$  = altura de voo (m);  $\gamma$  = divergência do *laser* (radianos).

A dimensão do *footprint* é considerado um fator limitante na resolução espacial, diâmetros pequenos permitem o mapeamento de alta resolução da topografia e da estrutura do dossel (HARDING, 2009). Em escala comercial, as aplicações florestais utilizam em sua maioria o sistema *small footprint*, cujos feixes emitidos atingem o solo com diâmetros até 90 cm (GORGENS et al., 2014). De acordo com Popescu et al. (2011), sistemas ALS com *footprint* menores fornecem maior grau de detalhe e precisão nas medidas de elevação do terreno e altura do dossel, mesmo em terreno acidentado e vegetação densa.

Figura 7 - Ilustração do efeito do ângulo de divergência do pulso *laser* sobre a dimensão da área iluminada na superfície terrestre (*footprint*) (A) e ilustração dos atributos inerentes ao processo de escaneamento *laser* aéreo (B)



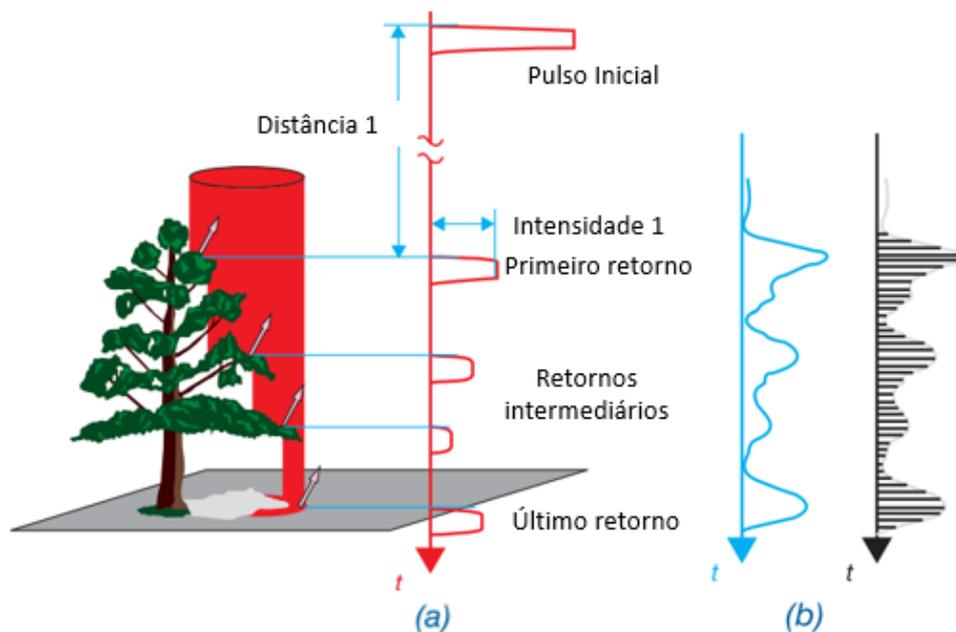
Fonte: Adaptado de Gatzliolis e Andersen (2008).

Fatores geométricos relacionados ao sobrevoo, também possuem ligação direta com a densidade, ou resolução espacial do levantamento ALS, como ilustrado na Figura 7(B). A altura da aeronave e a amplitude angular total de escaneamento determinam a largura da faixa de voo, assim como a densidade de pulsos emitidos na linha de escaneamento. O padrão de varredura em “gangorra” ou “zigue-zague” é o mais comum em aquisição para aplicações florestais, no qual o pulso é direcionado através da linha de escaneamento por um espelho oscilante e os

retornos são gerados continuamente em ambas as direções da varredura (GATZIOLIS; ANDERSEN, 2008). Nesse caso, a frequência de rotação do espelho e a velocidade da aeronave determinam a densidade de linhas escaneadas (VOSSSELMAN; MASS, 2010), como evidenciado na Figura 7(B).

Os sensores LiDAR também podem ser categorizados em função da característica do sinal de retorno registrado pelo *scanner*, conforme apresentado na Figura 8. Coops et al. (2007) mencionam que os sistemas de varredura a *laser* podem ser classificados como de amostragem de retorno discreto (*discrete-return*) ou na forma de onda (*waveform*). Inicialmente, os sistemas de amostragem discreta detectavam apenas o primeiro ou o último retorno dos pulsos emitidos, no entanto, com o aprimoramento da tecnologia, as duas informações são registradas, além de alguns retornos intermediários (GIONGO et al., 2010). Wagner et al. (2006) relatam que, de forma mais recente, foram desenvolvidos os sistemas de ondas contínuas (*full-waveform*), capazes de registrar integralmente todo sinal emitido pelo pulso. Segundo Mallet e Bretar (2009), sensores do tipo *full-waveform* fornecem maior controle ao usuário final no processo de interpretação da medição física, além de informações adicionais sobre a estrutura e as características físicas de retroespalhamento das superfícies iluminadas.

Figura 8 - Representação dos diferentes sistemas ALS (*Airborne Laser Scanning*): (A) sistema de pulsos ou de retornos discretos (*discrete-return*) e (B) sistema de ondas contínuas (*full-waveform*)



Fonte: Adaptado de Vosselman e Mass (2010).

### 2.2.5.2 Produtos derivados de levantamento ALS

A nuvem de pontos é o produto primário originado do levantamento ALS, refere-se a um conjunto de pontos tridimensionais, cujos eixos retratam a elevação da superfície e o par coordenadas planas georreferenciadas correspondente (MCMANAMON, 2019). As nuvens de pontos podem ser armazenadas e distribuídas em diversos formatos, no entanto, tem-se padronizado o uso de arquivos do tipo LAS (*LASer file*), na extensão *.las*, desenvolvido e gerenciado pela Sociedade Americana de Fotogrametria e Sensoriamento Remoto (*American Society for Photogrammetry and Remote Sensing - ASPRS*), com a intenção de fornecer um formato aberto que permita que diferentes ferramentas de hardware e software gerem dados em formato comum (ASPRS, 2019). O arquivo binário *.las* é um formato de arquivo público para o intercâmbio entre usuários e uma alternativa aos arquivos proprietários ou ao sistema genérico ASCII usado por muitas empresas (ASPRS, 2021).

A depender do contexto e das aplicações, as informações contidas nos arquivos LAS podem ser discretizadas em arquivos *raster* ou sintetizadas em métricas tomadas diretamente sobre a nuvem de pontos (D'OLIVEIRA et al., 2014). Tais métricas são descritas por Mcgaughey (2016), como uma variedade de parâmetros estatísticos que retratam determinado conjunto de dados LiDAR, tendo como base os valores de elevação e intensidade dos pontos. Em aplicações florestais, métricas relacionada a elevação dos pontos, especialmente altura média, são mais utilizadas (HAWBAKER et al., 2009; POPESCU et al., 2003; SHERIDAN et al., 2014). Para Gorgens et al. (2014), métricas que descrevem a intensidade da energia refletidas pelos objetos e registradas pelo sensor *laser*, são pouco empregadas na análise de dados LiDAR, em razão da grande variação que pode ser encontrada de um equipamento para outro, ou em levantamentos diferentes utilizando o mesmo equipamento.

No contexto florestal, *rasters* originados a partir de dados LiDAR são utilizados frequentemente para representação de Modelos Digitais de Terreno/Elevação (MDT/MDE), Modelos Digitais de Superfície (MDS) e Modelos Digitais de Altura de Copas (MDC) além de representação espacial dos modelos baseados em métricas (GORGENS et al., 2014; MALTAMO et al., 2014). Enquanto o MDT é produto da interpolação de pontos que caracterizam apenas a superfície descoberta do terreno, o MDS é gerado a partir da totalidade de pontos, englobando todas as feições da área mapeada (MCGAUGHEY, 2016). Já o MDC é o modelo produzido a partir da nuvem de pontos normalizada (KHOSRAVIPOUR et al., 2015). No processo de normalização a altitude elipsoidal dos pontos é convertida em cota altimétrica

pela subtração do MDT (WANG et al., 2008). O MDC também pode ser obtido via álgebra de *rasters*, pela subtração dos modelos MDS e MDT (AHMAD et al., 2017).

## 2.3 MONITORAMENTO DOS ESTOQUES DE BIOMASSA VEGETAL

### 2.3.1 Métodos empregados na estimativa de biomassa vegetal

A biomassa das árvores está relacionada ao seu volume, sua arquitetura e densidade de sua madeira (BONAN, 2008). Conforme relatam Popescu e Hauglin (2014), a biomassa florestal pode ser categorizada em dois componentes, denominados biomassa acima do solo (*Above-ground Biomass* – AGB), que engloba a totalidade do caule, galhos e folhas, e biomassa abaixo do solo (*Below-ground Biomass* - BGB), presente nas raízes. De acordo com Rodríguez-Veiga et al. (2017), a maior parte do carbono florestal é armazenado nas árvores na forma de AGB por meio do processo de fotossíntese, a qual é geralmente medida em toneladas de matéria seca por hectare ( $t \cdot ha^{-1}$  ou  $Mg \cdot ha^{-1}$ ).

Conforme relato de Sanquetta (2002), a biomassa florestal pode ser quantificada de forma direta, ou indireta, via modelos matemáticos. Pelo método direto, as árvores são abatidas e seus componentes são segregados e pesados (SILVEIRA et al., 2008). Já pelo método indireto, equações alométricas são utilizadas para converter variáveis estruturais como diâmetro, altura e densidade da madeira, em valores de biomassa (CHAVE et al., 2005). De acordo com Vieira et al. (2008), os modelos alométricos podem ser específicos, quando construídos visando atender um ecossistema em particular, ou gerais, quando permitem a estimativa de biomassa em diferentes locais.

Watzlawick (2003), menciona que em razão da maior carga de trabalho a campo, os métodos diretos para quantificação da biomassa florestal são mais onerosos e demandam maior tempo, de modo que, em trabalhos onde se deseja apenas a quantificação da biomassa e carbono e não outros elementos químicos, métodos indiretos (não destrutivos) tornam-se mais atrativos. A estimativa indireta da biomassa está condicionada a realização de um inventário florestal utilizando parcelas, seguido da escolha apropriada de equações alométricas e, por fim, a extrapolação dos resultados (CHAVE et al., 2004; HENRY et al., 2010). No entanto, como mencionam Hickey et al. (2018), aplicar equações alométricas em uma grande área, torna-se uma abordagem intrincada, e por vezes inviável, tendo em vista a dificuldade de obtenção das variáveis estruturais da floresta a campo.

De acordo com Lu et al. (2014), nas últimas três décadas, pesquisas substanciais foram conduzidas aplicando técnicas de sensoriamento remoto nas estimativas indiretas de AGB em ambientes florestais. Ainda assim, mesmo que em menor intensidade, medidas tomadas a campo são necessárias para calibração e validação das estimativas via sensoriamento remoto (POPESCU; HAUGLIN, 2014). Nesse sentido, a abordagem natural é a utilização de modelos de regressão que associam dados derivados de sensores remotos aos valores de biomassa tomados à campo, de maneira que os modelos ajustados são empregados para estimativas ao longo da paisagem (ALMEIDA et al., 2019; GIONGO et al., 2010; LEITOLD et al., 2015; TIMOTHY et al., 2016).

### 2.3.2 Integração de bases e *Upscaling*

As técnicas para estimar a AGB das florestas com base em dados de sensoriamento remoto desencadearam o processo denominado *scale-up*, ou extrapolação dos dados coletados a campo para áreas de maior abrangência (BACCINI et al., 2012; CHEN et al., 2018; SAATCHI et al., 2011). Trata-se de um processo de mapeamento preditivo, no qual o valor da variável de interesse é estimado para determinado local onde não exista observação direta (CHEN et al., 2018). Conforme relato de Schwieder et al. (2018), a possibilidade de extrapolação das amostras de campo para pixels alvo, é essencialmente o que viabiliza o uso de imagens de sensoriamento remoto para mapeamento e monitoramento de ecossistemas em ambientes heterogêneos. Em contraste com medidas pontuais realizadas a campo, essa técnica permite a criação de mapas com a representação contínua da biomassa e pode melhorar as estimativas do fluxo de carbono, tendo em conta o fornecimento de informações espacialmente consistentes para regiões de difícil acesso (HOUGHTON, 2005).

Na prática, o escalonamento (*scaling*) pode ser realizado em uma abordagem de baixo para cima (*bottom-up*) ou de cima para baixo (*top-down*): *Upscaling* consiste em usar informações em escalas menores para derivar informações em escalas maiores, enquanto *downscaling* consiste em decompor a informação mais detalhada e representá-la em escalas menores (HAY et al., 2001). De acordo com Tatsch et al. (2009), o processo de *upscaling* pode ser realizado de forma direta ou em duas etapas. Segundo os autores, no primeiro caso a informação é convertida diretamente entre alta e baixa resolução, já no segundo caso, uma resolução intermediária é empregada no fluxo da informação.

No contexto florestal, a escala dos levantamentos constitui papel chave na precisão e abrangência do monitoramento das variáveis (SAGANG et al., 2020). Abordagens tradicionais,

via amostragem de campo, fornecem valores de AGB mais precisos, mas são destrutivas e possuem abrangência limitada no tempo e no espaço (ENE et al., 2013; WATZLAWICK, 2003; WU et al., 2016). Dentre as fontes de dados de sensoriamento remoto, o LiDAR encontra-se entre os mais precisos para a estimativa de AGB porque é capaz de fornecer medições acuradas da estrutura da floresta (CLARK et al., 2011; JIANG et al., 2020; LEFSKY et al., 2002). No entanto, observações LiDAR apresentam restrições devido sua característica amostral, o que limita a observação de ecossistemas de forma contínua no espaço, já que não são generalizáveis além da localização do estudo em questão (DUBAYAH et al., 2020; HANCOCK et al., 2019; VALBUENA et al., 2020). Por sua vez, dados ópticos de sensores orbitais apresentam alcance global e capacidade temporal para monitoramento dos recursos florestais. Contudo, possuem limitações para resgatar elementos estruturais do dossel florestal, como altura e arranjo vertical dos estratos (VALBUENA et al., 2020). A saturação de dados ópticos têm sido reconhecida como um fator importante que causa subestimação para sítios florestais com alta AGB (LI et al., 2019). Avitabile e Camia (2018), relatam a baixa sensibilidade desses sensores em regiões de alta densidade de AGB (e.g.  $>200 \text{ Mg}\cdot\text{ha}^{-1}$ ). Lu et al. (2012) salientam que dados multiespectrais Landsat TM podem fornecer estimativas de biomassa adequadas para a sucessão secundária, mas não são adequados para estimativas de florestas maduras, devido à saturação. Ademais, para Lu (2006), a estimativa de biomassa em grandes áreas é limitada pela a resolução espacial de imagens orbitais que possuem pixels de composição mista em relação aos dados de referência na superfície.

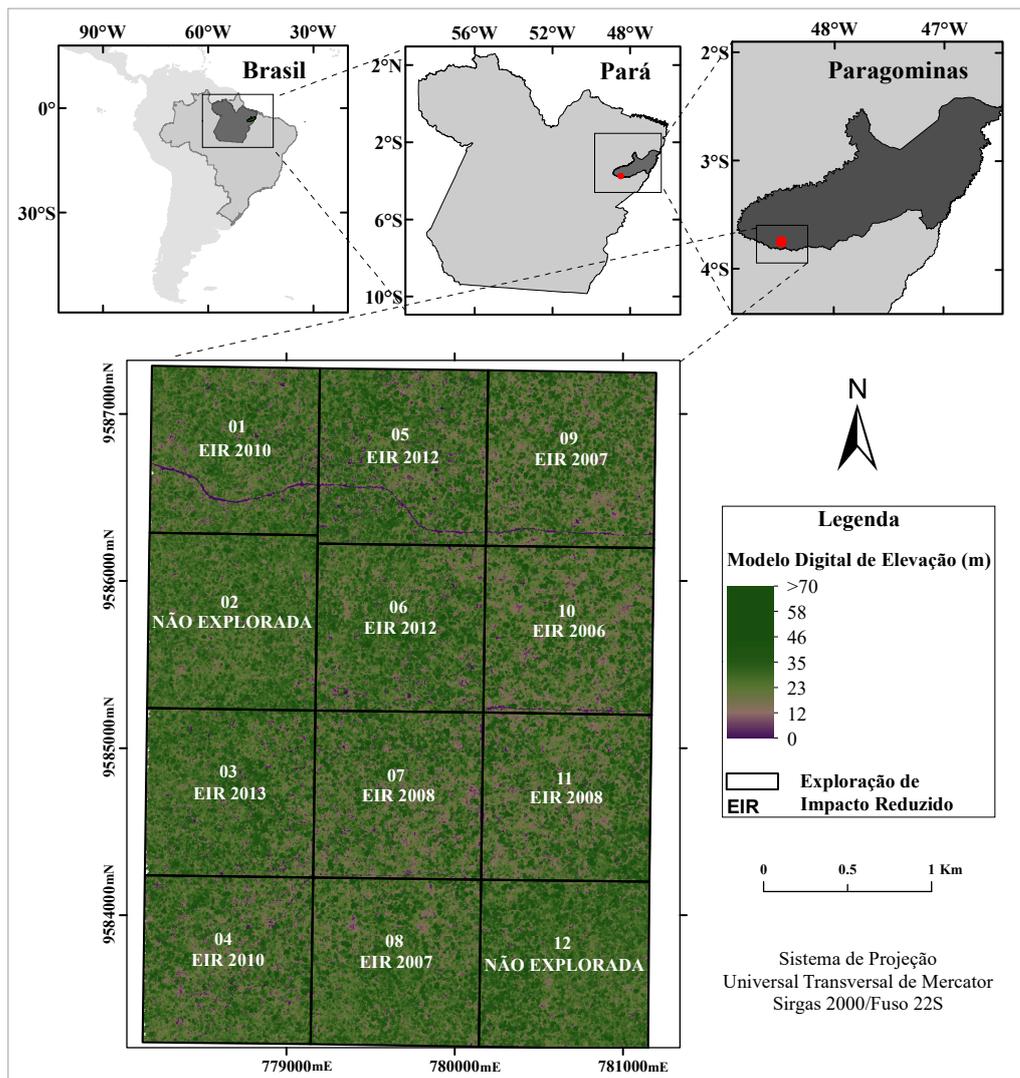
Tendo em vista as restrições individuais de cada abordagem, Bispo et al. (2020), relatam que a combinação de dados de sensoriamento remoto em diferentes escalas, com inventários de vegetação local, fornece os meios para quantificar a AGB em grandes áreas. Os sistemas multiplataforma e multissensor, com definições claras dos aspectos da estrutura do ecossistema abrangido, fornecem uma solução realista para avaliações globais de variáveis ecológicas, de forma prática, viável economicamente e sustentável no tempo (GEIJZENDORFFER et al., 2017; JETZ et al., 2019). Nesse sentido, dados ALS-LiDAR podem ser usados como um nível intermediário para aumentar substancialmente a amostragem de campo e aprimorar a calibração dos modelos (SAGANG et al., 2020; WANG et al., 2020). Por fim, dados orbitais abertos, como no caso das missões Landsat e Sentinel, podem ser empregados com a finalidade de extrapolar as estimativas LIDAR para além da área de aquisição (VALBUENA et al., 2020), ampliando, assim, a abrangência do levantamento.

### 3 MATERIAIS E MÉTODOS

#### 3.1 ÁREA DE ESTUDO

O local de estudo compreende uma extensão de 1.260 ha, localizado na fazenda Cauaxi, município de Paragominas, nordeste do estado do Pará, Brasil (Figura 9). O clima do município é do tipo Awi (classificação de Köppen - clima tropical chuvoso, com período significativo de seca), com temperatura média anual e precipitação pluvial média de 26,3° C e 1.700 mm, respectivamente (BASTOS et al., 2006). A tipologia florestal predominante na área de estudo é a Floresta Ombrófila Densa (MMA, 2002). Dominam a região Latossolos Amarelos de texturas média a muito argilosa (RODRIGUES et al., 2003), descritos como profundos, bem drenados e dissaturados, cuja ocorrência é associada a padrões de relevo plano a ondulado (DUARTE; CARNEIRO, 2017).

Figura 9 - Representação da área de estudo, localizada na fazenda Cauaxi, município de Paragominas, Pará



Fonte: Autor (2023).

A área de estudo encontra-se subdividida em 12 unidades de manejo (Figura 9), das quais dez são destinadas ao regime de extração de impacto reduzido (SILVA et al., 2017). A Tabela 3 apresenta os quantitativos dos volumes extraídos nas diferentes unidades de manejo entre os anos de 2006 e 2013. De acordo com Pinagé et al. (2019), cinco espécies respondem por quase 50% do volume total extraído, *Manilkara huberi* (Sapotaceae), *Manilkara paraensis* (Sapotaceae), *Chrysophyllum venezuelanense* (Sapotaceae), *Astronium lecointei* (Anacardiaceae), e *Hymenaea courbaril* (Fabaceae).

Tabela 3 – Característica das unidades de manejo florestal da fazenda Cauaxi, Paragominas/PA, sob regime de extração de impacto reduzido

Unidade	Área (ha)	Ano da colheita	Volume (m <sup>3</sup> /ha)	Volume *Efetivo (m <sup>3</sup> /ha)
01 EIR2010	99,9	2010	11,03	12,05
02 Não explorada	104,9	Intacta	-	-
03 EIR2013	99,9	2013	11,73	14,38
04 EIR2010	99,9	2010	21,46	23,79
05 EIR2012	104,9	2012	24,51	26,65
06 EIR2012	99,9	2012	14,99	19,32
07 EIR2008	99,9	2008	23,60	23,62
08 EIR2007	99,9	2007	14,41	17,76
09 EIR2007	105,9	2007	27,82	28,10
10 EIR2006	99,9	2006	21,29	21,29
11 EIR2008	99,9	2008	22,79	23,60
12 Não explorada	100,5	Intacta	-	-

Legenda: EIR – Exploração de Impacto Reduzido

\*A área efetiva do bloco remove todas as áreas com declives >20 graus (critério operacional).

Fonte: Adaptado de Pinagé et al. (2019).

### 3.2 BASE DE DADOS

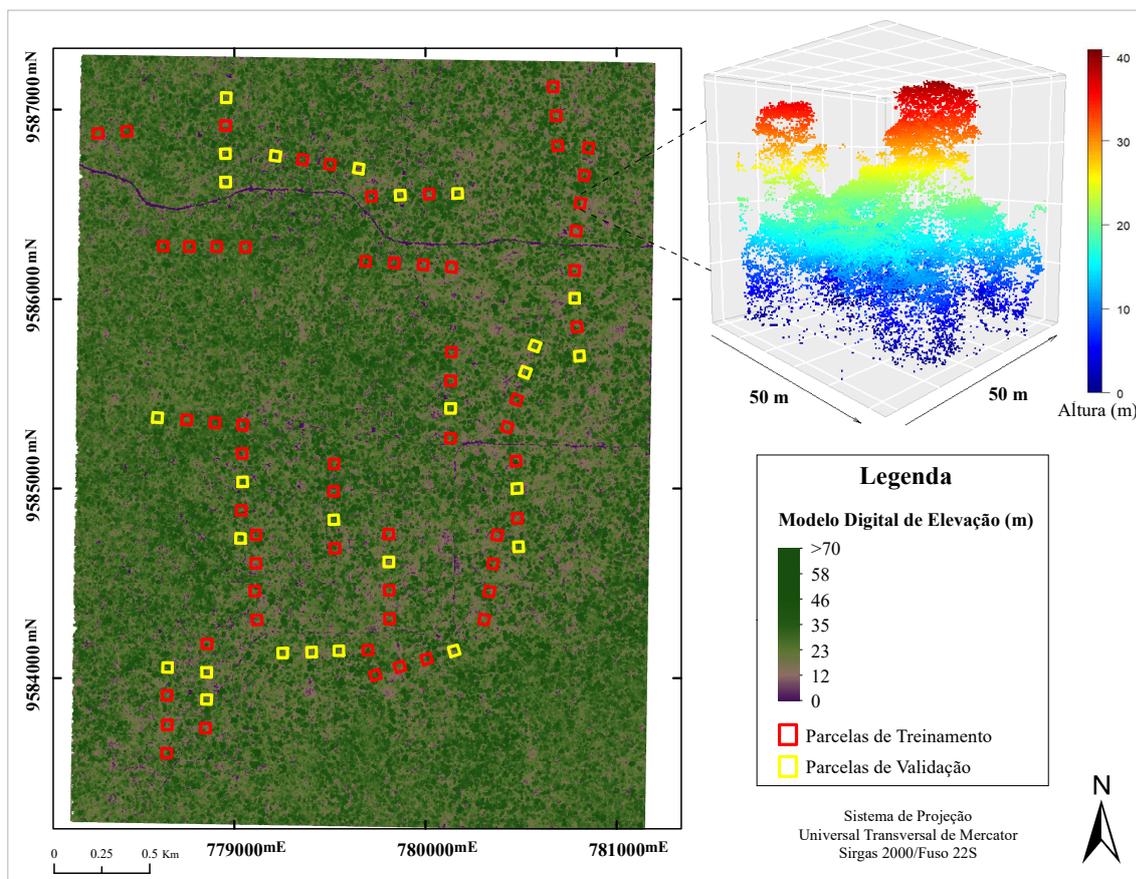
A base de dados da pesquisa foi composta por três categorias: Dados de inventário florestal; dados de aerolevanteamento LiDAR e imagens do sensor OLI (*Operational Land Imager*), embarcado no satélite Landsat-8. As nuvens de pontos LiDAR, assim como os dados de inventário florestal, foram adquiridos de forma gratuita junto ao ambiente *web* do Projeto Paisagens Sustentáveis Brasil (EMBRAPA, 2016). Por sua vez, as imagens OLI/Landsat-8 foram obtidas junto a USGS - *United States Geological Survey* (USGS, 2023a), também sem custos de aquisição.

O inventário florestal realizado na fazenda Cauaxi transcorreu no período entre 18/02/2014 e 25/04/2014, com o levantamento de 88 unidades amostrais (UA) regulares de 50x50m. Cada UA compunha-se de uma subparcela de dimensão 5x50 m. Nas subparcelas, o

DAP de inclusão para amostragem foi de 10 cm, enquanto no restante da unidade o limiar estabelecido foi de 35 cm. A nível de indivíduo, a base de dados dispõe de informações como nome científico, DAP, densidade da madeira, posição sociológica, par de coordenadas UTM, entre outros atributos. Do total de UA levantadas a campo, três não possuem cobertura de dados LiDAR, dessa forma, 85 UA integraram a base de dados inicial para modelagem.

Tendo em vista a condição de referência no processo de modelagem, as parcelas do inventário foram divididas de modo aleatório em 70% para treinamento/ajuste e 30% para teste/validação dos modelos. A separação da amostra tende a evitar que os modelos de aprendizado de máquina sejam supertreinados, assim, recomenda-se utilizar um conjunto de teste para medir o poder preditivo a partir de novos dados (CORRALES et al., 2015). A Figura 10 traz a espacialização dos subconjuntos de treinamento e validação ao longo da área de estudo.

Figura 10 - Distribuição das unidades amostrais inventariadas ao longo da área de estudo da fazenda Cauaxi, município de Paragominas/PA, e sua divisão aleatória entre as classes de treinamento e validação para o processo de modelagem da AGB via dados de sensoriamento remoto



Fonte: Autor (2023).

Por sua vez, o aerolevanteamento LiDAR foi realizado no mês de dezembro de 2014. Embora não corresponda exatamente à janela do inventário, o período já coincide ao de maior vigor vegetativo da região, após a retomada do regime sazonal das chuvas, durante a primavera. As características gerais do aerolevanteamento LiDAR realizado na área de estudo são apresentadas na Tabela 4.

Tabela 4 – Síntese sobre os dados de voo, características do sensor utilizado e os atributos das nuvens de pontos resultantes do aerolevanteamento LiDAR realizado na fazenda Cauaxi, Paragominas, Pará

Data do levantamento	26/12/2014 e 27/12/2014
Área recoberta	1.216 ha
Sobreposição da faixa de voo	65%
Densidade média de retornos	61,38 ppm <sup>2</sup> *
Densidade média do primeiro retorno	37,5 ppm <sup>2</sup>
Altitude média de voo	850 m
Ângulo de visada	12°
Sensor	OPTECH, ORION M300
Frequência do scanner	83 Hz
GNSS	APPLANIX, 09SEN243
Frequência GNSS	5 Hz
UMI (Unidade de Mensuração Inercial)	LITTON, 413996
Frequência UMI	100 kHz

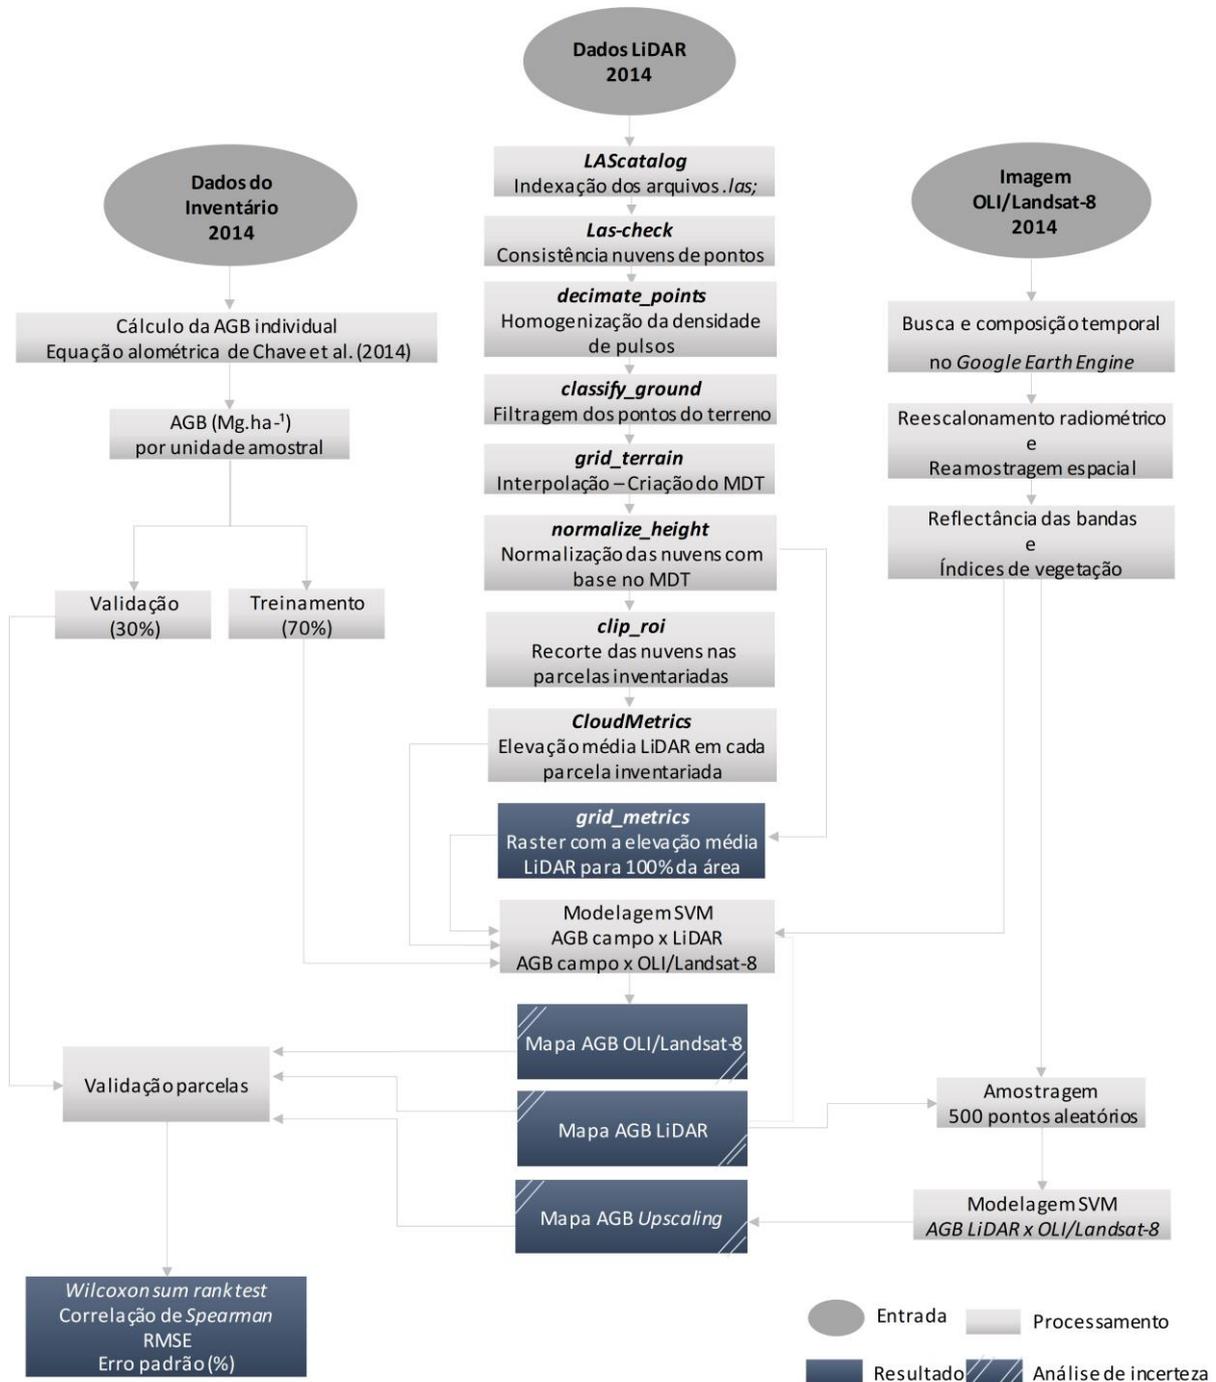
\*Pontos por metro quadrado

Fonte: Adaptado de Paisagens Sustentáveis Brasil (2016).

### 3.3 MODELAGEM E *UPSCALING* DA AGB

O método utilizado para modelagem da biomassa acima do solo presente na área amostral da fazenda Cauaxi considerou três abordagens distintas e seguiu o fluxo destacado na Figura 11. Nas duas primeiras, dados LiDAR e OLI/Landsat-8 foram associados diretamente à AGB derivada das medições à campo. Já pela abordagem alternativa, o mapa de AGB estimado via LiDAR foi tomado como referência para modelagem utilizando dados OLI/Landsat-8. A descrição de cada etapa da metodologia é apresentada nas subseções seguintes do texto.

Figura 11 - Fluxograma com o método utilizado para o *upscaling* e mapeamento da biomassa acima do solo em região de Floresta Amazônica, a partir da associação entre dados de campo, nuvens de pontos LiDAR e imagens OLI/Landsat-8



Fonte: Autor (2023).

### 3.3.1 Pré-processamento dos dados

#### 3.3.1.1 Dados de inventário florestal

A biomassa acima do solo (AGB) das árvores registradas no inventário florestal foi calculada, a nível de indivíduo, a partir da equação pantropical (Equação 3) apresentada por Chave et al. (2014), empregada em diversos estudos que abordam estimativas de AGB via dados de campo (CHEN et al., 2016; MARCHESAN et al., 2020; SATO et al., 2016; SCHUH et al., 2020; TANAGO et al., 2018). Em razão da alta diversidade de espécies presente em ecossistemas tropicais, modelos alométricos generalistas (espécies mistas) são mais apropriados do que equações específicas a nível de espécie (BROWN, 2002; CHAVE et al., 2005).

$$AGB \text{ (kg)} = \exp [-1,803 - 0,976E + 0,976 \ln(\rho) + 2,673 \ln(dap) - 0,0299 [\ln(dap)]^2] \quad (3)$$

Em que: *AGB (kg)* é a biomassa acima do solo da árvore viva em Kg; *dap* é o diâmetro do fuste, medido à 1,30 m do solo;  $\rho$  é a densidade da madeira; *E* é uma medida de estresse ambiental que considera a sazonalidade da temperatura, precipitação e déficit hídrico climático. A partir de coordenadas geográficas do local de estudo foi possível obter o valor da constante *E*, utilizando as funções do pacote BIOMASS (RÉJOU-MÉCHAIN et al., 2017), em linguagem R. Para a presente área de estudo adotou-se  $E = -0,103815$ .

Por meio da biomassa individual, computou-se o total de AGB por parcela, valor esse convertido em toneladas por hectare ou  $Mg \cdot ha^{-1}$ . Com base nos dados à nível de parcela, calculou-se o erro amostral e os intervalos de confiança para a média e o total da população com 95% de probabilidade. O Anexo A lista as equações das estatísticas calculadas no tratamento dos dados derivados do inventário florestal.

#### 3.3.1.2 Dados LiDAR aerotransportado

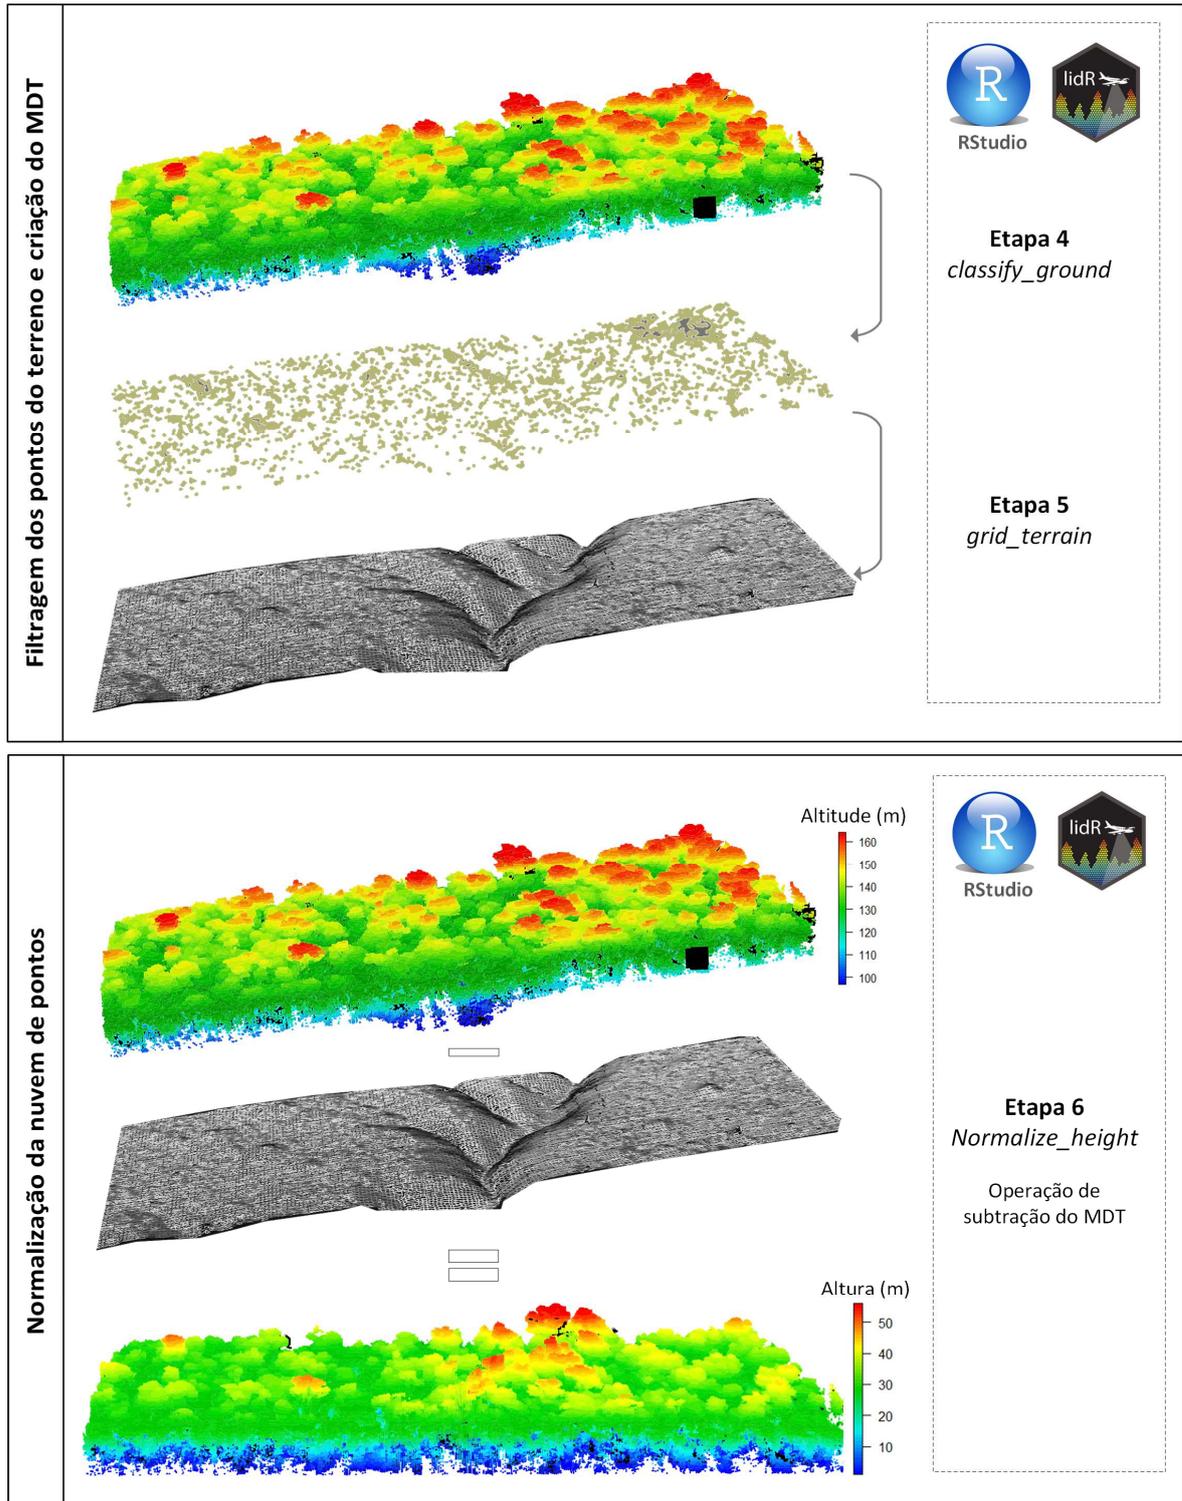
As nuvens de ponto LiDAR foram processadas em linguagem R (R CORE TEAM, 2021), na interface de programação RStudio® (RSTUDIO TEAM, 2021), utilizando como suporte o pacote *lidR* (ROUSSEL et al., 2020), desenvolvido em código aberto, e que dispõe de ferramentas para manipulação e tratamento de dados ALS com ênfase em aplicações florestais. Na Tabela 5 estão descritas as nove etapas envolvidas no processamento dos dados LiDAR no presente estudo, das quais três encontram-se ilustradas na Figura 12. No Apêndice A pode ser consultada a rotina computacional desenvolvida em linguagem R com as referidas etapas de processamento.

Tabela 5 – Ferramentas do pacote *lidR* utilizadas nas etapas de processamento das nuvens de pontos LiDAR em linguagem de programação R

<b>Etapa/ Ferramenta</b>	<b>Finalidade</b>
<b>Etapa 1</b> <i>LAScatalog</i>	Indexação dos conjuntos de arquivos <i>.las</i> com o objetivo de gerenciar o conjunto inteiro da base de dados, permitindo processar áreas extensas de forma sistemática, sem carregar todas as informações na memória do computador de forma simultânea.
<b>Etapa 2</b> <i>las-check</i>	Relatório descritivo para avaliação da qualidade e consistência dos dados, permitindo a verificação de ruídos.
<b>Etapa 3</b> <i>decimate_points</i>	Homogeneização da densidade de pulsos ao longo de toda área de cobertura. Sobre uma grade definida, o algoritmo filtra a nuvem de pontos selecionando aleatoriamente alguns pontos na célula, até que se atinja a densidade desejada (ROUSSEL; AUTY, 2021). Essa abordagem pode ser útil quando os dados LiDAR são adquiridos usando diferentes densidades de pulso, ou quando um único conjunto de dados LiDAR não é uniforme, por exemplo, em intervalos de sobreposição de linha de voo (MCGAUGHEY, 2016). No presente estudo, a densidade de pulsos final desejada foi definida como 12 ppm <sup>2</sup> (pulso por metro quadrado), utilizando uma janela de busca de 25m, conforme abordagem proposta por Silva et al. (2017).
<b>Etapa 4</b> <i>classify_ground</i>	Filtragem dos pontos representativos do terreno, diferenciando-os da vegetação. O algoritmo utilizado é conhecido como Filtro Morfológico Progressivo, do inglês <i>PMF - Progressive Morphological Filter</i> . Proposto por Zhang et al. (2003), o PMF, busca pontos do terreno utilizando um limiar de altura dentro de uma janela móvel de busca.
<b>Etapa 5</b> <i>grid_terrain</i>	Criação do Modelo Digital do Terreno – MDT (com resolução espacial de um metro), a partir da interpolação dos pontos relativos ao terreno.
<b>Etapa 6</b> <i>normalize_height</i>	Normalização das nuvens de pontos com base no MDT. Nesse processo a altimetria de cada ponto é relativizada em relação a superfície do terreno, transformando a elevação elipsoidal em cota altimétrica. Dessa forma, o efeito do terreno sobre a coordenada z dos pontos é eliminado, permitindo a tomada direta da altura do dossel.
<b>Etapa 7</b> <i>clip_roi</i>	Recorte das nuvens nas parcelas inventariadas utilizando como máscara arquivo vetorial em formato <i>shapefile</i> .
<b>Etapa 8</b> <i>cloud_metrics</i>	Computar métricas LiDAR em cada parcela inventariada. As métricas LiDAR são estatísticas que descrevem determinado conjunto de dados LiDAR em função dos valores de altimetria e intensidade dos pontos (MCGAUGHEY, 2016).
<b>Etapa 9</b> <i>grid_metrics</i>	Criar um arquivo <i>raster</i> representativo de cada métrica calculada sobre as nuvens de pontos LiDAR. Os arquivos <i>raster</i> foram gerados com resolução espacial de 50 m para compatibilizar a escala com as parcelas inventariadas.

Fonte: Autor (2023).

Figura 12 – Representação esquemática das etapas 4 (*classify\_ground*), 5 (*grid\_terrain*) e 6 (*normalize\_height*) do processamento das nuvens de pontos LiDAR por meio das ferramentas do pacote *lidR*



Fonte: Autor (2023).

### 3.3.1.3 Dados OLI/Landsat-8

As imagens OLI/Landsat-8 foram processadas na plataforma *Google Earth Engine - GEE* (GORELICK et al., 2017), descrita pelos desenvolvedores como uma plataforma baseada em nuvem que hospeda acervos alimentados diariamente com imagens orbitais gratuitas e, fornece APIs (*Application Programming Interfaces*) e outras ferramentas computacionais para análise maciça de dados em aplicações científicas.

A coleção escolhida para o trabalho já possui tratamento prévio e corresponde a dados de reflectância de superfície (Tabela 6). Os dados de reflectância de superfície OLI/Landsat-8 são gerados utilizando o algoritmo *Land Surface Reflectance Code – LaSRC*, que corrige os efeitos da dispersão e absorção de gases atmosféricos, aerossóis e vapor de água, o que é necessário para caracterizar de forma confiável a superfície terrestre (USGS, 2023c). Para tanto, o algoritmo *LaSRC* faz uso da banda de aerossol costeira para realizar testes de inversão de aerossol, usa dados climáticos auxiliares do sensor MODIS e um modelo exclusivo de transferência radiativa (VERMOTE et al., 2016; 2018).

Tabela 6 – Atributos da coleção presente no catálogo da plataforma *Google Earth Engine - GEE* que fornece dados de reflectância de superfície do sensor OLI/Landsat-8

Catálogo <i>GEE</i>	<i>LANDSAT/LC08/C02/T1_L2</i>	
	<ul style="list-style-type: none"> <li>• <i>C02</i> – Coleção 2 (atual), maior disponibilidade de dados em relação a primeira, mantida no <i>GEE</i> até 01/01/2023;</li> <li>• <i>T1 (Tier 1)</i> - Atende aos requisitos de qualidade geométrica e radiométrica;</li> <li>• <i>L2 (Level 2)</i> – Processamento nível 2 (Reflectância de superfície).</li> </ul>	
Radiometria	Número inteiro de 16 bits	
Escala radiométrica real	1 – 65.455	
Fatores da escala radiométrica	<i>Gain</i>	0,0000275
	<i>Offset</i>	-0,2

Fonte: Adaptado de Gorelick et al. (2017) e USGS (2023c).

A busca de dados no acervo de imagens OLI/Landsat-8 teve como referência à janela temporal de realização do inventário florestal e do sobrevoo LiDAR, dessa forma todo ano de 2014 foi adotado como referência inicial. Além do intervalo de datas, foi definido nos critérios de pesquisa, o resgate de cenas entre 10% e 90% recobertas por nuvem. Para cada cena presente no catálogo resultante da busca foi aplicada uma máscara a fim de remover pixels saturados,

assim como aqueles correspondentes a nuvens e sombras. Essa operação foi realizada por meio das informações assinaladas na banda de saturação de pixel (*QA\_RADSAT*) e na banda de avaliação da qualidade dos pixels (*QA\_PIXEL*). Na sequência, a função nativa do *GEE*, de composição mediana por pixel, foi aplicada a cada uma das bandas espectrais das cenas. Essa operação tem a finalidade de remover pixels escuros (por exemplo, devido à sombra), bem como pixels anormalmente brilhantes (por exemplo, devido à nuvem, neblina ou neve remanescente) do composto resultante (HIRD et al., 2017).

Foram realizados sucessivos testes, variando os critérios de busca em relação as datas e cobertura de nuvem. Como critério de seleção da composição de cena ideal, levou-se em conta a correlação entre os dados espectrais e os valores de referência da AGB nas parcelas inventariadas. Por fim, optou-se pelo uso de uma única cena, datada de 21/12/2014, sob o código de identificação *LANDSAT/LC08/C02/T1\_L2/LC08\_223063\_20141221*. O Apêndice B traz a rotina em linguagem *JavaScript* com a sequência de comandos utilizados. Usuários cadastrados na plataforma *GEE* podem ter acesso aberto ao código pelo seguinte endereço <<https://code.earthengine.google.com/87bc896e0f23461656e2385c41c1cf4c>>.

A composição temporal no *GEE* é uma boa alternativa ao se trabalhar em regiões de elevada precipitação como é o caso da Amazônia. No entanto, ao expandir a janela de datas visando obter uma composição de cena livre de nuvens, os dados espectrais perderam a relação com a variável biofísica a campo, de modo que o uso de apenas uma imagem se mostrou mais eficaz. Mesmo utilizando uma busca criteriosa de cenas, uma pequena porção da imagem escolhida possui cobertura de nuvem, o que determinou a exclusão de quatro, das 85 UA inicialmente elencadas para a modelagem. Dessa forma, 81 UA compuseram a base de dados final para o processo de modelagem.

A partir das bandas espectrais da imagem OLI/Landsat-8 foram computados, também na plataforma *GEE*, índices de vegetação compatíveis com o sensor (Tabela 7). O catálogo disponível no portal *Index DataBase – IDB* (HENRICH et al., 2012), foi usado como referência para a construção dos referidos índices. Dessa forma, a base de dados espectral ficou composta de 54 variáveis (reflectâncias das bandas 1 a 7, além de 47 índices de vegetação). Por fim, todos os arquivos *raster* derivados do sensor OLI/Landsat-8 foram reamostrados para resolução espacial de 50m para compatibilizar sua escala com as parcelas de inventário.

Tabela 7 - Índices de vegetação adaptados às bandas do sensor OLI/Landsat-8 que compuseram a base de dados para modelagem da biomassa acima do solo na fazenda Cauaxi, município de Paragominas-PA

(continua)

	<b>Índice de vegetação</b>	<b>Abreviatura</b>	<b>Expressão matemática</b>
1	<i>Adjusted Transformed Soil-Adjusted VI</i>	ATSAVI	$1,22 \frac{B5 - 1,22B4 - 0,03}{1,22B5 + B4 - (1,22)(0,03) + 0,08(1 + 1,22^2)}$
2	<i>Aerosol Free Vegetation Index 1600</i>	AFRI1600	$B5 - 0,66 \frac{B6}{B5 + 0,66B6}$
3	<i>Atmospherically Resistant Vegetation Index 2</i>	ARVI 2	$-0,18 + 1,17[(B5-B4) / (B5+B4)]$
4	<i>Blue-Wide Dynamic Range Vegetation Index</i>	BWDRVI	$(0,1B5-B2) / (0,1B5+B2)$
5	<i>Chlorophyll Index Green</i>	CIGreen	$(B5 / B3) - 1$
6	<i>Chlorophyll Vegetation Index</i>	CVI	$B5(B4 / B3^2)$
7	<i>Simple Ratio</i>	SR	$B5/B4$
8	<i>Normalized Difference Vegetation Index</i>	NDVI	$(B5-B4) / (B5+B4)$
9	<i>Coloration Index</i>	CI	$(B4-B2) / B4$
10	<i>Corrected Transformed Vegetation Index</i>	CTVI	$\frac{(B5-B3)/(B5+B3) + 0,5}{ (B5-B3)/(B5+B3) + 0,5 } \sqrt{ (B5-B3)/(B5+B3) + 0,5 }$
11	<i>Green Difference Vegetation Index</i>	GDVI	$B5-B3$
12	<i>Enhanced Vegetation Index</i>	EVI	$2,5[(B5-B4) / ((B5+6B4-7,5B2) + 1)]$
13	<i>Global Environment Monitoring Index</i>	GEMI	$\frac{n(1 - 0,25n) - ((B4 - 0,125) / (1 - B4))}{n = (2(B5^2 - B4^2) + 1,5B5 + 0,5B4) / (B5 + B4 + 0,5)}$
14	<i>Green Leaf Index</i>	GLI	$(2B3-B4-B2) / (2B3+B4+B2)$
15	<i>Soil-Adjusted Vegetation Index</i>	SAVI	$[(B5-B4) / (B5+B4+0,5)] 1,5$
16	<i>Green Optimized Soil Adjusted Vegetation Index</i>	GOSAVI	$(B5-B3) / (B5+B3+0,16)$
17	<i>Green Soil Adjusted Vegetation Index</i>	GSAVI	$[(B5-B3) / (B5+B3+0,5)] 1,5$
18	<i>Green-Blue Ndvi</i>	GBNDVI	$(B5-(B3+B2)) / (B5+(B3+B2))$
19	<i>Green-Red Ndvi</i>	GRNDVI	$(B5-(B3+B4)) / (B5+(B3+B4))$
20	<i>Hue</i>	HUE	$\arctan [((2B4-B3-B2) / 30,5) (B3-B2)]$
21	<i>Infrared Percentage Vegetation Index</i>	IPVI	$(B5/((B5+B4)/2)) ((B4-B3/B4+B3) + 1)$
22	<i>Intensity</i>	I	$(1 / 30,5) (B4+B3+B2)$
23	<i>Mid-Infrared Vegetation Index</i>	MVI	$B5/B6$
24	<i>Modified Soil Adjusted Vegetation Index</i>	MSAVI	$[2B5 + 1 - \sqrt{(2B5+1)^2 - 8(B5-B4)}] / 2$

Tabela 7 - Índices de vegetação adaptados às bandas do sensor OLI/Landsat-8 que compuseram a base de dados para modelagem da biomassa acima do solo na fazenda Cauaxi, município de Paragominas-PA (conclusão)

	Índice de vegetação	Abreviatura	Expressão matemática
25	<i>Norm G</i>	Norm G	$B3 / (B5+B4+B3)$
26	<i>Norm NIR</i>	Norm NIR	$B5 / (B5+B4+B3)$
27	<i>Norm R</i>	Norm R	$B4 / (B5+B4+B3)$
28	<i>Normalized Green Red Difference Index</i>	NGRDI	$(B3-B4) / (B3+B4)$
29	<i>Blue-Normalized Difference Vegetation Index</i>	BNDVI	$(B5-B2) / (B5+B2)$
30	<i>Green-Normalized Difference Vegetation Index</i>	GNDVI	$(B5-B3) / (B5+B3)$
31	<i>Modified Normalized Difference Vegetation Index</i>	MNDVI	$(B5-B7) / (B5+B7)$
32	<i>Normalized Difference Red/Green Redness Index</i>	RI	$(B4-B3) / (B4+B3)$
33	<i>Pan NDVI</i>	PNDVI	$[B5-(B3+B4+B2)] / [B5+(B3+B4+B2)]$
34	<i>Red-Blue NDVI</i>	RBNDVI	$[B5-(B4+B2)] / [B5+(B4+B2)]$
35	<i>Shape Index</i>	IF	$[2B4-B3-B2] / [B3-B2]$
36	<i>Blue Green Pigment Index</i>	BGI	$B1/B3$
37	<i>Simple Ratio 560/658 Gviihyper</i>	SR560/658	$B3/B4$
38	<i>Ratio Drought Index</i>	RDI	$B7/B5$
39	<i>Green Ratio Vegetation Index</i>	GRVI	$B5/B3$
40	<i>Red-Green Ratio</i>	RGR	$B4/B3$
41	<i>Specific Leaf Area Vegetation Index</i>	SLAVI	$B5 / (B4+B7)$
42	<i>Tasselled Cap - brightness</i>	SBI	$0.3037B2 + 0.2793B3 + 0.4743B4 + 0.5585B5 + 0.5082B9 + 0.1863B7$
43	<i>Tasselled Cap - vegetation</i>	GVI	$-0.2848B2 - 0.2435B3 - 0.5436B4 + 0.7243B5 + 0.0840B6 - 0.1800B7$
44	<i>Tasselled Cap - wetness</i>	WET	$0.1509B2 + 0.1973B3 + 0.3279B4 + 0.3406B5 - 0.7112B6 - 0.4572B7$
45	<i>Transformed Vegetation Index</i>	TVI	$\sqrt{((B4-B3) / (B4+B3)) + 0,5}$
46	<i>Wide Dynamic Range Vegetation Index</i>	WDRVI	$0,1(B5-B4) / 0,1(B5+B4)$
47	<i>Normalized Difference Moisture Index</i>	NDMI	$(B5-B6) / (B5+B6)$

Fonte: Adaptado de Henrich et al. (2012).

### 3.3.2 Composição e implementação dos modelos

A combinação de variáveis utilizadas no processo de modelagem da AGB nas fases de treinamento e validação é apresentada na Tabela 8. Na abordagem AGB LiDAR apenas um preditor foi utilizado. A métrica de elevação média derivada do processamento das nuvens de pontos LiDAR foi associada a AGB correspondente em cada unidade amostral do inventário, compondo a base de dados para criação do modelo. Para mesma área de estudo, ao avaliar a importância de métricas LiDAR como preditoras na modelagem de AGB via aprendizado de máquina, Marchesan et al. (2020) e Schuh et al. (2020), identificaram a elevação média como melhor variável explicativa. Esse padrão é observado na literatura, onde a métrica de elevação média do dossel é comumente utilizada em estudos de biomassa florestal a partir de dados LiDAR, como é o caso de Popescu et al. (2003), Hawbaker et al. (2009) e Sheridan et al. (2014). O modelo treinado com os dados das parcelas foi submetido ao *raster* de elevação média derivada das nuvens de pontos LiDAR, dando origem ao mapa de AGB para toda área de estudo.

Tabela 8 – Composição das três abordagens utilizadas para modelagem da biomassa acima do solo na fazenda Cauaxi via associação entre dados de campo e de sensores remotos

Abordagem	Treinamento			Validação
	Preditores	Variável resposta	Amostra	
AGB LiDAR	Elevação média LiDAR	AGB campo	57 parcelas	AGB campo 24 parcelas
AGB OLI/Landsat-8	7 bandas OLI 47 índices de vegetação	AGB campo	57 parcelas	
AGB <i>Upscaling</i>	7 bandas OLI 47 índices de vegetação	Mapa AGB LiDAR	500 pontos aleatórios	

Fonte: Autor (2023).

Por sua vez, na abordagem AGB OLI/Landsat-8 levou-se em conta a associação direta entre as imagens e os dados de AGB derivados das parcelas a campo. A extração dos atributos das imagens foi realizada na plataforma *GEE* utilizando a função *reduceRegions* (Apêndice B). Já a abordagem *uspscaling* consistiu no mapeamento da AGB via dados OLI/Landsat-8 utilizando o mapa de AGB LiDAR como referência na calibração do modelo. Os dados de reflectância de superfície das bandas e os índices de vegetação foram associados a pixels do mapa AGB LiDAR, compondo a base de dados para treinamento do modelo. Para tanto, no

*software* QGIS 3.28 (QGIS DEVELOPMENT TEAM, 2023), foram tomados 500 pontos aleatórios sobre o mapa AGB LiDAR, cujos valores de pixel foram armazenados e exportados em arquivo vetorial do tipo *shapefile*. Na plataforma *GEE*, essa camada foi então utilizada para extrair os valores de pixel dos dados OLI/Landsat-8, por meio da função *sampleRegions* (Apêndice B).

Nos modelos derivados dos dados espectrais (AGB OLI/Landsat-8 e AGB *Upscaling*), 54 variáveis preditoras foram consideradas inicialmente. Destas, apenas as variáveis que apresentaram correlação significativa com os valores referência de AGB foram incorporadas ao treinamento dos modelos. A função *cor.test*, em linguagem R, foi utilizada para implementar o método de seleção via correlação de *Spearman*.

No processo de construção dos modelos optou-se pelo uso do algoritmo de aprendizado de máquina *Support Vector Machine – SVM*. Ao comparar diferentes algoritmos de aprendizado de máquina, Marchesan et al. (2023), verificaram que o SVM apresentou melhor precisão ao mapear o estoque e a dinâmica da AGB para a presente área de estudo. Na implementação dos modelos SVM em linguagem R utilizou-se o pacote *e1071* (MEYER et al., 2018). As funções do pacote permitem a configuração de parâmetros intrínsecos do algoritmo SVM. Ajustou-se o *cost*, termo que controla o equilíbrio entre a precisão e a complexidade do modelo; a função *Kernel*, que projeta os valores para um plano de maior dimensão, linearmente separáveis; e o parâmetro *gamma*, relacionado ao raio de influência das amostras selecionadas pelo modelo como vectores de suporte (FACELI et al., 2011). Após sucessivos testes, a configuração final dos parâmetros de cada modelo preditivo levou em conta os valores apresentados na Tabela 9. As configurações objetivaram aumentar a capacidade do modelo em reter informações e torná-lo mais generalista.

Tabela 9 – Configuração dos hiperparâmetros de cada modelo de aprendizado de máquina usado na modelagem da biomassa acima do solo de um trecho de Floresta de Terra firme na fazenda Cauaxi, Paragominas, Pará, pelo algoritmo *Support Vector Machine – SVM*

<b>Modelo</b>	<i>cost</i>	<i>gamma</i>	<i>Kernel</i>
SVM AGB LiDAR	16	1,3	
SVM AGB OLI/Landsat-8	100	1,7	Radial
SVM AGB <i>Upscaling</i>	50	2,5	

Fonte: Autor (2023).

A fim de se obter uma representação mais confiável da AGB nos mapas, os procedimentos de treinamento e validação foram incorporados a um processo recursivo de

reamostragem denominado *bootstrap*, de 500 iterações, a exemplo dos trabalhos desenvolvidos por Lopatin et al. (2016), Silva et al. (2017) e Marchesan (2020). Dessa forma, o mapa final corresponde a representação média resultante das 500 iterações. Visando retratar a variabilidade presente nas estimativas, gerou-se o desvio padrão para os pixels levando em conta as iterações. A rotina de programação em linguagem R com as etapas do processamento pode ser consultada no Apêndice C. O *script* apresenta a imputação dos dados, a aplicação de uma função genérica para seleção de preditores pelo teste de correlação, o treinamento do modelo e a geração dos mapas de AGB (média e desvio-padrão).

### 3.3.3 Validação e análise de incerteza

Os intervalos de confiança da AGB resultante do inventário florestal foram tomados como referência para avaliação da precisão das estimativas a nível de paisagem (mapa de AGB gerado para toda a área de estudo) via sensoriamento remoto. As parcelas sorteadas para validação foram sobrepostas aos mapas de AGB gerados pelos modelos para avaliar o nível de correspondência das estimativas. O teste não paramétrico de *Wilcoxon Rank Sum Test*, equivalente ao teste *U* de *Mann-Whitney* (FIELD et al., 2012), foi aplicado para avaliar se os valores preditos e observados apresentaram diferenças a nível de significância de 5%.

A fim de comparar o desempenho preditivo dos diferentes modelos, foram adotados os seguintes indicadores estatísticos: Coeficiente de correlação de *Spearman*, rho (Equação 4), alternativa não paramétrica para medir o grau de associação entre dois conjuntos de dados (MIOT, 2018); a Raiz do Erro Quadrático Médio, do inglês *Root Mean Squared Error – RMSE* (Equação 5), e o Erro padrão da estimativa percentual *Syx %* (Equação 6).

$$\rho = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)} \quad (4)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (5)$$

$$S_{yx} (\%) = \frac{\sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}}}{\bar{y}} * 100 \quad (6)$$

Onde:  $d_i = R(\hat{y}_i) - R(y_i)$ , a diferença entre os postos das variáveis no nível *i* (BEST; ROBERTS, 1975); *n* é o número de unidades amostrais;  $y_i$  é o valor referência para a biomassa na unidade amostral *i*;  $\bar{y}$  é a biomassa média para a unidade amostral *i*;  $\hat{y}_i$  é o valor predito para a unidade amostral *i*

A análise da incerteza levou em conta as principais fontes de erro existentes ao longo das etapas do trabalho. Para composição dos mapas de incerteza foi utilizada a equação de propagação das incertezas (Equação 7), conforme metodologia aplicada por Saatchi et al. (2011), Rodríguez-Veiga et al. (2016) e adaptada por Bispo et al. (2020):

$$\sigma_{AGB} = (\sigma_{\text{medição}}^2 + \sigma_{\text{LiDAR}}^2 + \sigma_{\text{alometria}}^2 + \sigma_{\text{amostragem}}^2 + \sigma_{\text{predição}}^2)^{1/2} \quad (7)$$

Onde:

- $\sigma_{AGB}$  = Erro de predição em cada pixel do mapa de biomassa;
- $\sigma_{\text{medição}}$  = Erro médio dos parâmetros dendrométricos dentro da parcela (Fixado em 10%);
- $\sigma_{\text{LiDAR}}^4$  = Assumido como 0.5% (de um erro do instrumento de 0,1 m (OPTECH, 2021) para uma altura média do dossel nas parcelas de 20,96 m);
- $\sigma_{\text{alometria}}$  = Erro da equação alométrica (Equação 3) utilizada na estimativa de AGB nas parcelas inventariadas. De acordo com Chave et al. (2014), o erro a nível de parcela com 0,25 ha é da ordem de 10%;
- $\sigma_{\text{amostragem}}$  = Variabilidade estimada de AGB dentro dos pixels (Erro padrão do modelo em %. Valor obtido pela validação do modelo com valores referência de AGB);
- $\sigma_{\text{predição}}$  = Desvio padrão dos valores dos pixels levando em conta cada repetição k dos mapas gerados.

---

<sup>4</sup> O parâmetro  $\sigma_{\text{LiDAR}}$  foi desconsiderado para o cálculo de incerteza do mapa AGB OLI/Landsat-8.

## 4 RESULTADOS E DISCUSSÕES

### 4.1 INVENTÁRIO FLORESTAL – AGB REFERÊNCIA

Nas 85 UA utilizadas no presente estudo, que compõem o inventário florestal realizado na fazenda Cauaxi em 2014, foram contabilizados 1.649 indivíduos, excluindo-se lianas, árvores mortas e não identificadas. A distribuição diamétrica apresentou elevada amplitude, com valores entre 10 e 186 cm (Tabela 10). Em consequência, a biomassa individual (Kg.árvore<sup>-1</sup>), e o valor computado para as parcelas (Mg.ha<sup>-1</sup>), também seguiram esse padrão, com valores de CV (%) de 210,22 e 36,8, respectivamente.

Tabela 10 – Síntese dos valores da distribuição diamétrica (medição direta) e da biomassa acima do solo estimada a partir do inventário florestal realizado na fazenda Cauaxi, Paragominas/PA, no ano de 2014

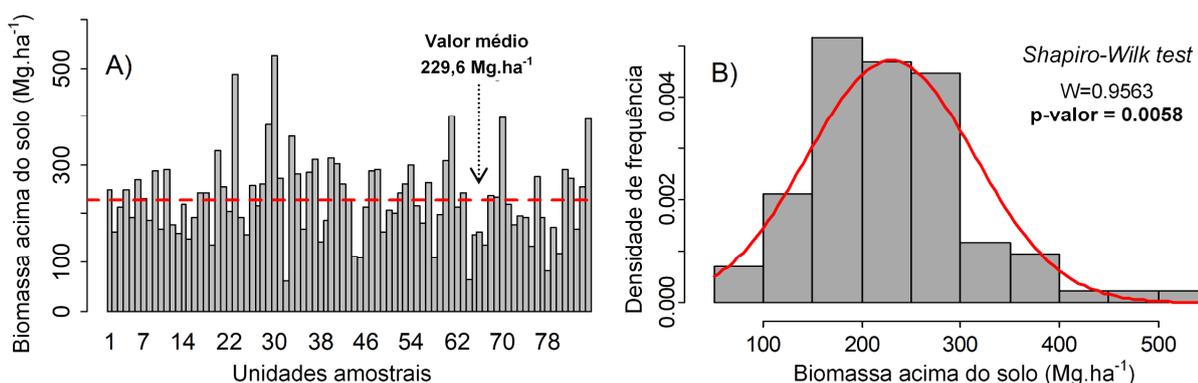
Variável	Mín	Máx	Média	DP	CV (%)
DAP (cm)	10,00	186,00	32,11	19,99	62,25
AGB (Kg.árvore <sup>-1</sup> )	22,46	73.697,49	1.777,87	3.737,503	210,22
AGB (Mg.ha <sup>-1</sup> )	61,46	527,31	229,57	84,48	36,80

Em que: Mín = Valor mínimo; Máx = Valor máximo; DP = Desvio padrão e CV = Coeficiente de variação.

Fonte: Autor (2023).

A grande amplitude nos valores de AGB nas UA inventariadas (Figura 13) reflete a heterogeneidade presente na área. Como resultado, os dados não apresentaram distribuição normal, conforme indicou a estatística do teste de *Shapiro-Wilk* (Figura 13B), o que inviabiliza o uso de regressão paramétrica linear e reforça a necessidade de métodos preditivos alternativos, como o uso do aprendizado de máquina (LARY et al., 2016).

Figura 13 - Representação dos valores de AGB obtidos nas 85 UA inventariadas na fazenda Cauaxi, Paragominas/PA, no ano de 2014. A) Distribuição dos valores de AGB em cada UA. B) Histograma dos valores de AGB distribuídos em classes de 50 Mg.ha<sup>-1</sup>



Fonte: Autor (2023).

Na avaliação do erro amostral, utilizando-se como referência a variável AGB ( $\text{Mg}\cdot\text{ha}^{-1}$ ), de acordo com a estatística descritiva (Tabela 11), o número total de parcelas alocadas foi satisfatório, obtendo-se um erro amostral de 7,9%, considerando uma probabilidade de 95%. A estimativa do estoque de AGB por hectare foi de  $229,6 \text{ Mg}\cdot\text{ha}^{-1}$  ( $211,3 \text{ Mg}\cdot\text{ha}^{-1} \leq \mu \leq 247,8 \text{ Mg}\cdot\text{ha}^{-1}$ ), o que para o total da área de estudo foi equivalente a  $289.256,5 \text{ Mg}$  ( $266.297,7 \text{ Mg} \leq X \leq 312.215,3 \text{ Mg}$ ).

Tabela 11 – Dados descritivos e estatísticos da estimativa da biomassa acima do solo, considerando a probabilidade de 95%, de um trecho de floresta de Terra Firme na fazenda Cauaxi, Paragominas, Pará, obtidos em 2014

Parâmetro	Descrição/Valor obtido
Área total (ha)	1.260
Área da unidade amostral (ha)	0,25
Número de unidades amostrais	85
Fração de amostragem (f)	(1-f) = 0,9831 (população infinita)
Amostragem mínima (n)	54
AGB média ( $\text{Mg}\cdot\text{ha}^{-1}$ )	229,6
Variância ( $\text{Mg}\cdot\text{ha}^{-1}$ ) <sup>2</sup>	7.136,4
Desvio padrão ( $\text{Mg}\cdot\text{ha}^{-1}$ )	$\pm 84,4$
Variância da média ( $\text{Mg}\cdot\text{ha}^{-1}$ ) <sup>2</sup>	83,9
Erro padrão da média ( $\text{Mg}\cdot\text{ha}^{-1}$ )	9,163
Coefficiente de variação (%)	36,8
Erro de amostragem ( $\text{Mg}\cdot\text{ha}^{-1}$ )	18,2
Erro de amostragem (%)	7,9
IC para Média ( $\text{Mg}\cdot\text{ha}^{-1}$ )	[211,3 $\leq$ 229,6 $\leq$ 247,8] (95%)
AGB Total da população (Mg)	289.256,5
IC para o Total da População (Mg)	[266.297,7 $\leq$ 289.256,5 $\leq$ 312.215,3] (95%)

Fonte: Autor (2023).

Ao investigarem a dinâmica de regeneração em área de extração seletiva de madeira na Floresta Estadual do Antimary, no estado do Acre, D'Oliveira et al. (2012), estimaram valores médios para biomassa de  $230,9 \text{ Mg}\cdot\text{ha}^{-1} \pm 74,6 \text{ Mg}\cdot\text{ha}^{-1}$ , valor muito próximo ao observado no presente estudo. Já Matos e Kirchner (2008), em floresta de terra firme no estado do Amazonas, registraram valores de biomassa variando entre 272,38 e 402,92  $\text{Mg}\cdot\text{ha}^{-1}$ , para um valor médio de  $343,06 \text{ Mg}\cdot\text{ha}^{-1} \pm 34,45 \text{ Mg}\cdot\text{ha}^{-1}$ . Conforme relatado por Cummings et al. (2002), em sítios florestais com formações intactas de floresta densa no sudoeste da Amazônia brasileira, entre os estados do Amazonas e Rondônia, podem ter valores elevados de AGB, que variam entre 298 a 534  $\text{Mg}\cdot\text{ha}^{-1}$ , com média e desvio padrão de  $377 \text{ Mg}\cdot\text{ha}^{-1} \pm 33,4 \text{ Mg}\cdot\text{ha}^{-1}$ . Independentemente das técnicas de levantamento e das condições de sítio específicas nesses

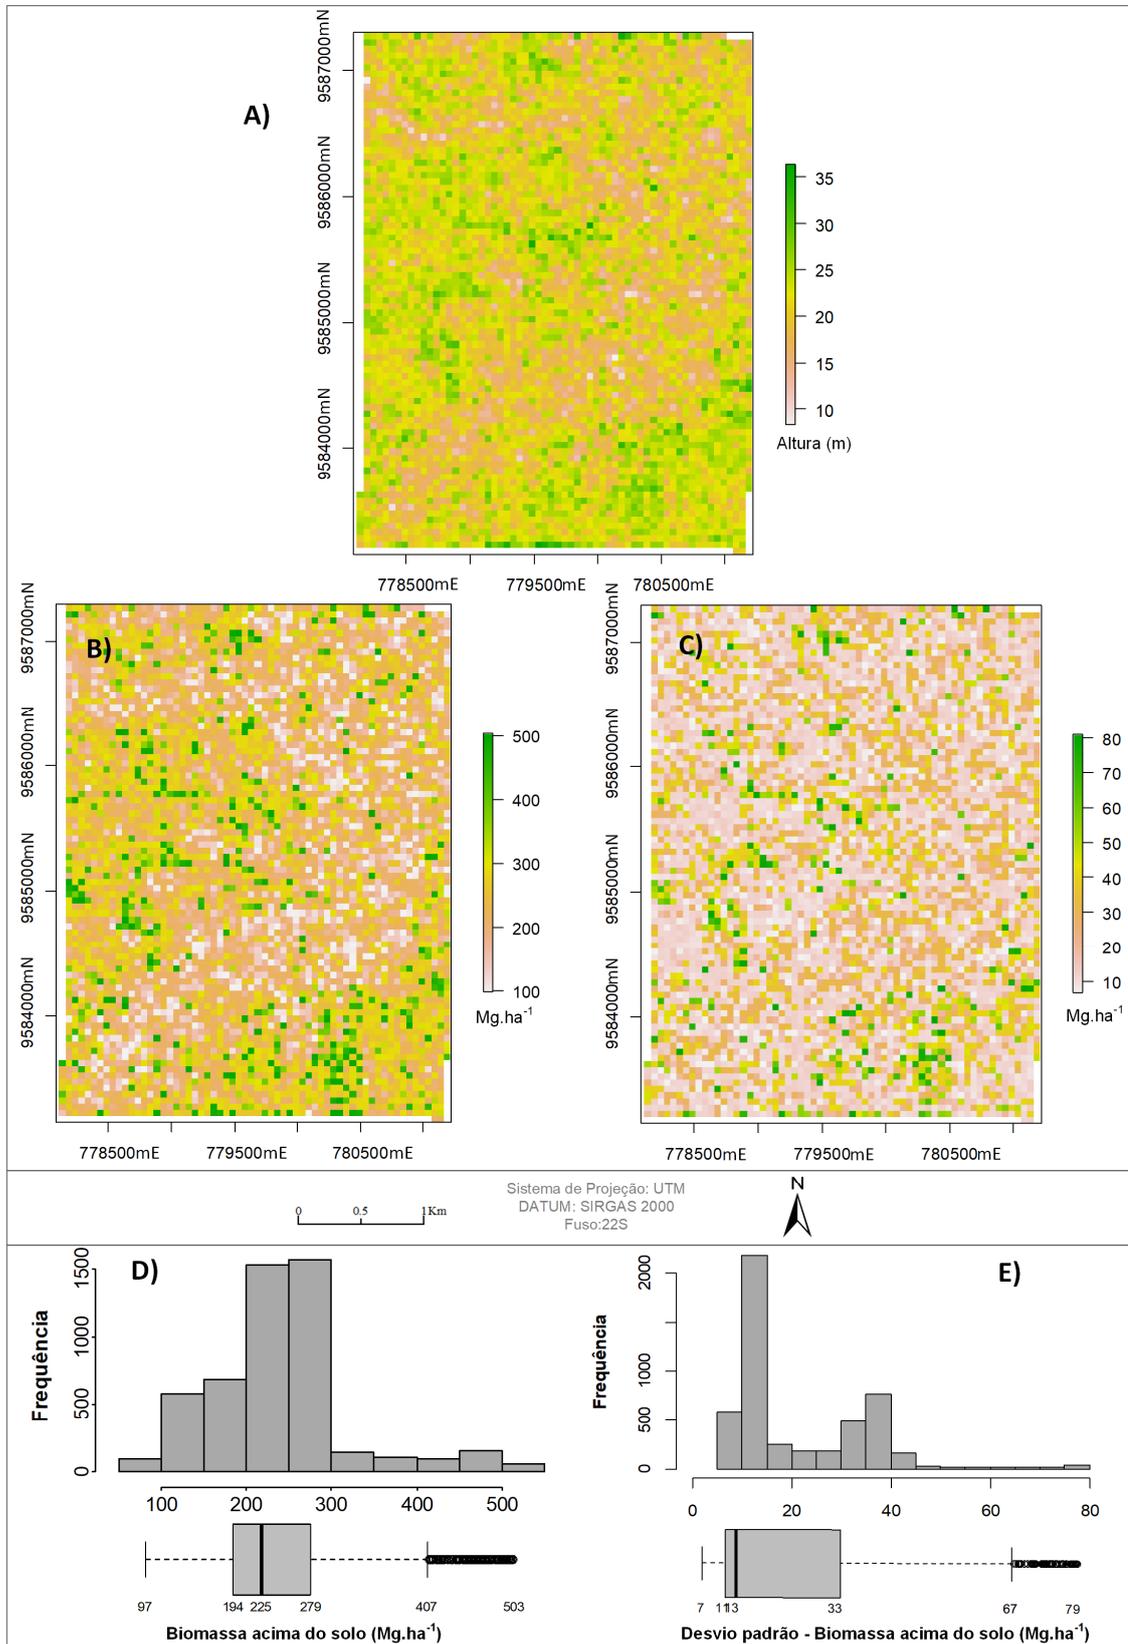
diferentes locais, o manejo florestal baseado na extração seletiva, descrita por Pinagé et al. (2019), pode ser considerado o principal fator que explica de forma mais abrangente a variabilidade nos níveis de biomassa observados na fazenda Cauaxi.

## 4.2 MODELO AGB LIDAR

A partir da espacialização das variáveis, foi possível observar a relação direta existente entre a elevação média e o mapa estimado da biomassa ( $\rho = 0,93$ ,  $p\text{-valor} < 0,001$ ), assim como uma certa correspondência destas com o mapa de desvio padrão (Figura 14). A dispersão das estimativas de algumas observações excederam o limite superior da distribuição, até o valor máximo de  $503 \text{ Mg}\cdot\text{ha}^{-1}$ , sendo rotuladas como *outliers* no gráfico *boxplot*. Ainda assim, é possível afirmar que o modelo conseguiu reproduzir adequadamente, ao longo da área de estudo, a amplitude registrada nos valores de referência.

A análise da Figura 14E, revela pixels com valores de desvio padrão distribuídos entre 7 e  $79 \text{ Mg}\cdot\text{ha}^{-1}$ . Como a distribuição é assimétrica, a mediana está posicionada em  $13 \text{ Mg}\cdot\text{ha}^{-1}$ , para um valor médio é de  $21 \text{ Mg}\cdot\text{ha}^{-1}$ . Valor esse, que pode ser considerado baixo, e revela uma certa estabilidade do modelo ao longo das 500 iterações *bootstrap*, especialmente tendo em vista a amplitude geral da AGB observada na área de estudo.

Figura 14 - A) Espacialização da métrica de elevação média (em metros), utilizada como variável preditora no modelo de estimativa de AGB via LiDAR, B) Espacialização da AGB (em  $\text{Mg}\cdot\text{ha}^{-1}$ ) média das 500 iterações do modelo SVM treinado, C) Espacialização do desvio padrão associado à média de AGB (em  $\text{Mg}\cdot\text{ha}^{-1}$ ), Dispersão dos valores médios (D) e do desvio padrão (E) associado a AGB estimada para área de estudo



Fonte: Autor (2023).

### 4.3 MODELO AGB OLI/LANDSAT-8

A seleção das variáveis pelo critério de correlação de *Spearman* estabeleceu uma redução expressiva no número de variáveis explicativas para construção do modelo. Das 54 variáveis espectrais testadas como preditoras, apenas os índices de vegetação IF e CI apresentaram correlação significativa com a AGB de referência (Tabela 12).

Tabela 12 - Relação de preditores selecionados pelo teste correlação para construção do modelo de estimativa de biomassa acima do solo em um trecho de floresta de Terra Firme na Amazônia paraense, pela abordagem OLI/Landsat-8

Variável	Correlação de <i>Spearman</i> ( $\rho$ )	p-valor
<i>Shape Index - IF</i>	0,2530	0,0229
<i>Coloration Index - CI</i>	0,2203	0,0483

Fonte: Autor (2023).

Ainda que significativos pelo teste de hipótese, os valores dos coeficientes rho de 0,25 e 0,22, caracterizam uma “correlação fraca” entre os respectivos índices e a biomassa, de acordo com o critério estabelecido por Cohen (1992). Phua et al. (2017), também encontraram baixa correlação (aproximadamente 0,40, p-valor<0,05) entre índices de vegetação e a AGB utilizando imagens OLI/Landsat-8 em área de floresta tropical úmida na Malásia.

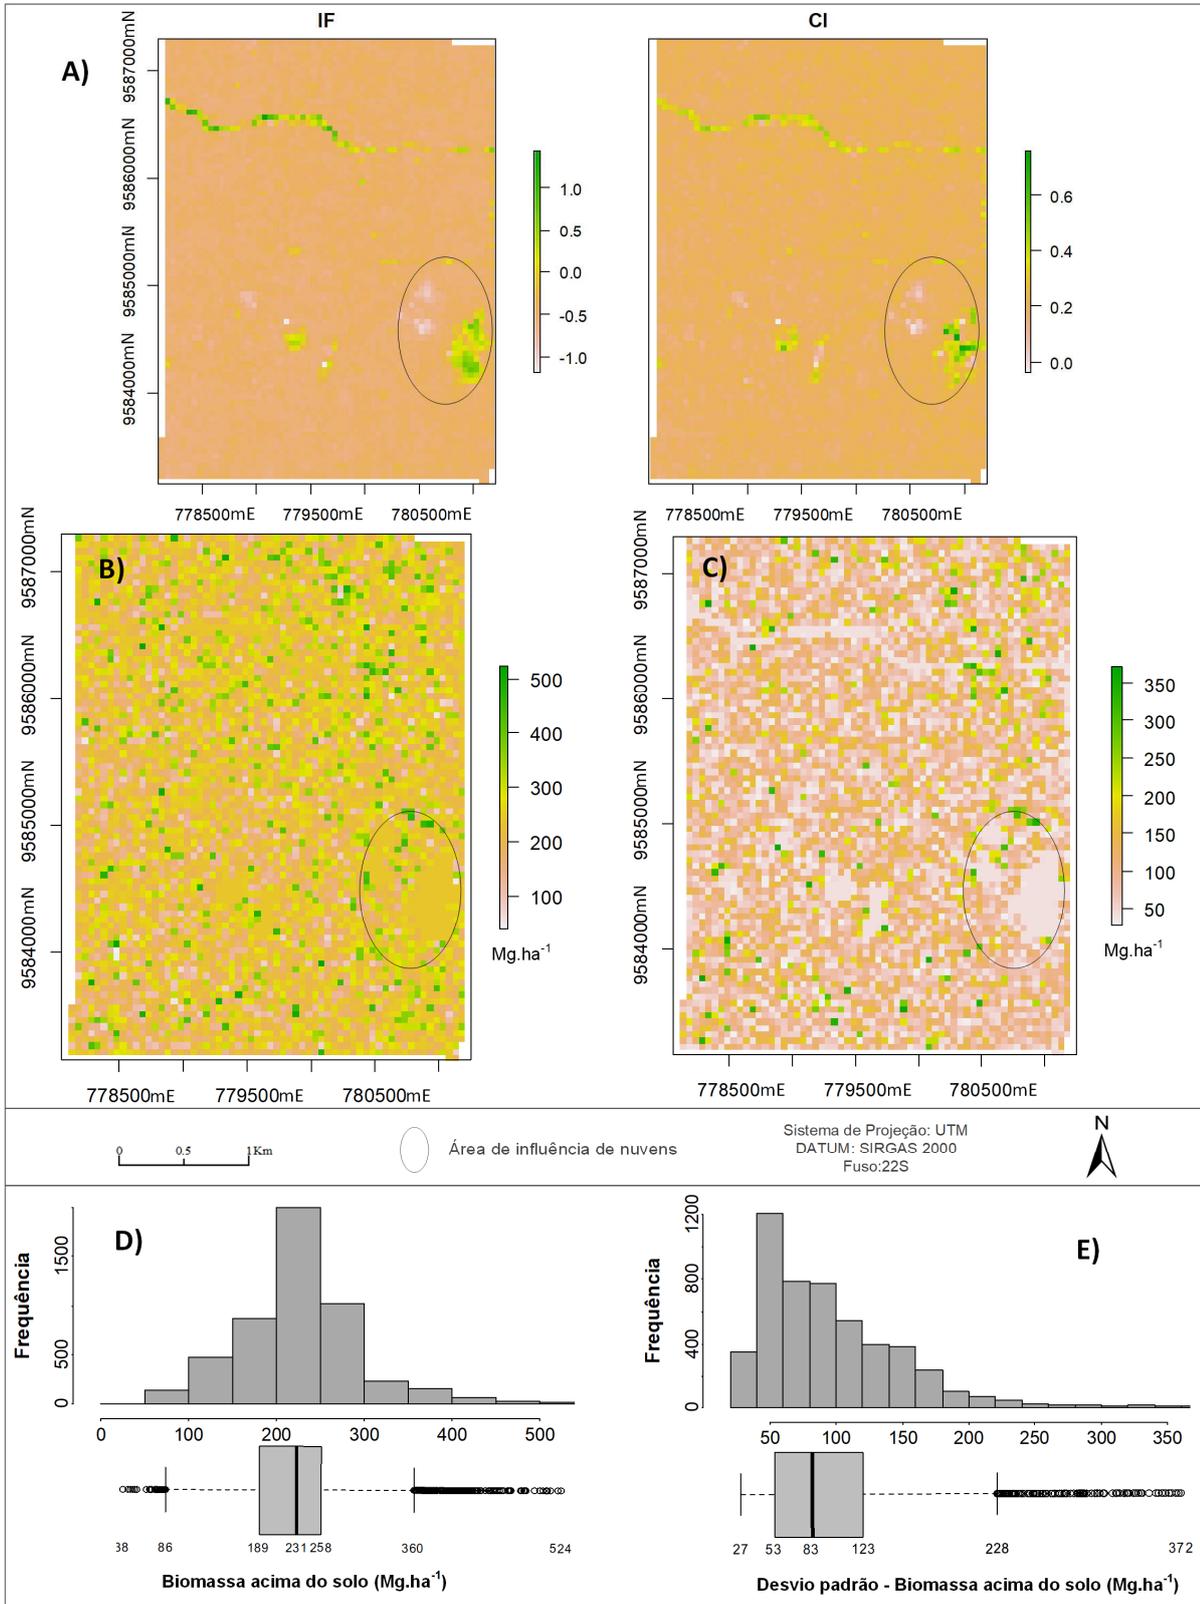
O índice de vegetação IF é composto pelas bandas da região do azul (banda 2), verde (banda 3) e vermelho (banda 4) e o IC pelas bandas do azul e vermelho, dessa forma, pode-se afirmar que as bandas da região do visível foram as que apresentaram maior relação com a AGB, porém combinadas na forma de índice de vegetação. De acordo com Lu et al. (2004), os índices de vegetação podem reduzir parcialmente os efeitos das sombras e das condições ambientais, trazendo melhorias nas correlações com a AGB, principalmente em áreas de floresta com estruturas complexas.

Ao avaliarem as bandas e índices de vegetação do sensor OLI/Landsat-8 para estimativa da AGB em floresta tropical da Tailândia, Jha et al. (2021), também obtiveram melhores resultados para a bandas do azul (banda 2), verde (banda 3) e vermelho (banda 4). Conforme Rullan-Silva et al. (2013), as bandas do visível são sensíveis às variações da reflectância da cobertura florestal devido às propriedades fotossintéticas. Assim, a região do visível está diretamente relacionada aos pigmentos foliares, sendo nessa faixa espectral que ocorre a absorção da maior parte da radiação (PONZONI et al., 2012).

Analisando a literatura, percebe-se que estruturas de dossel menos complexas, são mais favoráveis a associação entre AGB e dados de imagem. Em área de floresta temperada no México, com predomínio de espécies coníferas, López-Serrano et al. (2020) obtiveram correlação de -0,45 com a banda 7 (Infravermelho médio) da imagem OLI/Landsat-8, seguido do NDVI (0,42) e da banda do vermelho (-0,42). Gizachew et al. (2016), ao utilizarem imagens OLI/Landsat-8 na estimativa de AGB no sudeste da Tanzânia, região caracterizada por baixos valores de AGB florestal, obtiveram uma correlação de *Pearson* de 0,50 ( $p$ -valor $<0,005$ ) com o índice EVI, seguindo pelos índices NDVI, SAVI e MSAVI com 0,49 ( $p$ -valor $<0,005$ ). Desse modo, em áreas onde a floresta apresenta menor complexidade, observam-se correlações mais altas entre a AGB e as variáveis derivadas do sensor OLI/Landsat-8. Em um contexto ainda mais homogêneo, Bretas et al. (2021), registraram correlação de 0,82 ( $p$ -valor $<0,05$ ) entre os índices de vegetação NDVI e OSAVI, com a biomassa em pastagem de *Brachiaria* (syn. *Urochloa*) em diferentes regiões do Brasil.

As manchas de nuvem e sombra presentes nos preditores foram propagadas tanto na representação da AGB média, quanto no desvio padrão (Figura 15). A dispersão das estimativas revelou que algumas observações excederam os limites inferior e superior da distribuição, cujos extremos variam entre 38 e 524 Mg.ha<sup>-1</sup> (Figura 15D). Na Figura 15E observou-se pixels com valores de desvio padrão distribuídos entre 27 e 372 Mg.ha<sup>-1</sup>. Mesmo sendo a distribuição assimétrica, a mediana está posicionada em 83 Mg.ha<sup>-1</sup>, para um valor médio de 95 Mg.ha<sup>-1</sup>. Valores comparativamente altos em relação à abordagem LiDAR, evidenciando instabilidade do modelo ao longo das 500 iterações *bootstrap*. Além disso, os valores elevados de desvio padrão contribuíram substancialmente para o aumento da incerteza associada aos pixels, como será detalhado na sequência.

Figura 15 - A) Espacialização das variáveis preditoras selecionadas para comporem o modelo de estimativa de AGB na abordagem OLI/Landsat-8 B) Espacialização da AGB (em Mg.ha<sup>-1</sup>) média das 500 iterações do modelo SVM treinado, C) Espacialização do desvio padrão associado à média de AGB (em Mg.ha<sup>-1</sup>), Dispersão dos valores médios (D) e do desvio padrão (E) associado a AGB estimada para área de estudo



Fonte: Autor (2023).

#### 4.4 MODELO AGB *UPSCALING*

O teste de correlação realizado entre a AGB LiDAR e as variáveis espectrais nos 500 pontos de amostragem, indicou a significância de seis preditores, os quais são apresentados na Tabela 13. Os índices de vegetação CI e IF foram novamente significativos, além de quatro novos preditores, em comparação com a modelagem OLI/Landsat-8.

Tabela 13 – Relação de preditores selecionados pelo teste correlação para construção do modelo de estimativa de biomassa acima do solo em um trecho de floresta de Terra Firme na Amazônia paraense, pela abordagem *upscaling*

Variável	Correlação de Spearman (rho)	p-valor
<i>Modified Normalized Difference Vegetation Index</i> - MNDVI	0,1080	0,0182
<i>Blue green pigment index</i> - BGI	0,0925	0,0432
<i>Ratio Drought Index</i> - RDI	-0,1080	0,0182
<i>Shape Index</i> - IF	-0,1081	0,0181
Banda 7 - SR_B7	-0,1302	0,0043
<i>Coloration Index</i> - CI	-0,1897	0,00003

Fonte: Autor (2023).

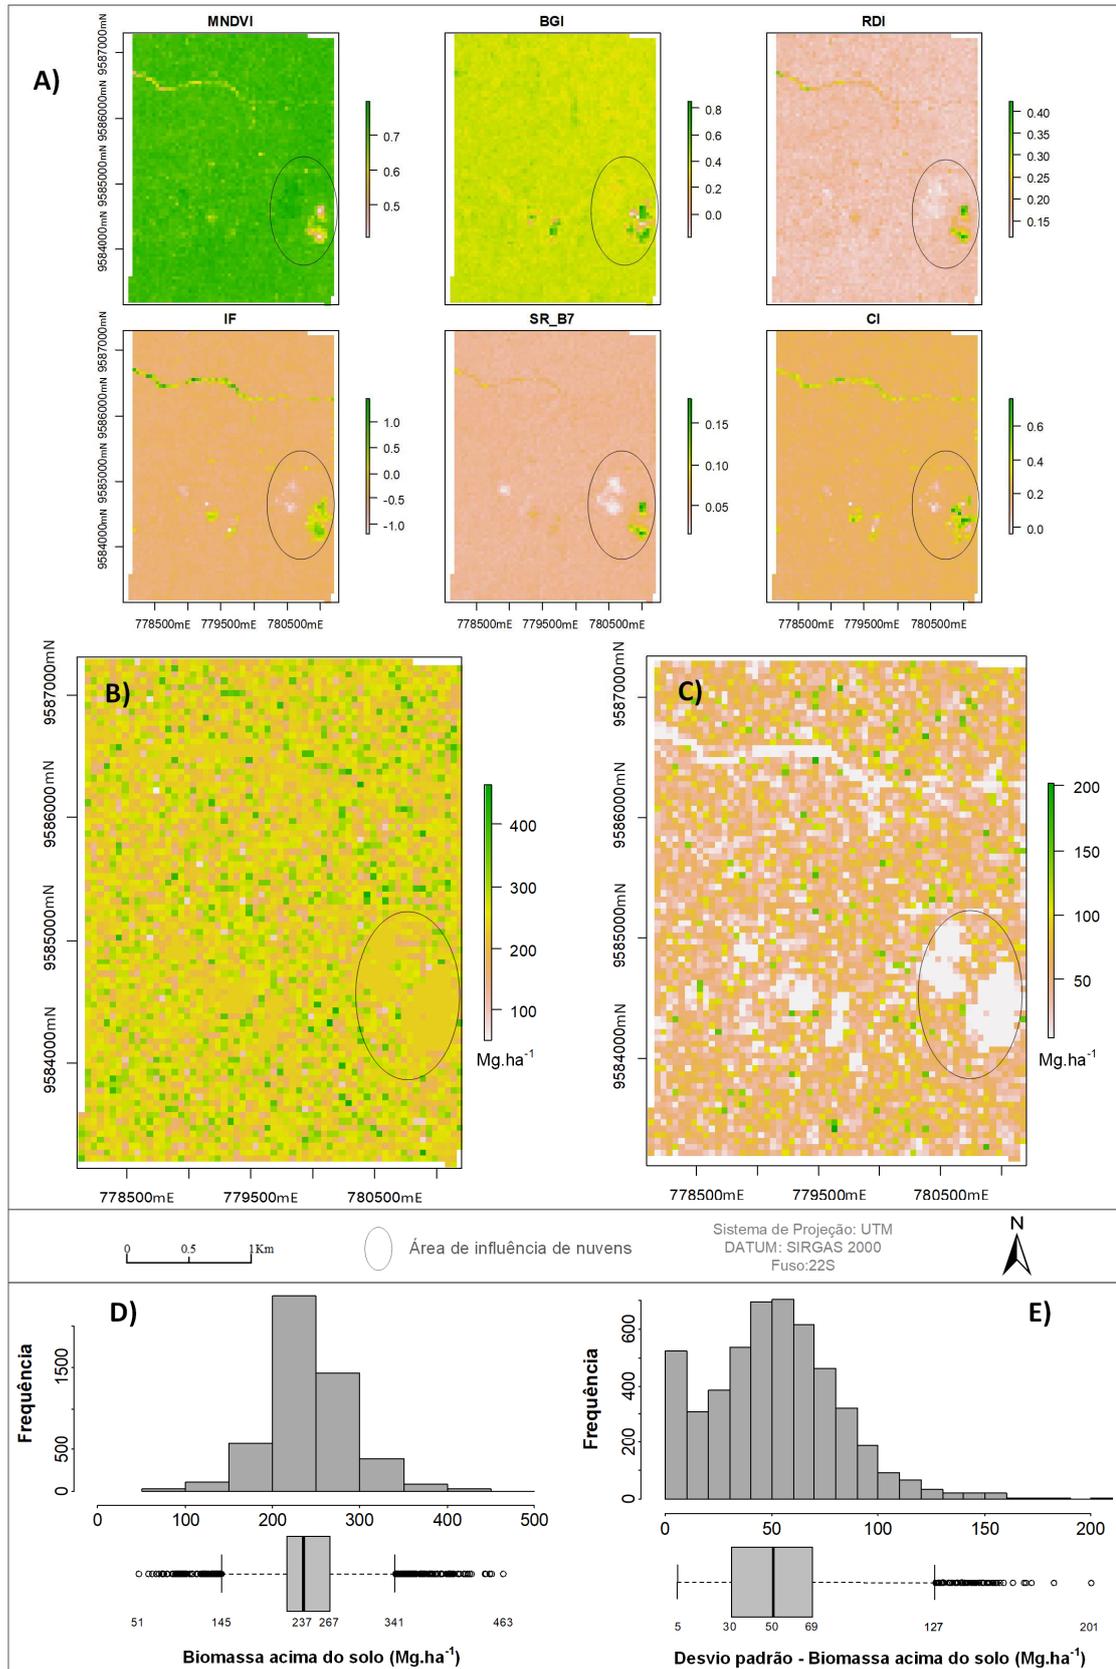
As variáveis preditoras que obtiveram melhores correlações foram o CI, a banda 7 e o IF, respectivamente, seguidos dos índices MNDVI, RDI e BGI. Os índices CI e IF são compostos pelas bandas do visível, conforme mencionado anteriormente. Já o MNDVI utiliza as bandas do infravermelho próximo (banda 5) e infravermelho médio (banda 7), assim como o RDI, construído pela razão simples dessas duas faixas. Por sua vez, o índice BGI é construído utilizando as bandas costal (banda 1) e verde (banda 3). Dessa forma, além das bandas espectrais do visível, a banda 7, é a de maior destaque na composição dos índices selecionados.

A banda do infravermelho médio (banda 7) está relacionada ao teor de umidade da vegetação e do solo, dessa forma, a reflectância capturada pelo sensor diminui conforme aumenta a umidade da superfície, assim, devido aos elevados níveis de umidade em áreas com floresta densa, essa faixa do espectro apresenta baixa refletância (LÓPEZ-SERRANO et al., 2015), o que possibilita correlacionar essa variável com a AGB. Além disso, na região do infravermelho médio as condições atmosféricas causam menor impacto nas assinaturas espectrais da vegetação quando comparada as regiões do visível e infravermelho próximo (GAO et al., 2018). Dessa forma, os autores destacam que para os tipos florestais mais

complexos, como as florestais tropicais, essa região do espectro eletromagnético torna-se mais importante para modelagem da AGB.

Na Figura 16 são apresentados os resultados do mapeamento da biomassa utilizando a abordagem *Upscaling*. Novamente, a presença das nuvens nas variáveis de entrada (Figura 16A), tem efeito sobre as estimativas de média (Figura 16B) e desvio padrão (Figura 16C). A dispersão das estimativas (Figura 16D) revela que algumas observações excederam os limites inferior e superior da distribuição, com valores mínimo e máximo de 51 e 463 Mg.ha<sup>-1</sup> respectivamente, sendo rotuladas como *outliers* no gráfico *boxplot*. A distribuição do desvio padrão (Figura 16E) traz uma amplitude entre 5 e 201 Mg.ha<sup>-1</sup> nos valores dos pixels, o que representa uma melhora em relação a abordagem OLI/Landsat-8. Esse padrão também é verificado nos valores de tendência central, tendo em vista que a mediana está posicionada em 50 Mg.ha<sup>-1</sup>, para um valor médio de 51 Mg.ha<sup>-1</sup>.

Figura 16 – A) Espacialização das variáveis predictoras selecionadas para comporem o modelo de estimativa de AGB na abordagem *Upscaling*, B) Espacialização da AGB (em  $\text{Mg}\cdot\text{ha}^{-1}$ ) média das 500 iterações do modelo SVM treinado, C) Espacialização do desvio padrão associado à média de AGB (em  $\text{Mg}\cdot\text{ha}^{-1}$ ), Dispersão dos valores médios (D) e do desvio padrão (E) associado a AGB estimada para área de estudo



Fonte: Autor (2023).

## 4.5 COMPARATIVO DAS ABORDAGENS

### 4.5.1 Análise a nível de paisagem

O valor médio dos pixels e o total de AGB em cada mapa gerado foram comparados aos dados de referência (Tabela 14). Foi possível constatar que as três estimativas realizadas via sensoriamento remoto estão dentro dos intervalos de confiança da AGB resultante do inventário florestal. Em termos relativos, o mapa de AGB gerado na abordagem OLI/Landsat-8 foi o que apresentou estimativas mais próximas aos dados de referência, com valores variando de -1,3% e -2,1% para média e o total da população, respectivamente. Por outro lado, o método *Upscaling* foi o que apresentou as maiores diferenças, com 5,8% para a média e 5% para o total de AGB.

Tabela 14 - Comparativo das estimativas de biomassa acima do solo em relação aos dados de referência para a média e o total da população em trecho de floresta de Terra Firme na Fazenda Cauaxi, Paragominas, Pará

	Mín. (Mg.ha <sup>-1</sup> )	Média (Mg.ha <sup>-1</sup> )	Máx. (Mg.ha <sup>-1</sup> )	Desvio padrão (Mg.ha <sup>-1</sup> )	Total (Mg)	Diferença em relação à média (Mg.ha <sup>-1</sup> )		Diferença em relação ao total (Mg)	
						Absoluta	%	Absoluta	%
<b>Referência (Inventário)</b>	<b>61,5</b>	<b>229,6</b>	<b>527,3</b>	<b>84,4</b>	<b>289.256,5</b>	-	-	-	-
LiDAR	97,2	238,8	504,3	82,8	298.475,7	9,21	4,0%	9.219,2	3,2%
OLI/Landsat-8	38,9	226,6	524,1	66,5	283.313,6	-3,01	-1,3%	-5.942,9	-2,1%
<i>Upscaling</i>	51,9	242,9	463,9	46,8	303.827,7	13,40	5,8%	14.571,2	5,0%

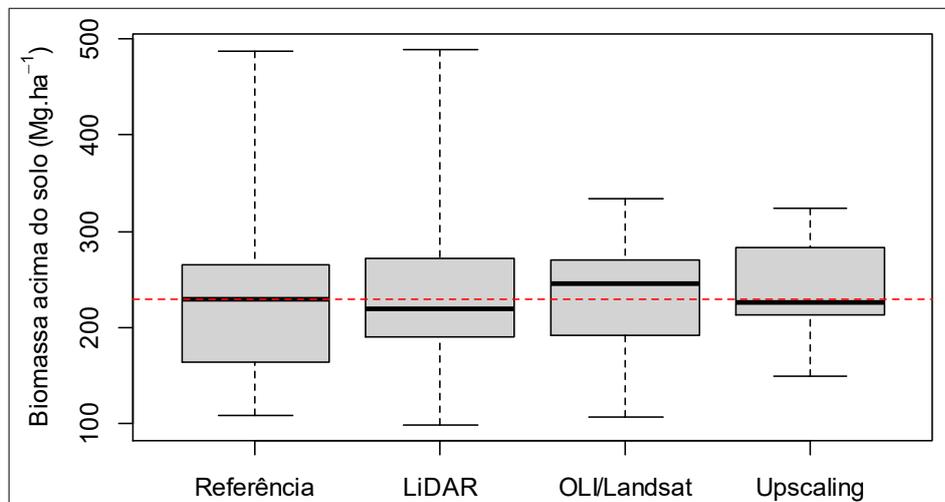
Fonte: Autor (2023).

### 4.5.2 Validação nas unidades amostrais

Os diagramas *boxplot* presentes na Figura 17 representam a distribuição da biomassa, referência e estimada, nas 24 unidades amostrais utilizadas para validação dos modelos. A estimativa AGB LiDAR conseguiu caracterizar melhor a distribuição dos dados de referência, reproduzindo toda a amplitude da AGB obtida no inventário. Já as estimativas OLI/Landsat-8 e *Upscaling* concentraram os valores próximos a amplitude interquartílica<sup>5</sup> da distribuição de referência. Em termos de tendência central, a estimativa *Upscaling* é a que mais se aproxima da mediana de referência (linha tracejada em vermelho na Figura 17).

<sup>5</sup> Amplitude entre o primeiro (Q1) e o terceiro (Q3) quartil da distribuição (FONSECA; MARTINS, 2015).

Figura 17 - Distribuição dos valores de referência da biomassa acima do solo e seu comparativo com as estimativas pelos diferentes métodos em 24 unidades amostrais de floresta de Terra Firme na fazenda Cauaxi, Paragominas, Pará

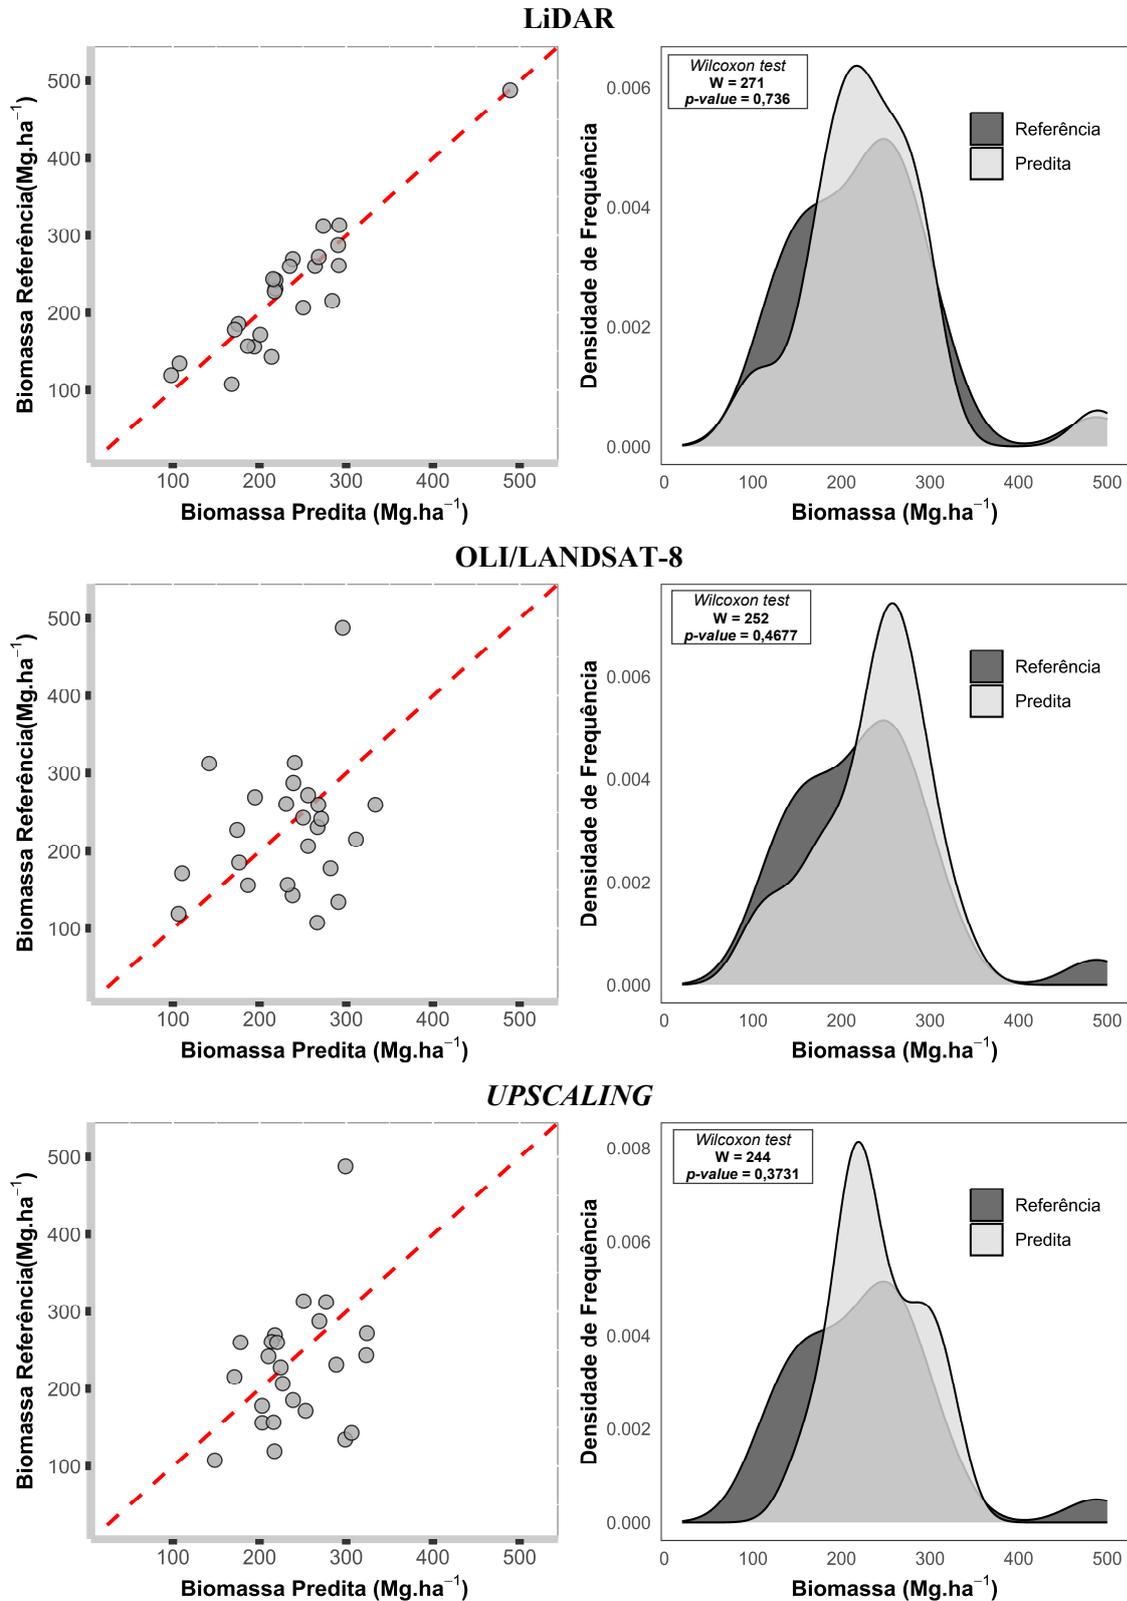


Fonte: Autor (2023).

De maneira geral, os modelos demonstraram estimativas que se aproximaram da mediana dos valores de referência, o que sugere uma boa performance em termos de validação. Essa avaliação preliminar é confirmada pela estatística *Wilcoxon Rank Sum Test* (Figura 18). Para as três abordagens analisadas, o valor da probabilidade do teste foi maior do que o limite de aceitação estabelecido ( $p\text{-value} > 0,05$ ), de modo que a hipótese de equivalência entre os conjuntos testados é refutada. Isso determina que não há diferença significativa, com 95% de confiança, entre a mediana dos valores estimados e da biomassa tomada como referência.

A dispersão dos pontos e as curvas de densidade de frequência apresentadas na Figura 18 são também uma evidência de que o modelo LiDAR conseguiu reproduzir melhor o conjunto de dados de validação. Já os modelos OLI/Landsat-8 e *Upscaling* não conseguiram estimar os extremos da distribuição, assim como observado nos gráficos *boxplot* da Figura 17.

Figura 18 – Dispersão e curvas de distribuição da biomassa referência e estimada pelos diferentes métodos nas unidades amostrais de validação em um trecho de floresta de Terra Firme na Fazenda Cauaxi, Paragominas, Pará



Fonte: Autor (2023).

As observações realizadas em relação a validação dos modelos a partir da análise gráfica foram confirmadas pelas estatísticas de precisão (Tabela 15). O desempenho superior nos três indicadores de validação, conferem ao modelo LiDAR a condição de melhor adequação aos dados de teste. Em contrapartida, com o RMSE na ordem de 87 Mg.ha<sup>-1</sup> e erro padrão de 38%, o modelo OLI/Landsat-8, apresentou menor flexibilidade e capacidade de generalização com as informações fornecidas na etapa de validação. Ao passo que a nível de paisagem, a estimativa OLI/Landsat-8 consegue a melhor aproximação em relação à média e ao total de AGB referência, a nível de parcela, o mesmo não ocorre. Como visto graficamente, o modelo concentra as predições no centro da distribuição, o que permitiu boas aproximações a nível global. No entanto, como o modelo não consegue reproduzir adequadamente toda a amplitude dos dados, sua performance quando analisada de forma pontual (pixel a pixel), é prejudicada.

Tabela 15 – Estatísticas de precisão nas estimativas de biomassa acima do solo pelos diferentes modelos preditivos nas unidades amostrais de validação da área de estudo, localizada em um trecho de floresta de Terra Firme na Fazenda Cauaxi, Paragominas, Pará

<b>Estimativa</b>	<b>Correlação de Spearman (rho)</b>	<b>RMSE (Mg.ha<sup>-1</sup>)</b>	<b>Erro Padrão (%)</b>
LiDAR	0,89 (p-valor < 0,0001)	32,81	14,46
OLI/Landsat-8	0,13 (p-valor = 0,2642)	87,20	38,45
<i>Upscaling</i>	0,31 (p-valor = 0,0699)	79,26	34,95

Fonte: Autor (2023).

Embora o erro padrão das estimativas OLI/Landsat-8 e *Upscaling* seja relativamente alto, acima de 30%, os valores de RMSE são coerentes com o que se observa na literatura. A título de comparação, a Tabela 16 traz alguns estudos envolvendo a predição de AGB via sensoriamento remoto para o mesmo tipo de formação florestal da presente pesquisa. Tais estudos sugerem que o desempenho da modelagem pode variar em função do tipo de sensor utilizado, ou a combinação desses, assim como o método de regressão empregado. Nesse sentido, Lee et al. (2018) recomendam realizar uma análise de sensibilidade para verificar qual algoritmo/modelo tem melhor desempenho (menor incerteza) a cada nova área de estudo.

Tabela 16 - Síntese dos resultados em estudos similares de predição da AGB florestal com auxílio de dados de sensoriamento remoto para a mesma tipologia florestal

Autor	Tipo de sensor	Modelagem	RMSE (Mg.ha <sup>-1</sup> )
Feng et al. (2017)	LiDAR	Linear	70,25
		RF	60,12
		SVM	58,26
Marchesan et al. (2023)	LiDAR	ANN	51,22
		RF	48,01
		SVM	44,99
	LiDAR + OLI/Landsat-8	ANN	54,49
		RF	45,24
		SVM	46,00
Nguyen et al. (2016)	OLI/Landsat-8 + ALOS 2 SAR	Linear	60,45
Phua et al. (2017)	LiDAR	Linear	178,77
	OLI/Landsat-8		191,19
	LiDAR + OLI/Landsat-8		131,33

Onde: RF = *Random Forest*; ANN = *Artificial Neural Network* e SVM = *Support Vector Machine*.

Fonte: Autor (2023).

Do ponto de vista da arquitetura dos modelos SVM ajustados, a fraca correlação entre a AGB e os preditores derivados das imagens (Tabela 12 e Tabela 13), determinou a necessidade de uma escolha minuciosa dos parâmetros dos modelos. Os altos valores de *cost* e *gamma* (Tabela 9 – Item 3.3.2) revelam a dificuldade dos modelos em acomodar as observações e realizar predições satisfatórias. A título de comparação e referência, os valores de *cost* = 1 e *gamma* = 1/número de observações, são as configurações *default* da função *svm* do pacote *e1071* (MEYER et al., 2018). De acordo com Géron (2021), como os parâmetros *gamma* e *cost* são elementos de regularização, aumentá-los torna o modelo mais flexível e ajuda evitar o *underfitting* (subajuste). Em contrapartida, valores muito elevados podem levar ao *overfitting* (sobreajuste). Segundo Facure (2017), *overfitting* acontece quando o modelo aprende não apenas os padrões esperados, mas também captura o ruído presente nos dados de treinamento, tornando-o pouco generalista e flexível a novos dados, elevando o erro na etapa de validação.

Alguns fatores podem dificultar a associação das variáveis espectrais com a AGB. Dentre esses, tem-se a saturação dos pixels, que ocorre em áreas de floresta com elevada biomassa, como a floresta Amazônica (LU et al., 2012), devido à heterogeneidade do tamanho das árvores e da composição de espécies (ZHAO et al., 2016). Conforme estudo realizado por Jha et al. (2021), em área de floresta tropical densa, valores baixos de AGB ( $\leq 200$  Mg.ha<sup>-1</sup>) são

preditos de forma mais precisa do que valores mais altos (acima de 200 Mg.ha<sup>-1</sup>), quando utilizados dados OLI/Landsat-8.

Outro fator relevante, que pode causar erros nas estimativas de AGB, é a mistura espectral, a qual ocorre principalmente em imagens de baixa e média resolução espacial, onde um único pixel concentra a informação espectral de diversos alvos. Dessa forma, imagens OLI/Landsat-8, por apresentarem resolução espacial de 30 m, irão englobar, em um único pixel, a reflectância de diversas árvores e as sombras dos indivíduos de maior porte, o que irá interferir nos valores de reflectância. Segundo Dube e Mutanga (2015), os sombreamentos causados pelas árvores de grande porte contribuem na alteração da reflectância espectral capturada pelos sensores, ocasionando baixo desempenho nas estimativas de AGB, além disso, os autores destacam que a maioria dos índices de vegetação foram projetados para vegetação com estrutura menos complexa.

Ao compararem imagens OLI/Landsat-8, Sentinel-2B e Worldview-3, para mapear AGB em uma área de floresta tropical densa na Tailândia, Jha et al. (2021), concluíram que as imagens dos sensores de resolução mais alta, Sentinel-2B e Worldview-3, forneceram estimativas de AGB mais precisas quando comparadas ao sensor OLI/Landsat-8, o que pode estar atrelado, segundo os autores, a maior resolução espectral e espacial e, ainda, a disponibilidade da banda *Red-Edge*.

O incorreto georreferenciamento das parcelas de campo também podem contribuir para aumentar os erros na modelagem da AGB em áreas de floresta tropical, uma vez que, as árvores de grande porte, com dossel denso e elevado DAP, dificultam a obtenção do posicionamento preciso por meio do GNSS (D'OLIVEIRA et al., 2012). Silva et al. (2017), ao analisarem o deslocamento das parcelas de campo na mesma área de estudo do presente trabalho, observaram que os centros das parcelas foram movidos em média 18,38 m ( $\pm 6,32$  m) dos locais iniciais das unidades. Os autores destacam que é comum encontrar nessa região árvores com diâmetros de copa maiores que 30 m, assim, nos casos em que grandes indivíduos estão localizados na periferia das parcelas (as árvores não são contabilizadas no inventário a campo), partes da copa podem estar dentro da parcela, o que irá influenciar nos resultados. Conforme estudo realizado por Hernández-Stefanoni et al. (2018), a razão perímetro-área diminui conforme aumenta o tamanho da parcela, reduzindo os efeitos de borda e conseqüentemente os erros nas estimas de AGB, além disso, maiores parcelas aumentam a sobreposição entre os dados de campo e os dados LiDAR, diminuindo o erro de posicionamento discutido anteriormente.

Em seu estudo de revisão, Mutanga et al. (2023), mencionam que um considerável esforço de pesquisa tem sido exercido para abordar o fenômeno de saturação espectral em

vegetação de alta densidade. Esses esforços, segundo os autores, englobam a utilização de sensores com alta resolução espacial, espectral e temporal, múltiplas transformações de imagem (índices de vegetação e métricas de textura), técnicas de fusão, bem como técnicas robustas de aprendizado de máquina. Os autores apontam ainda que apesar da diversidade de estudos feitos sobre saturação espectral, o objetivo da comunidade de pesquisa será desenvolver uma abordagem comum que transcenda vários tipos de vegetação e estruturas, de modo que ferramentas avançadas de aprendizado profundo, podem desempenhar um papel significativo nesse processo.

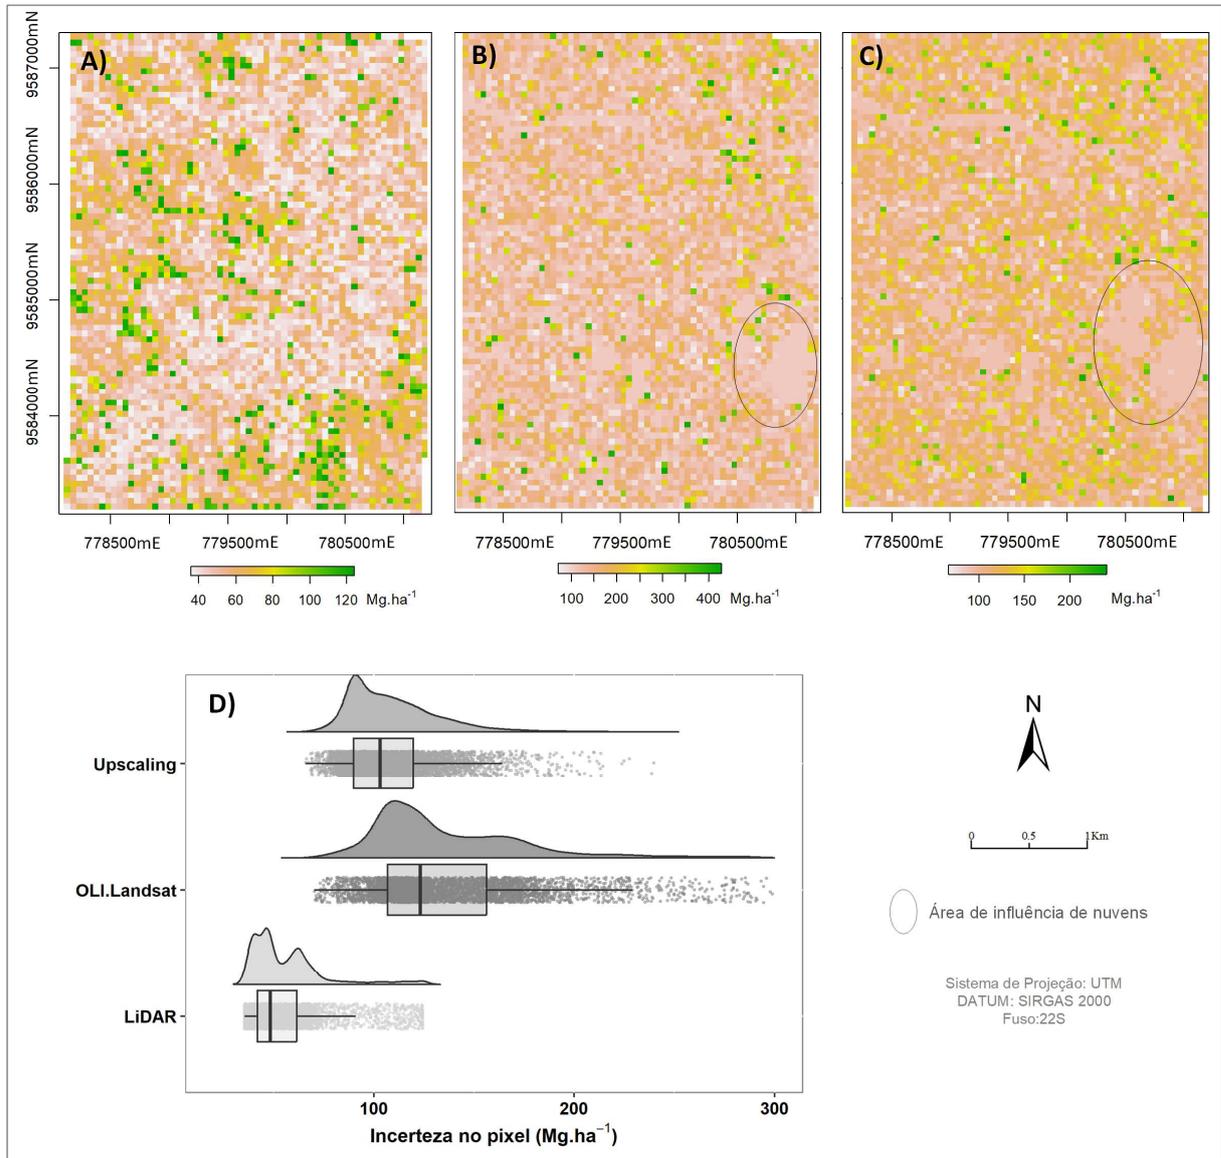
### 4.5.3 Análise da incerteza

Os dados de incerteza apresentados na Figura 19 revelam a mesma tendência observada na validação dos modelos. O mapa com menor incerteza associada aos pixels de AGB refere-se ao modelo LiDAR, com amplitude entre 35,56 e 124,39  $\text{Mg}\cdot\text{ha}^{-1}$ , para um valor médio de 54,59  $\text{Mg}\cdot\text{ha}^{-1}$ . Já a abordagem OLI/Landsat-8 apresentou grande incerteza, variando de 70,38  $\text{Mg}\cdot\text{ha}^{-1}$  até um máximo de 428,79  $\text{Mg}\cdot\text{ha}^{-1}$ , para uma média de 138,19  $\text{Mg}\cdot\text{ha}^{-1}$ . Por sua vez a abordagem *Upscaling* teve um desempenho intermediário com amplitude entre 66 e 239,57  $\text{Mg}\cdot\text{ha}^{-1}$ , e valor médio de 108,09  $\text{Mg}\cdot\text{ha}^{-1}$ .

Esses resultados são diretamente proporcionais ao desvio padrão oriundo do método *bootstrap* de reamostragem utilizado para construção dos mapas. A fraca correlação entre as variáveis preditoras com a AGB, e o menor número de repetições, podem ter contribuído para a maior instabilidade do modelo OLI/Landsat-8, a qual se verifica pelo alto desvio padrão do mapa resultante. Segundo Rajput et al. (2023), a acurácia dos modelos de aprendizado de máquina tende a aumentar, à medida que a variância dos dados diminui pelo incremento de unidades amostrais. Nesse sentido, o maior número de observações (500 pontos amostrais) utilizado no *Upscaling* pode ter contribuído para estabilizar o modelo, em comparação com a abordagem OLI/Landsat-8, que utiliza menos repetições (57 UA).

Ao mapear a AGB florestal em uma bacia hidrográfica no estado de Goiás, no bioma Cerrado, Bispo et al. (2020), aplicaram o método *Upscaling* combinando dados LiDAR com imagens Landsat 8 e ALOS-2/PALSAR-2. Os autores estimaram valores de incerteza na ordem de 0 a 50  $\text{Mg}\cdot\text{ha}^{-1}$ , para uma amplitude de AGB de 0 a 90  $\text{Mg}\cdot\text{ha}^{-1}$ . Embora o estudo pertença a outro bioma, o paralelo que pode ser feito é a alta relação incerteza/AGB encontrada pelos autores.

Figura 19 - Espacialização da incerteza associada a predição de AGB ( $\text{Mg}\cdot\text{ha}^{-1}$ ), pelos modelos LiDAR (A), OLI/Landsat-8 (B) e *Upscaling* (C). D) distribuição dos valores de incerteza para as três abordagens



Fonte: Autor (2023).

De forma geral, os resultados alcançados ao longo do desenvolvimento da pesquisa atestam a hipótese de que a abordagem *upscaling* melhora a precisão das estimativas de AGB a partir de imagens OLI/Landsat-8. A hipótese é corroborada tanto pelas estatísticas de precisão utilizadas na validação das estimativas, quanto pela análise de incerteza dos mapas de AGB.

Por outro lado, a hipótese de que o método *upscaling* permite retratar as irregularidades locais da AGB ao longo do mosaico da vegetação, não pode ser confirmada. Embora o método tenha atingido boas aproximações a nível global, apresentando valores dentro do intervalo de confiança da AGB referência, o ganho de performance comparado a abordagem OLI/Landsat-8, não foi suficiente para garantir previsões precisas pixel a pixel. Mesmo que as estimativas

tenham sido validadas estatisticamente pelo teste de *Wilcoxon*, o valor do erro padrão próximo a 35% e a incerteza média de 108 Mg.ha<sup>-1</sup>, revelam a necessidade de aprimoramento no método para assegurar previsões locais adequadas.

## 5 CONCLUSÃO

O estudo investigou o desenvolvimento e aplicação de três abordagens para modelagem e mapeamento da AGB em área de Floresta Ombrófila Densa da Amazônia paraense, por meio da associação entre dados de campo, nuvens de pontos LiDAR e imagens OLI/Landsat-8. Em linhas gerais, os métodos utilizados permitiram estimativas adequadas a nível de paisagem e estatisticamente aceitáveis nas parcelas destinadas a validação.

A abordagem AGB/LiDAR conseguiu retratar de forma adequada a condição local, apresentando os melhores indicadores de validação e incerteza. Já a abordagem OLI/Landsat apresentou fraca correlação entre os preditores derivados das imagens e a AGB nas parcelas. Essa circunstância determinou a dificuldade do modelo em generalizar novas observações, levando aos piores indicadores de validação, quando comparado aos demais. Esse fator também contribuiu para instabilidade do modelo, dando origem a maior incerteza associada aos pixels de AGB.

A abordagem de *upscaling* proposta nesse estudo trouxe ganho de performance às estimativas de AGB a partir de imagens OLI/Landsat-8. O treinamento do modelo utilizando como referência o mapa AGB via LiDAR teve como primeira consequência o aumento no número de preditores significativos em relação a AGB. Ademais, o número superior de repetições (500 pontos amostrais em relação a 57 UA), agregou maior detalhe a base de dados, permitindo o resgate de mais nuances sobre o componente espectral e a melhor caracterização de toda amplitude da AGB presente na área de estudo. O maior número de preditores, associado ao maior detalhamento da amostra, deixou o modelo mais generalista e estável, o que determinou a melhora nos indicadores de validação e incerteza.

Diante deste contexto, os resultados da pesquisa recomendam a combinação de sensores remotos na estimativa de AGB em ambiente amazônico. A calibração de modelos espectrais com mapas prévios de AGB, via dados LiDAR, tende a compensar a saturação de dados ópticos e melhorar a predição. Além dessa estratégia, em trabalhos futuros recomenda-se avaliar a inclusão de diferentes preditores nos 3 modelos, como métricas de textura relacionada as imagens e outras variáveis LiDAR. Cabe avaliar ainda, a utilização de outras fontes de dados, como sensores de maior resolução espacial, espectral e temporal. Por fim, recomenda-se o emprego de técnicas robustas de aprendizado de máquina, o que envolve a calibração precisa dos parâmetros inerentes à arquitetura utilizada e um processo criterioso e transparente de avaliação da incerteza propagada pelo método.

## REFERÊNCIAS BIBLIOGRÁFICAS

ADHIKARI, H.; HEISKANEN, J.; SILJANDER, M.; et al. Determinants of Aboveground Biomass across an Afremontane Landscape Mosaic in Kenya. **Remote Sensing** 2017, Vol. 9, Page 827, v. 9, n. 8, p. 827, 2017.

AHMAD, F.; GOPARAJU, L.; QAYUM, A. Natural Resource Mapping Using Landsat and Lidar towards Identifying Digital Elevation, Digital Surface and Canopy Height Models. **International Journal of Environmental Sciences & Natural Resources**, v. 2, n. 1, 2017.

ALBA, E.; MARCHESAN, J.; SCHUH, M.; et al. Influence of forest coverage in the surface albedo. **Floresta**, v. 50, n.1, 2020.

ALMEIDA, C. T. DE; DELGADO, R. C.; GALVÃO, L. S.; ARAGÃO, L. E. DE O. C. E.; RAMOS, M. C. Improvements of the MODIS Gross Primary Productivity model based on a comprehensive uncertainty assessment over the Brazilian Amazonia. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 145, p. 268–283, 2018.

ALMEIDA, C. T. DE; GALVÃO, L. S.; EDUARDO, L.; et al. Aboveground Biomass Estimation in the Brazilian Amazon Using Combined Lidar and Hyperspectral Data. Simpósio Brasileiro de Sensoriamento Remoto. **Anais...** . p.1843–1846, 2019. São José dos Campos - São Paulo: INPE-Instituto Nacional de Pesquisas Espaciais.

ANDERSON, K.; HANCOCK, S.; DISNEY, M.; GASTON, K. J. Is waveform worth it? A comparison of LiDAR approaches for vegetation and landscape characterization. **Remote Sensing in Ecology and Conservation**, v. 2, n. 1, p. 5–15, 2016.

ASNER, G. P.; MASCARO, J. Mapping tropical forest carbon: Calibrating plot estimates to a simple LiDAR metric. **Remote Sensing of Environment**, v. 140, p. 614–624, 2014. Elsevier. Acesso em: 16 jul. 2021.

ASPRS. American Society for Photogrammetry and Remote Sensing. **LAS Specification 1.4-R14**. Bethesda, Maryland, 2019. Disponível em: <[https://www.asprs.org/wp-content/uploads/2019/03/LAS\\_1\\_4\\_r14.pdf](https://www.asprs.org/wp-content/uploads/2019/03/LAS_1_4_r14.pdf)>. Acesso em: 05 mar. 2021.

ASPRS. American Society for Photogrammetry and Remote Sensing. **LASer (LAS) File Format Exchange Activities**. 2021. Disponível em: <<https://www.asprs.org/divisions-committees/lidar-division/laser-las-file-format-exchange-activities>>. Acesso em: 5 mar. 2021.

AVITABILE, V.; CAMIA, A. An assessment of forest biomass maps in Europe using harmonized national statistics and inventory plots. **Forest Ecology and Management**, v. 409, p. 489–498, 2018.

BACCINI, A.; ASNER, G. P. Improving pantropical forest carbon maps with airborne LiDAR sampling. **Carbon Management**, v. 4, n. 6, p. 591–600, 2013.

BACCINI, A.; GOETZ, S. J.; WALKER, W. S.; et al. Estimated carbon dioxide emissions from tropical deforestation improved by carbon-density maps. **Nature Climate Change**, v. 2, n. 3, p. 182–185, 2012.

- BAKKER, W. H.; GRABMAIER, K. A.; HUURNEMAN, G. C.; et al. **Rinciples of Remote Sensing**. 3<sup>a</sup> ed. Enschede/Netherlands: ITC Educational Textbook Series, 2004.
- BASTOS, T. X.; DA SILVA, G. DE F. G.; PACHECO, N. A.; FIGUEIREDO, R. DE O. Informações agroclimáticas do município de Paragominas para o planejamento agrícola. In: Congresso Brasileiro de Meteorologia, 14., 2006, Florianópolis. **Anais. [...]**. Florianópolis: SBMET, 2006.
- BEST, D. J.; ROBERTS, D. E. Algorithm AS 89: The Upper Tail Probabilities of Spearman's Rho. **Journal of the Royal Statistical Society. Series C (Applied Statistics)**, v. 24, n. 3, p. 377–379, 1975. [Wiley, Royal Statistical Society]. Disponível em: <<http://www.jstor.org/stable/2347111>>. Acesso em: 05 set. 2023.
- BISPO, P. DA C.; PEDRO, R.-V.; BARBARA, Z.; et al. Woody aboveground biomass mapping of the brazilian savanna with a multi-sensor and machine learning approach. **Remote Sensing**, v. 12, n. 17, 2020. Disponível em: <<https://doi.org/10.3390/rs12172685>>. Acesso em: 20 jul. 2023.
- BONAN, G. B. Forests and climate change: Forcings, feedbacks, and the climate benefits of forests. **Science**, v. 320, n. 5882, p. 1444–1449, 2008.
- BOX, G. E. P. Robustness in the Strategy of Scientific Model Building. **Robustness in Statistics**. p.201–236, 1979.
- BRETAS, I. L.; VALENTE, D. S. M.; SILVA, F. F.; et al. Prediction of aboveground biomass and dry-matter content in Brachiaria pastures by combining meteorological data and satellite imagery. **Grass and Forage Science**, v. 76, n. 3, p. 340–352, 2021. John Wiley & Sons, Ltd. Disponível em: <<https://onlinelibrary.wiley.com/doi/full/10.1111/gfs.12517>>. Acesso em: 13 jul. 2023.
- BROWN, S. Measuring, monitoring, and verification of carbon benefits for forest-based projects. **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, v. 360, n. 1797, p. 1669–1683, 2002.
- BUSTAMANTE, M. M. C.; ROITMAN, I.; AIDE, T. M.; et al. Toward an integrated monitoring framework to assess the effects of tropical forest degradation and recovery on carbon stocks and biodiversity. **Global Change Biology**, v. 22, n. 1, p. 92–109, 2016.
- CALDERS, K.; JONCKHEERE, I.; NIGHTINGALE, J.; VASTARANTA, M. Remote sensing technology applications in forestry and REDD+. **Forests**, v. 11, n. 2, p. 10–13, 2020.
- CHAPIN, F. S.; EVINER, V. T. Biogeochemical Interactions Governing Terrestrial Net Primary Production. In: H. D. Holland; K. K. Turekian (Orgs.). **Treatise on Geochemistry: Second Edition**. p.189–216, 2014.
- CHAVE, J.; ANDALO, C.; BROWN, S.; et al. Tree allometry and improved estimation of carbon stocks and balance in tropical forests. **Oecologia**, v. 145, n. 1, p. 87–99, 2005.
- CHAVE, J.; CONDIT, R.; AGUILAR, S.; et al. Error propagation and scaling for tropical forest biomass estimates. **Philosophical Transactions of the Royal Society B**, v. 359, n. 1443, p. 409–420, 2004.

CHAVE, J.; RÉJOU-MÉCHAIN, M.; BÚRQUEZ, A.; et al. Improved allometric models to estimate the aboveground biomass of tropical trees. **Global Change Biology**, v. 20, n. 10, p. 3177–3190, 2014. Disponível em: <<http://doi.wiley.com/10.1111/gcb.12629>>. Acesso em: 16 set. 2018.

CHEN, L.; REN, C.; ZHANG, B.; WANG, Z.; XI, Y. Estimation of forest above-ground biomass by geographically weighted regression and machine learning with sentinel imagery. **Forests**, v. 9, n. 10, p. 1–20, 2018. MDPI AG.

CHEN, Q.; LU, D.; KELLER, M.; et al. Modeling and mapping agroforestry aboveground biomass in the Brazilian Amazon using airborne lidar data. **Remote Sensing**, v. 8, n. 1, p. 1–17, 2016.

CHUVIECO, E. **Fundamentals of satellite remote sensing: An environmental approach**. 2º ed. ed. New York: CRC Press Taylor & Francis Group, 2016, 457 p.

CLARINDO, W.; DALLACORT, R.; DIAS, V.; TIEPPO, R.; BARRETO, J. Estimativa de produtividade da cultura do milho safrinha por imagens de satélite Landsat 8. **ENCICLOPÉDIA BIOSFERA**, v. 19, n. 40, 2022.

CLARK, M. L.; ROBERTS, D. A.; EWEL, J. J.; CLARK, D. B. Estimation of tropical rain forest aboveground biomass with small-footprint lidar and hyperspectral sensors. **Remote Sensing of Environment**, v. 115, n. 11, p. 2931–2942, 2011.

COHEN, J. A power primer. **Psychological Bulletin**, American Psychological Association Inc. v. 112, n. 1, p. 155–159, 1992.

COOPS, N. C.; HILKER, T.; WULDER, M. A.; et al. Estimating canopy structure of Douglas-fir forest stands from discrete-return LiDAR. **Trees - Structure and Function**, v. 21, n. 3, p. 295–310, 2007.

CORRALES, M.; CUSCÓ, P.; USMANOVA, D. R.; et al. Machine Learning: How Much Does It Tell about Protein Folding Rates? **PLoS ONE**, v. 10, n. 11, 2015. Disponível em: <<http://europepmc.org/backend/ptpmcrender.fcgi?accid=PMC4659572&blobtype=pdf>>. Acesso em: 30 dez. 2018.

CUMMINGS, D. L.; KAUFFMAN, J. B.; PERRY, D. A.; HUGHES, R. F. Aboveground biomass and structure of rainforests in the southwestern Brazilian Amazon. **Forest Ecology and Management**, v. 163, p. 293–307, 2002. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378112701005874>>. Acesso em: 20 jul. 2023.

DE ALMEIDA, C. T.; GALVÃO, L. S.; ARAGÃO, L. E. DE O. C. E.; et al. Combining LiDAR and hyperspectral data for aboveground biomass modeling in the Brazilian Amazon using different regression algorithms. **Remote Sensing of Environment**, v. 232, 2019.

DE FREITAS, R.; CAVALCANTI, J. M. B.; CLEGER, S.; et al. Estimating Amazon carbon stock using AI-based remote sensing. **Communications of the ACM**, v. 63, n. 11, p. 46–48, 2020.

DIAZ, J. C. F.; CARTER, W. E.; SHRESTHA, R. L.; GLENNIE, C. L. LiDAR Remote Sensing. **Handbook of Satellite Applications**. 1º ed, v. 1, p.758–808, 2013.

DI MAIO, A.; RUDORFF, B. F. T.; MORAES, E. C.; et al. **Sensoriamento Remoto. Formação Continuada de Professores. Curso Astronáutica e Ciências do Espaço.** Ministério da Ciência e Tecnologia (MCT) e Agência Espacial Brasileira (AEB), 2008, 78p.

D'OLIVEIRA, M. V. N.; FIGUEIREDO, E. O.; PAPA, D. DE A. **Uso do Lidar como Ferramenta para o Manejo de Precisão em Florestas Tropicais.** 2014.

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

DOS SANTOS, E. G.; SHIMABUKURO, Y. E.; JORGE, A.; et al. Estimativa de biomassa em floresta degradada na região central do Estado do Mato Grosso a partir de dados de sensoriamento remoto. *In: XIX Simpósio Brasileiro de Sensoriamento Remoto. Anais [...].* Santos-SP: v. 358, 2019. Disponível em: <<https://proceedings.science/sbsr-2019/trabalhos/estimativa-de-biomassa-em-floresta-degradada-na-regiao-central-do-estado-do-mato?lang=pt-br>>. Acesso em: 20 jun. 2021.

DUARTE, J. F. DOS S.; CARNEIRO, R. S. G. S. **Análise de Vulnerabilidade Erosiva no Município de Paragominas-PA.** INPE: [s.n.], 2017, 20 p. Disponível em: <[http://wiki.dpi.inpe.br/lib/exe/fetch.php?media=ser300:alunos2017-ser300:grupo\\_monografia:trabalho\\_final\\_-\\_jessyca\\_e\\_rebeca.pdf](http://wiki.dpi.inpe.br/lib/exe/fetch.php?media=ser300:alunos2017-ser300:grupo_monografia:trabalho_final_-_jessyca_e_rebeca.pdf)>. Acesso em: 11 dez. 2018.

DUBAYAH, R.; BLAIR, J. B.; GOETZ, S.; et al. The Global Ecosystem Dynamics Investigation: High-resolution laser ranging of the Earth's forests and topography. **Science of Remote Sensing**, v. 1, p. 100002, 2020.

DUBE, T.; MUTANGA, O. Investigating the robustness of the new Landsat-8 Operational Land Imager derived texture metrics in estimating plantation forest aboveground biomass in resource constrained areas. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 108, p. 12–32, 2015. Elsevier B.V. Disponível em: <<https://doi.org/10.1016/j.isprsjprs.2015.06.002>>. Acesso em: 20 jul. 2023.

DUNCANSON, L.; ARMSTON, J.; DISNEY, M.; et al. The Importance of Consistent Global Forest Aboveground Biomass Product Validation. **Surveys in Geophysics**, v. 40, n. 4, p. 979–999, 2019.

DUNCANSON, L.; ARMSTON, J.; DISNEY, M.; et al. Aboveground Woody Biomass Product Validation Good Practices Protocol. Version 1.0. In: Laura Duncanson; Mat Disney; John Armston; et al. (Orgs.); **Good Practices for Satellite Derived Land Product Validation**. p.236, 2021.

ELACHI, C.; ZYL, J. VAN. **Introduction to the Physics and Techniques of Remote Sensing.** Second ed. John Wiley & Sons, 2006.

EMBRAPA. Empresa Brasileira de Pesquisa Agropecuária. **Paisagens Sustentáveis - Portal Embrapa.** 2016. Disponível em: <<https://www.embrapa.br/busca-de-solucoes-tecnologicas/-produto-servico/3862/paisagens-sustentaveis>>. Acesso em: 11 ago. 2021.

EMBRAPA. Empresa Brasileira de Pesquisa Agropecuária. **LANDSAT - Landsat Remote Sensing Satellite**. 2023. Disponível em: <<https://www.embrapa.br/satelites-de-monitoramento/missoes/landsat>>. Acesso em: 5 set. 2023.

ENE, L. T.; NÆSSET, E.; GOBAKKEN, T.; et al. A simulation approach for accuracy assessment of two-phase post-stratified estimation in large-area LiDAR biomass surveys. **Remote Sensing of Environment**, v. 133, p. 210–224, 2013.

FACELI, K.; LORENA, A. C.; GAMA, J.; CARVALHO, ANDRÉ, C. P. L. F. DE. **Inteligência Artificial - Uma Abordagem de Aprendizado de Máquina**. Rio de Janeiro: LTC Editora, 2011.

FACURE, M. **Aprendizado de Máquina: Essencial**. Disponível em: <<https://matheusfacure.github.io/AM-Essencial/>>. Acesso em: 30 dez. 2018.

FAGUA, J. C.; JANTZ, P.; RODRIGUEZ-BURITICA, S.; DUNCANSON, L.; GOETZ, S. J. Integrating LiDAR, multispectral and SAR data to estimate and map canopy height in tropical forests. **Remote Sensing**, v. 11, n. 2697, 2019.

FEARNSIDE, P. M. Brazil's Amazonian forest carbon: the key to Southern Amazonia's significance for global climate. **Regional Environmental Change**, v. 18, n. 1, p. 47–61, 2018.

FENG, Y.; LU, D.; CHEN, Q.; et al. Examining effective use of data sources and modeling algorithms for improving biomass estimation in a moist tropical forest of the Brazilian Amazon. **International Journal of Digital Earth**, v. 10, n. 10, p. 996–1016, 2017. Disponível em: <<https://doi.org/10.1080/17538947.2017.1301581>>. Acesso em: 1 jan. 2019.

FERREIRA, L. G.; FERREIRA, N. C.; FERREIRA, M. E. Sensoriamento remoto da vegetação: evolução e estado-da-arte. **Acta Scientiarum. Biological Sciences**, v. 30, n. 4, p. 379–390, 2008.

FIELD, A.; MILES, J.; FIELD, Z. **Discovering Statistics Using R**. 1st edition ed. AGE Publications Ltd, 2012, 957 p.

FONSECA, J. S. DA; MARTINS, G. DE A. **Curso de Estatística**. 6ª edição. São Paulo: Atlas, 2015. 320p.

FOODY, G. M.; BOYD, D. S.; CUTLER, M. E. J. Predictive relations of tropical forest biomass from Landsat TM data and their transferability between regions. **Remote Sensing of Environment**, v. 85, n. 4, p. 463–474, 2003.

FOULADINEJAD, F.; MATKAN, A.; HAJEB, M.; BRAKHASI, F. History and applications of space-borne LiDARS. *In: International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS. Anais [...]*. v. 42, p.407–414, 2019. Disponível em:< <https://isprs-archives.copernicus.org/articles/XLII-4-W18/407/2019/>>. Acesso em: 05 mar. 2019.

FOWLER, J. E. Compressive pushbroom and whiskbroom sensing for hyperspectral remote-sensing imaging. *In: IEEE International Conference on Image Processing, ICIP 2014. Anais [...]*. p.684–688, 2014. Disponível em: < <https://ieeexplore.ieee.org/document/7025137> >. Acesso em: 8 dez. 2022.

FUJIWARA, T.; TAKEUCHI, W. Simulation of sentinel-2 bottom of atmosphere reflectance using shadow parameters on a deciduous forest in Thailand. **ISPRS International Journal of Geo-Information**, v. 9, n. 10, p. 1–17, 2020.

GAIDA, W.; BREUNIG, F. M.; GALVÃO, L. S.; PONZONI, F. J. Correção Atmosférica em Sensoriamento Remoto: Uma Revisão. **Revista Brasileira de Geografia Física**, v. 13, n. 1, p. 229, 2020.

GAO, Y.; LU, D.; LI, G.; et al. Comparative analysis of modeling algorithms for forest aboveground biomass estimation in a subtropical region. **Remote Sensing**, v. 10, n. 4, 2018. MDPI AG. Disponível em: <<https://www.mdpi.com/2072-4292/10/4/627>>. Acesso em: 20 jul. 2023.

GATZIOLIS, D.; ANDERSEN, H. E. **A guide to LIDAR data acquisition and processing for the forests of the Pacific Northwest**. Gen. Tech. Rep. PNW-GTR-768. Portland, OR: U.S. Department of Agriculture, Forest Service, Pacific Northwest Research Station, 2008, 32 p.

GEIJZENDORFFER, I. R.; VAN TEEFFELLEN, A. J.; ALLISON, H.; et al. How can global conventions for biodiversity and ecosystem services guide local conservation actions? **Current Opinion in Environmental Sustainability**, v. 29, p. 145–150, 2017.

GERACE, A. D.; SCHOTT, J. R.; NEVINS, R. Increased potential to monitor water quality in the near-shore environment with Landsat's next-generation satellite. **Journal of Applied Remote Sensing**, v. 7, n. 1, p. 073558, 2013.

GÉRON, A. **Mãos à obra: aprendizado de máquina com Scikit-Learn, Keras & TensorFlow**. 2ª edição ed. Rio de Janeiro: Alta Books, 2021, 614 p.

GIONGO, M.; KOEHLER, H. S.; MACHADO, S. DO A.; KIRCHNER, F. F.; MARCHETTI, M. LiDAR: princípios e aplicações florestais. **Pesquisa Florestal Brasileira**, v. 30, n. 63, p. 231–244, 2010.

GIOSTRI, G. F.; NASCIMENTO, R. D. B. A estratégia mundial de REDD+: desafios e oportunidades do Brasil e, especialmente, da Floresta Amazônica. **Conexão Ciência (Online)**, v. 11, n. 1, p. 139–152, 2016.

GIZACHEW, B.; SOLBERG, S.; NÆSSET, E.; et al. Mapping and estimating the total living biomass and carbon in low-biomass woodlands using Landsat 8 CDR data. **Carbon Balance and Management**, v. 11, n. 1, 2016. BioMed Central Ltd. Disponível em: <<https://cbmjournal.biomedcentral.com/articles/10.1186/s13021-016-0055-8>>. Acesso em: 20 jul. 2023.

GLOOR, M.; PHILLIPS, O. L.; LLOYD, J. J.; et al. Does the disturbance hypothesis explain the biomass increase in basin-wide Amazon forest plot data? **Global Change Biology**, v. 15, n. 10, p. 2418–2430, 2009.

GORELICK, N.; HANCHER, M.; DIXON, M.; et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, 2017.

GORGENS, E. B.; DA SILVA, A. G. P.; RODRIGUEZ, L. C. E. **LiDAR: Aplicações Florestais**. 1.ed. ed. Curitiba-PR: Editora CRV, 2014, 132p.

HADI; PFEIFER, M.; KORHONEN, L.; WHEELER, C.; RAUTIAINEN, M. Forest canopy structure and reflectance in humid tropical Borneo: A physically-based interpretation using spectral invariants. **Remote Sensing of Environment**, v. 201, p. 314–330, 2017.

HAJEK, F.; VENTRESCA, M. J.; SCRIVEN, J.; CASTRO, A. Regime-building for REDD+: Evidence from a cluster of local initiatives in south-eastern Peru. **Environmental Science & Policy**, v. 14, n. 2, p. 201–215, 2011.

HANCOCK, S.; ARMSTON, J.; HOFTON, M.; et al. The GEDI Simulator: A Large-Footprint Waveform Lidar Simulator for Calibration and Validation of Spaceborne Missions. **Earth and Space Science**, v. 6, n. 2, p. 294–310, 2019.

HARDING, D. Pulsed Laser Altimeter Ranging Techniques and Implications for Terrain Mapping. In: Shan J, Toth CK (eds) **Book Review— Topographic Laser Ranging and Scanning: Principles and Processing**. Broken Sound Parkway, NW: Taylor & Francis Group, LLC. v. I, p.173–192, 2009.

HAWBAKER, T. J.; KEULER, N. S.; LESAK, A. A.; et al. Improved estimates of forest vegetation structure and biomass with a LiDAR-optimized sampling design. **Journal of Geophysical Research: Biogeosciences**, v. 114, n. G2, p. n/a--n/a, 2009.

HAY, G. J.; MARCEAU, D. J.; DUBÉ, P.; BOUCHARD, A. A multiscale framework for landscape analysis: Object-specific analysis and upscaling. **Landscape Ecology**, v. 16, p. 471–490, 2001.

HE, T.; WANG, D.; QU, Y. Land surface albedo. **Comprehensive Remote Sensing**. v. 1–9, p.140–162, 2017.

HEINRICH, V. H. A.; DALAGNOL, R.; CASSOL, H. L. G.; et al. Large carbon sink potential of secondary forests in the Brazilian Amazon to mitigate climate change. **Nature Communications**, v. 12, n. 1, p. 1–11, 2021.

HENRICH, V.; KRAUSS, G.; GÖTZE, C.; SANDOW, C. **IDB - www.indexdatabase.de**, Entwicklung einer Datenbank für Fernerkundungsindizes. AK Fernerkundung, Bochum, 4.-5. 10. 2012. Disponível em: <<https://www.indexdatabase.de/>>. Acesso em: 13 set. 2022.

HENRY, M.; BESNARD, A.; ASANTE, W. A.; et al. Wood density, phytomass variations within and among trees, and allometric equations in a tropical rainforest of Africa. **Forest Ecology and Management**, v. 260, n. 8, p. 1375–1388, 2010.

HENTZ, Â. M. K.; RUZA, M. S.; DALLA CORTE, A. P.; SANQUETTA, C. R. Técnicas de sensoriamento remoto para estimativa de biomassa em ambientes florestais. **Enciclopédia Biosfera**, v. 10, n. 18, p. 2810–2823, 2014.

HERNÁNDEZ-STEFANONI, J. L.; CASTILLO-SANTIAGO, M. Á.; MAS, J. F.; et al. Improving aboveground biomass maps of tropical dry forests by integrating LiDAR, ALOS PALSAR, climate and field data. **Carbon Balance and Management**, v. 15, n. 1, p. 1–17, 2020. Disponível em: <<https://doi.org/10.1186/s13021-020-00151-6>>. Acesso em: 5 abr. 2021.

HERNÁNDEZ-STEFANONI, J. L.; REYES-PALOMEQUE, G.; CASTILLO-SANTIAGO, M. ÁNGEL; et al. Effects of sample plot size and GPS location errors on aboveground

biomass estimates from LiDAR in tropical dry forests. **Remote Sensing**, v. 10, n. 10, 2018. Disponível em: <<https://www.mdpi.com/2072-4292/10/10/1586>>. Acesso em: 20 jul. 2023.

HICKEY, S. M.; CALLOW, N. J.; PHINN, S.; LOVELOCK, C. E.; DUARTE, C. M. Spatial complexities in aboveground carbon stocks of a semi-arid mangrove community: A remote sensing height-biomass-carbon approach. **Estuarine, Coastal and Shelf Science**, v. 200, p. 194–201, 2018.

HIRD, J. N.; DELANCEY, E. R.; MCDERMID, G. J.; KARIYEVA, J. Google Earth Engine, Open-Access Satellite Data, and Machine Learning in Support of Large-Area Probabilistic Wetland Mapping. **Remote Sensing**, v. 9, n. 12, p. 1315, 2017.

HORNING, N.; ROBINSON, J. A.; STERLING, E. J.; TURNER, W.; SPECTOR, S. **Remote Sensing for Ecology and Conservation: A Handbook of Techniques**. Oxford University Press, 2010.

HOUGHTON, R. A. Aboveground forest biomass and the global carbon balance. **Global Change Biology**, v. 11, n. 6, p. 945–958, 2005.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Mapa de biomas do Brasil. 2004.**

Disponível em:

<[https://geoftp.ibge.gov.br/informacoes\\_ambientais/estudos\\_ambientais/biomas/mapas/biomas\\_5000mil.pdf](https://geoftp.ibge.gov.br/informacoes_ambientais/estudos_ambientais/biomas/mapas/biomas_5000mil.pdf)>. Acesso em: 25 mar. 2021.

IBGE. Instituto Brasileiro de Geografia e Estatística. Geociências. Organização do território. Estrutura territorial. **Amazônia Legal. 2022.** Disponível em:

<<https://www.ibge.gov.br/geociencias/organizacao-do-territorio/estrutura-territorial/15819-amazonia-legal.html>>. Acesso em: 15 ago. 2023.

IMAZON. Instituto do Homem e Meio Ambiente da Amazônia. **Home/Imprensa. 2023.**

Disponível em: <<https://imazon.org.br/imprensa/amazonia-perdeu-quase-3-mil-campos-de-futebol-por-dia-de-floresta-em-2022-maior-desmatamento-em-15-anos/>>. Acesso em: 12 set. 2023.

INPE. Instituto Nacional de Pesquisas Espaciais. **TerraBrasilis. DETER Avisos - Amazônia Legal. 2023.** Disponível em:

<[http://terrabrasilis.dpi.inpe.br/app/dashboard/deforestation/biomes/legal\\_amazon/rates](http://terrabrasilis.dpi.inpe.br/app/dashboard/deforestation/biomes/legal_amazon/rates)>. Acesso em: 8 jul. 2023.

INPE. Instituto Nacional de Pesquisas Espaciais. **PRODES - Amazônia. Monitoramento da Floresta Brasileira por Satélite. 2022.** Disponível em:

<<http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/prodes>>. Acesso em: 7 jul. 2023.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: Uma perspectiva em Recursos Naturais**. São José dos Campos - São Paulo: Paêntese, 2009. 598 p.

JENSEN, J. R. **Introductory digital image processing: A remote sensing perspective**. 4th Editio ed. Pearson series in geographic information science, 2016. 623 p.

JETZ, W.; MCGEOCH, M. A.; GURALNICK, R.; et al. Essential biodiversity variables for mapping and monitoring species populations. **Nature Ecology and Evolution**, v. 3, n. 4, p. 539–551, 2019.

- JHA, N.; TRIPATHI, N. K.; BARBIER, N.; et al. The real potential of current passive satellite data to map aboveground biomass in tropical forests. **Remote Sensing in Ecology and Conservation**, 2021. Disponível em: <<https://doi.org/10.1002/rse2.203>>. Acesso em: 21 jul. 2021.
- JHA, N.; TRIPATHI, N. K.; CHANTHORN, W.; et al. Forest aboveground biomass stock and resilience in a tropical landscape of Thailand. **Biogeosciences**, v. 17, n. 1, p. 121–134, 2020.
- JIANG, X.; LI, G.; LU, D.; MORAN, E.; BATISTELLA, M. Modeling forest aboveground carbon density in the Brazilian Amazon with integration of MODIS and airborne lidar data. **Remote Sensing**, v. 12, n. 20, p. 1–25, 2020.
- JUNIOR, E. M. O uso do sensoriamento orbital na pesquisa socioeconômica. **Revista Científica Eletrônica de Agronomia**, v. V, n. 10, 2006.
- JUNK, W. J.; PIEDADE, M. T. F.; SCHÖNGART, J.; et al. A classification of major naturally-occurring Amazonian lowland wetlands. **Wetlands**, v. 31, n. 4, p. 623–640, 2011.
- KELSEY, K. C.; NEFF, J. C. Estimates of Aboveground Biomass from Texture Analysis of Landsat Imagery. **Remote Sensing**, v. 6, n. 7, p. 6407–6422, 2014.
- KHOSRAVIPOUR, A.; SKIDMORE, A. K.; WANG, T.; ISENBURG, M.; KHOSHELHAM, K. Effect of slope on treetop detection using a LiDAR Canopy Height Model. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 104, p. 44–52, 2015.
- KUMAR, L.; MUTANGA, O. Remote Sensing of Above-Ground Biomass. **Remote Sensing**, v. 9, n. 935, p. 8, 2017.
- LAFRANKIE, J. V.; ASHTON, P. S.; CHUYONG, G. B.; et al. Contrasting structure and composition of the understory in species-rich tropical rain forests. **Ecology**, v. 87, n. 9, p. 2298–2305, 2006.
- LAPOLA, D. M.; PINHO, P.; BARLOW, J.; et al. The drivers and impacts of Amazon forest degradation. **Science**, v. 379, n. 6630, p. eabp8622, 2023. Disponível em: <<https://www.science.org/doi/abs/10.1126/science.abp8622>>. Acesso em: 05 jun. 2023.
- LARY, D. J.; ALAVI, A. H.; GANDOMI, A. H.; WALKER, A. L. Geoscience Frontiers Machine learning in geosciences and remote sensing. **Geoscience Frontiers**, v. 7, n. 1, p. 3–10, 2016.
- LEE, J.; IM, J.; KIM, K.; QUACKENBUSH, L. J. Machine learning approaches for estimating forest stand height using plot-based observations and Airborne LiDAR data. **Forests**, v. 9, n. 5, 2018. Disponível em: <<https://www.mdpi.com/1999-4907/9/5/268>>. Acesso em: 20 jul. 2023.
- LEFSKY, M. A.; COHEN, W. B.; HARDING, D. J.; et al. Lidar remote sensing of above-ground biomass in three biomes. **Global Ecology and Biogeography**, v. 11, n. 5, p. 393–399, 2002.

LEITOLD, V.; KELLER, M.; MORTON, D. C.; COOK, B. D.; SHIMABUKURO, Y. E. Airborne lidar-based estimates of tropical forest structure in complex terrain: opportunities and trade-offs for REDD+. **Carbon Balance and Management**, v. 10, n. 1, p. 3, 2015.

LEVIN, S. A. The Problem of Pattern and Scale in Ecology: The Robert H. MacArthur Award Lecture. **Ecology**, v. 73, n. 6, p. 1943–1967, 1992.

LI, C.; LI, M.; IIZUKA, K.; et al. Effects of Forest Canopy Structure on Forest Aboveground Biomass Estimation Using Landsat Imagery. **IEEE Access**, v. 9, p. 5285–5295, 2021.

LI, G.; XIE, Z.; JIANG, X.; LU, D.; CHEN, E. Integration of ZiYuan-3 Multispectral and Stereo Data for Modeling Aboveground Biomass of Larch Plantations in North China. **Remote Sensing**, v. 11, n. 19, p. 2328, 2019.

LI, Y.; LI, M.; LI, C.; LIU, Z. Forest aboveground biomass estimation using Landsat 8 and Sentinel-1A data with machine learning algorithms. **Scientific Reports**, v. 10, n. 1, p. 1–12, 2020.

LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. **Remote Sensing and Image Interpretation**. 5<sup>a</sup> ed. WILEY, 2004, 763 p.

LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. **Remote Sensing and Image Interpretation**. 7th Edition. Wiley, 2015, 770p.

LIMA, T. A.; BEUCHLE, R.; LANGNER, A.; et al. Comparing Sentinel-2 MSI and Landsat 8 OLI Imagery for Monitoring Selective Logging in the Brazilian Amazon. **Remote Sensing**, v. 11, n. 8, p. 961, 2019.

LOPATIN, J.; DOLOS, K.; HERNÁNDEZ, H. J.; GALLEGUILLOS, M.; FASSNACHT, F. E. Comparing Generalized Linear Models and random forest to model vascular plant species richness using LiDAR data in a natural forest in central Chile. **Remote Sensing of Environment**, v. 173, p. 200–210, 2016.

LÓPEZ-SERRANO, P. M.; DOMÍNGUEZ, J. L. C.; CORRAL-RIVAS, J. J.; et al. Modeling of aboveground biomass with landsat 8 oli and machine learning in temperate forests. **Forests**, v. 11, n. 1, 2020. MDPI AG. Disponível em: <<https://www.mdpi.com/1999-4907/11/1/11>>. Acesso em: 20 jul. 2023.

LÓPEZ-SERRANO, P. M.; LÓPEZ-SÁNCHEZ, C. A.; DÍAZ-VARELA, R. A.; et al. Estimating biomass of mixed and uneven-aged forests using spectral data and a hybrid model combining regression trees and linear models. **IForest**, v. 9, p. 226–234, 2015. Disponível em: <<https://doi.org/10.3832/ifer1504-008>>. Acesso em: 20 jul. 2023.

LORENZZETTI, J. A. **Princípios Físicos de Sensoriamento Remoto**. 1 ed. ed. São Paulo - SP: Editora Blucher, 2015, 293 p.

LU, D. The potential and challenge of remote sensing-based biomass estimation. **International Journal of Remote Sensing**, v. 27, n. 7, p. 1297–1328, 2006.

LU, D.; CHEN, Q.; WANG, G.; et al. Aboveground Forest Biomass Estimation with Landsat and LiDAR Data and Uncertainty Analysis of the Estimates. **International Journal of**

- Forestry Research**, v. 2012, p. 1–16, 2012. Hindawi Limited. Disponível em: <<https://www.hindawi.com/journals/ijfr/2012/436537/>>. Acesso em: 20 jul. 2023.
- LU, D.; MAUSEL, P.; BRONDÍZIO, E.; MORAN, E. Relationships between forest stand parameters and Landsat TM spectral responses in the Brazilian Amazon Basin. **Forest Ecology and Management**, v. 198, n. 1–3, p. 149–167, 2004. Disponível em: <<https://doi.org/10.1016/j.foreco.2004.03.048>>. Acesso em: 20 jul. 2023.
- LU, X.; GUO, Q.; LI, W.; FLANAGAN, J. A bottom-up approach to segment individual deciduous trees using leaf-off lidar point cloud data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 94, p. 1–12, 2014.
- MACHADO, C. A. S.; QUINTANILHA, J. A. Módulo de treinamento: **Sistemas de Informações Geográficas (SIG) e Geoposicionamento: Uma aplicação Urbana**. 2008. Disponível em <[http://sites.poli.usp.br/d/ptr2355/PTR2355\\_Apostila\\_SR.pdf](http://sites.poli.usp.br/d/ptr2355/PTR2355_Apostila_SR.pdf)>. Acesso em: 04 jul. 2023.
- MALHI, Y.; ARAGÃO, L. E. O. C.; METCALFE, D. B.; et al. Comprehensive assessment of carbon productivity, allocation and storage in three Amazonian forests. **Global Change Biology**, v. 15, n. 5, p. 1255–1274, 2009.
- MALLET, C.; BRETAR, F. Full-waveform topographic lidar: State-of-the-art. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 64, n. 1, p. 1–16, 2009.
- MALTAMO, M.; NAESSET, E.; VAUHKONEN, J. **Forestry Applications of Airborne Laser Scanning**. Springer Science and Business Media Dordrecht, 2014.
- MAPBIOMAS. **Projeto MapBiomass – Coleção 7.1 da Série Anual de Mapas de Uso e Cobertura da Terra do Brasil**. 2021. Disponível em: <<https://mapbiomas.org/agropecuaria-urbanizacao-e-mineracao-transformam-a-amazonia>>. Acesso em: 21 ago. 2023.
- MARCHESAN, J. **Predição do estoque e dinâmica da biomassa acima do solo na floresta Amazônica utilizando inteligência artificial e dados de sensores remotos**, 2020. Tese ((Doutorado em Engenharia Florestal) - Universidade Federal de Santa Maria, Santa Maria, RS, 2020.
- MARCHESAN, J.; ALBA, E.; SCHUH, M. S.; FAVARIN, J. A. S.; PEREIRA, R. S. Aboveground Biomass Estimation in a Tropical Forest With Selective Logging Using Random Forest and Lidar Data. **Floresta**, v. 50, n. 4, p. 1873, 2020.
- MARCHESAN, J.; ALBA, E.; SCHUH, S.; et al. Aboveground biomass stock and change estimation in Amazon rainforest using airborne light detection and ranging , multispectral data , and machine learning algorithms. **Journal of Applied Remote Sensing**, v. 17, n. 2, p. 1–21, 2023. Disponível em: <<https://doi.org/10.1117/1.JRS.17.024509>>. Acesso em: 20 jul. 2023.
- MARSELIS, S. M.; ABERNETHY, K.; ALONSO, A.; et al. Evaluating the potential of full-waveform lidar for mapping pan-tropical tree species richness. **Global Ecology and Biogeography**, v. 29, n. 10, p. 1799–1816, 2020.

- MATOS, F. D. DE A.; KIRCHNER, F. F. Estimativa De Biomassa Da Floresta Ombrófila Densa De Terra Firme Na Amazônia Central Com O Satélite Ikonos II. **Floresta**, v. 38, n. 1, p. 157–171, 2008.
- MCGAUGHEY, R. J. **FUSION/LDV: Software for LIDAR Data Analysis and Visualization (Manual)**. U.S. Department of Agriculture, Forest Service. 2016, 206 p.
- MCMANAMON, P. **LiDAR Technologies and Systems**. Bellingham, Washington USA: SPIE PRESS, 2019, 504 p.
- MCROBERTS, R. E.; COHEN, W. B.; NÆSSET, E.; STEHMAN, S. V.; TOMPPO, E. O. Using remotely sensed data to construct and assess forest attribute maps and related spatial products. <https://doi.org/10.1080/02827581.2010.497496>, v. 25, n. 4, p. 340–367, 2010.
- MENESES, P. R.; ALMEIDA, T. **Princípios de sensoriamento Remoto**. Brasília, DF: UNB: Brasília, 2012, 266 p.
- MENESES, P. R.; NETTO, J. DA S. M. **Sensoriamento Remoto - Reflectância de alvos naturais**. Brasília/DF/ Planaltina: Universidade Federal de Brasília - UnB / Embrapa Cerrados, 2001, 262 p.
- MEYER, D.; DIMITRIADOU, E.; HORNIK, K.; WEINGESSEL, A.; LEISCH, F. e1071: Misc Functions of the Department of Statistics, Probability Theory Group (Formerly: E1071), TU Wien. R package version 1.7-0. 2018. Disponível em: <<https://cran.r-project.org/package=e1071>>.
- MIOT, H. A. Análise de correlação em estudos clínicos e experimentais. **Jornal Vascular Brasileiro**, v. 17, n. 4, p. 275–279, 2018.
- MISIUKAS, J. M.; CARTER, S.; HEROLD, M. Tropical Forest Monitoring: Challenges and Recent Progress in Research. **Remote Sensing 2021, Vol. 13, Page 2252**, v. 13, n. 12, p. 2252, 2021.
- MITCHARD, E. T. A.; FELDPAUSCH, T. R.; BRIENEN, R. J. W.; et al. Markedly divergent estimates of Amazon forest carbon density from ground plots and satellites. **Global Ecology and Biogeography**, v. 23, n. 8, p. 935–946, 2014.
- MMA. Ministério do Meio Ambiente. Biomas. **Amazônia**. 2021. Disponível em: <<https://antigo.mma.gov.br/biomas/amazonia>>. Acesso em: 25 mar. 2021.
- MMA. Ministério do Meio Ambiente. **ENREDD+: estratégia nacional para redução das emissões provenientes do desmatamento e da degradação florestal, conservação dos estoques de carbono florestal, manejo sustentável de florestas e aumento de estoques de carbono florestal**. Brasília: Brasil. Ministério do Meio Ambiente. Secretaria de Mudanças Climáticas e Qualidade Ambiental. Departamento de Políticas de Combate ao Desmatamento, 2016b. Disponível em: <[https://redd.unfccc.int/media/brazil\\_national\\_redd\\_strategy.pdf](https://redd.unfccc.int/media/brazil_national_redd_strategy.pdf)>. Acesso em: 26 jun. 2021.
- MMA. Ministério do Meio Ambiente. **Mapas de Cobertura Vegetal dos Biomas Brasileiros**. 2002. Disponível em: <<http://mapas.mma.gov.br/mapas/aplic/probio/datadownload.htm>>. Acesso em: 8 nov. 2017.

- MMA. Ministério do Meio Ambiente. **O que é REDD+**. 2016a. Disponível em: <<http://redd.mma.gov.br/pt/pub-apresentacoes/item/82-o-que-e-redd>>. Acesso em: 26 jun. 2021.
- MMA. Ministério do Meio Ambiente. **REDD+ na UNFCCC**. 2017. Disponível em: <<http://redd.mma.gov.br/pt/redd-unfccc>>. Acesso em: 8 jul. 2021.
- MOREIRA, M. A. **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação**. 1ª ed. São José dos Campos - SP: Instituto Nacional de Pesquisas Espaciais - INPE, 2001, 250 p.
- MOREIRA, M. A. **Fundamentos do Sensoriamento Remoto e metodologias de aplicação**. 4. ed. ed. Viçosa: Editora UFV, 2011, 422 p.
- MORTON, D. C. Forest carbon fluxes: A satellite perspective. **Nature Climate Change**, v. 6, n. 4, p. 346–348, 2016.
- MOURA, Y. M. DE; BALZTER, H.; GALVÃO, L. S.; et al. Carbon Dynamics in a Human-Modified Tropical Forest: A Case Study Using Multi-Temporal LiDAR Data. **Remote Sensing**, v. 12, n. 3, p. 430, 2020.
- MUTANGA, O.; ADAM, E.; CHO, M. A. High density biomass estimation for wetland vegetation using WorldView-2 imagery and random forest regression algorithm. v. 18, p. 399–406, 2012.
- MUTANGA, O.; MASENYAMA, A.; SIBANDA, M. Spectral saturation in the remote sensing of high-density vegetation traits: A systematic review of progress, challenges, and prospects. **ISPRS Journal of Photogrammetry and Remote Sensing**, 1. abr. 2023. Elsevier B.V. Disponível em: <<https://doi.org/10.1016/j.isprsjprs.2023.03.010>>. Acesso em: 20 jul. 2023.
- MYSTER, R. W. The Physical Structure of Forests in the Amazon Basin: a Review. **The Botanical Review**, v. 82, p. 407–427, 2016.
- NASA. National Aeronautics and Space Administration. Landsat Science. Disponível em: <<https://landsat.gsfc.nasa.gov/>>. Acesso em: 2 jul. 2023.
- NGUYEN, L. V.; TATEISHI, R.; KONDOH, A.; et al. Mapping tropical forest biomass by combining ALOS-2, Landsat 8, and field plots data. **Land**, v. 5, n. 4, 2016. Disponível em: <<https://doi.org/10.3390/land5040031>>. Acesso em: 20 jul. 2023.
- NGUYEN, T. H.; JONES, S. D.; SOTO-BERELOV, M.; HAYWOOD, A.; HISLOP, S. Monitoring aboveground forest biomass dynamics over three decades using Landsat time-series and single-date inventory data. **International Journal of Applied Earth Observation and Geoinformation**, v. 84, n. 101952, 2020.
- NOVO, E. M. L. DE M. **Sensoriamento Remoto Princípios e Aplicações**. 4º Edição ed. São Paulo: Editora Blucher, 2010.
- NUNES, S.; OLIVEIRA, L.; SIQUEIRA, J.; MORTON, D. C.; SOUZA, C. M. Unmasking secondary vegetation dynamics in the Brazilian Amazon. **Environmental Research Letters**, v. 15, n. 3, p. 034057, 2020.

OPTECH. **Airborne Lidar Summary Specification Sheet - ORION M300**. Disponível em: <[www.optech.com](http://www.optech.com)>. Acesso em: 17 ago. 2021.

ORDWAY, E. M.; ASNER, G. P. Carbon declines along tropical forest edges correspond to heterogeneous effects on canopy structure and function. **Proceedings of the National Academy of Sciences**, v. 117, n. 14, p. 7863–7870, 2020.

PAISAGENS SUSTENTÁVEIS BRASIL. **Forest Inventory: Fazenda Cauaxi**. 2016. Disponível em:

<<https://www.paisagenslidar.cnptia.embrapa.br/geonetwork/srv/por/catalog.search#/metadata/386defe3-9c2a-41e2-9392-dec94fbf52e3>>. Acesso em: 12 dez. 2018.

PANDIT, S.; TSUYUKI, S.; DUBE, T. Landscape-Scale Aboveground Biomass Estimation in Buffer Zone Community Forests of Central Nepal: Coupling In Situ Measurements with Landsat 8 Satellite Data. **Remote Sensing**, v. 10, n. 11, p. 1848, 2018.

PELLETIER, C.; VALERO, S.; INGLADA, J.; CHAMPION, N.; DEDIEU, G. Assessing the robustness of Random Forests to map land cover with high resolution satellite image time series over large areas. **Remote Sensing of Environment**, v. 187, p. 156–168, 2016.

PÉLLICO NETTO, S.; BRENA, D. A. **Inventário Florestal**. Curitiba-PR, 1997, 316 p.

PEREIRA, G. H. DE A.; LOHMANN, M.; DEPPE, F. Monitoramento de incêndios utilizando imagens Landsat 8: Um estudo de caso para o estado do Tocantins. *In: XVIII Simpósio Brasileiro de Sensoriamento Remoto - SBSR. Anais [...]*. Santos – SP, 2017. Disponível em: <<https://proceedings.science/sbsr/trabalhos/monitoramento-de-incendios-utilizando-imagens-landsat-8-um-estudo-de-caso-para-o?lang=pt-br>>. Acesso em: 07 jun. 2023.

PERIGOLO, N. A.; BRILHANTE DE MEDEIROS, M.; SIMON, M. F. Vegetation types of the upper Madeira River in Rondônia, Brazil. **Brittonia**, v. 64, n. 4, p. 423–446, 2017.

PHIRI, D.; MORGENROTH, J. Developments in Landsat land cover classification methods: A review. **Remote Sensing**, v. 9, n. 9, p. 967, 2017.

PHUA, M. H.; JOHARI, S. A.; WONG, O. C.; et al. Synergistic use of Landsat 8 OLI image and airborne LiDAR data for above-ground biomass estimation in tropical lowland rainforests. **Forest Ecology and Management**, v. 406, p. 163–171, 2017. Disponível em: <<https://doi.org/10.1016/j.foreco.2017.10.007>>. Acesso em: 20 jul. 2023.

PINAGÉ, E. R.; KELLER, M.; DUFFY, P.; et al. Long-Term Impacts of Selective Logging on Amazon Forest Dynamics from Multi-Temporal Airborne LiDAR. **Remote Sensing**, v. 11, n. 6, p. 709, 2019. Disponível em: <<https://www.mdpi.com/2072-4292/11/6/709/htm>>. Acesso em: 9 ago. 2021.

PIRES, J. M.; PRANCE, G. T. The vegetation types of the Brazilian Amazon. In: Prance, G.T.; Lovejoy, T. E. (Eds.) **Amazonia: Key Environments Series**. Pergamon Press, p.109–145, 1985.

PLOTON, P.; MORTIER, F.; RÉJOU-MÉCHAIN, M.; et al. Spatial validation reveals poor predictive performance of large-scale ecological mapping models. **Nature Communications** 2020 11:1, v. 11, n. 1, p. 1–11, 2020.

PONZONI, F. J. Sensoriamento Remoto No Estudo Da Vegetação: Diagnosticando a Mata Atlântica. In: RUDOFF, B. F. T. et al. (Ed.) **Curso De Uso De Sensoriamento Remoto No Estudo Do Meio Ambiente**. p.27, 2002. São José dos Campos - São Paulo: INPE. Disponível em: < [http://ecologia.ib.usp.br/lepac/bie5759/CAP8\\_FJPonzoni.pdf](http://ecologia.ib.usp.br/lepac/bie5759/CAP8_FJPonzoni.pdf) >. Acesso em: 04 jun. 2021.

PONZONI, F. J.; DOS SANTOS, S. B. Conversão de números digitais de imagens orbitais em valores de FRB de superfície. **Boletim de Ciências Geodesicas**, v. 14, n. 4, p. 541–556, 2008.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no Estudo da Vegetação**. São José dos Campos - São Paulo: Parêntese, 2009, 127 p.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. 2ª edição ed. São Paulo: Oficina dos Textos, 2012, 176 p.

POPESCU, S. C.; HAUGLIN, M. Estimation of Biomass Components by Airborne Laser Scanning. **Forestry Applications of Airborne Laser Scanning**. p.157–175, 2014.

POPESCU, S. C.; WYNNE, R. H.; NELSON, R. F. Measuring individual tree crown diameter with lidar and assessing its influence on estimating forest volume and biomass. **Canadian Journal of Remote Sensing**, v. 29, n. 5, p. 564–577, 2003.

POPESCU, S. C.; ZHAO, K.; NEUENSCHWANDER, A.; LIN, C. Satellite lidar vs. small footprint airborne lidar: Comparing the accuracy of aboveground biomass estimates and forest structure metrics at footprint level. **Remote Sensing of Environment**, v. 115, n. 11, p. 2786–2797, 2011.

PUIG, H. **A Floresta Tropical Úmida**. São Paulo: Editora UNESP: Imprensa Oficial do Estado de São Paulo, 2008, 496 p.

QGIS DEVELOPMENT TEAM. **QGIS Geographic Information System**. 2023. QGIS Association. Disponível em: <<https://www.qgis.org>>.

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

RAJPUT, D.; WANG, W. J.; CHEN, C. C. Evaluation of a decided sample size in machine learning applications. **BMC Bioinformatics**, v. 24, n. 1, 2023. BioMed Central Ltd. Disponível em: <<https://doi.org/10.1186/s12859-023-05156-9>>. Acesso em: 20 jul. 2023.

REDDY, M. A. **Remote Sensing and Geographical Information System**. 3ª ed. Hyderabad/Índia: BS Publications, 2008.

RÉJOU-MÉCHAIN, M.; BARBIER, N.; COUTERON, P.; et al. Upscaling Forest Biomass from Field to Satellite Measurements: Sources of Errors and Ways to Reduce Them. **SURVEYS IN GEOPHYSICS**, v. 40, n. 4, SI, p. 881–911, 2019.

RÉJOU-MÉCHAIN, M.; TANGUY, A.; PIPONIOT, C.; CHAVE, J.; HÉRAULT, B. biomass: an r package for estimating above-ground biomass and its uncertainty in tropical forests. **Methods in Ecology and Evolution**, v. 8, n. 9, p. 1163–1167, 2017.

RODRIGUES, T. E.; SILVA, R. DAS C.; SILVA, J. M. L. DA; et al. Caracterização e Classificação dos Solos do Município de Paragominas, Estado do Pará. **Embrapa**, v. ISSN 1517-, p. 55, 2003. Disponível em: <<https://www.embrapa.br/busca-de-publicacoes/-/publicacao/408067/caracterizacao-e-classificacao-dos-solos-do-municipio-de-paragominas-estado-do-para>>. Acesso em: 06 dez. 2021.

RODRÍGUEZ-VEIGA, P.; SAATCHI, S.; TANSEY, K.; BALZTER, H. Magnitude, spatial distribution and uncertainty of forest biomass stocks in Mexico. **Remote Sensing of Environment**, v. 183, p. 265–281, 2016.

RODRÍGUEZ-VEIGA, P.; WHEELER, J.; LOUIS, V.; TANSEY, K.; BALZTER, H. Quantifying Forest Biomass Carbon Stocks From Space. **Current Forestry Reports**, v. 3, n. 1, p. 1–18, 2017.

ROMAN, A.; URSU, T.-M. Multispectral satellite imagery and airborne laser scanning techniques for the detection of archaeological vegetation marks. *In: Landscape archaeology on the northern frontier of the Roman empire at Porolissum*. An interdisciplinary research project. Cluj-Napoca: Mega Publishing p.141–150, 2016.

ROUSSEL, J. R.; AUTY, D.; COOPS, N. C.; et al. lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. **Remote Sensing of Environment**, v. 251, p. 112061, 2020.

ROUSSEL, J.-R.; AUTY, D. **homogenize: Point Cloud Decimation Algorithm in lidR: Airborne LiDAR Data Manipulation and Visualization for Forestry Applications**. 2021. Disponível em: <<https://rdr.io/cran/lidR/man/homogenize.html>>. Acesso em: 5 ago. 2021.

RSTUDIO TEAM. RStudio: Integrated Development Environment for R. Boston, MA: RStudio, PBC. Disponível em: <<http://www.rstudio.com/>>. 2021.

RULLAN-SILVA, C. D.; OLTHOFF, A. E.; DELGADO DE LA MATA, J. A.; PAJARES-ALONSO, J. A. Remote monitoring of forest insect defoliation. A review. **Forest Systems**, v. 22, n. 3, p. 377–391, 2013. Disponível em: <<https://doi.org/10.5424/fs/2013223-04417>>. Acesso em: 20 jul. 2023.

SAATCHI, S. S.; HARRIS, N. L.; BROWN, S.; et al. Benchmark map of forest carbon stocks in tropical regions across three continents. **Proceedings of the National Academy of Sciences**, v. 108, n. 24, p. 9899–9904, 2011.

SAATCHI, S. S.; HOUGHTON, R. A.; DOS SANTOS ALVALÁ, R. C.; SOARES, J. V.; YU, Y. Distribution of aboveground live biomass in the Amazon basin. **Global Change Biology**, v. 13, n. 4, p. 816–837, 2007.

SAGANG, L. B. T.; PLOTON, P.; SONKÉ, B.; et al. Airborne Lidar Sampling Pivotal for Accurate Regional AGB Predictions from Multispectral Images in Forest-Savanna Landscapes. **REMOTE SENSING**, v. 12, n. 10, p. 1637, 2020.

SANQUETTA, C. R. Metodologias para determinação de biomassa florestal. In: C. R. Sanquetta; L. F. Watzlawick; R. Balbinot; M. A. B. Ziliotto; F. S. Gomes (Orgs.); **As florestas e o carbono**. Curitiba-PR: UFPR, p.119–140, 2002.

SANTOS, C. P. F.; VALLES, G. F.; SESTINI, M. F.; et al. Mapeamento dos Remanescentes e Ocupação Antrópica no Bioma Amazônia. *In: XIII Simpósio de Sensoriamento Remoto. Anais [...]*. Florianópolis. p.6941–6948, 2007. Disponível em: <<http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2006/11.18.01.25/doc/6941-6948.pdf>>. Acesso em: 05 mar. 2019.

SANTOS, E. G. DOS; SHIMABUKURO, Y. E.; MENDES DE MOURA, Y.; et al. Multi-scale approach to estimating aboveground biomass in the Brazilian Amazon using Landsat and LiDAR data. **International Journal of Remote Sensing**, v. 40, n. 22, p. 8635–8645, 2019.

SATO, L. Y.; GOMES, V. C. F.; SHIMABUKURO, Y. E.; et al. Post-fire changes in forest biomass retrieved by airborne LiDAR in Amazonia. **Remote Sensing**, v. 8, n. 10, p. 1–15, 2016.

SCHAWLOW, A. L.; TOWNES, C. H. Infrared and optical masers. **Physical Review**, v. 112, n. 6, p. 1940–1949, 1958.

SCHUH, M.; FAVARIN, J. A. S.; MARCHESAN, J.; et al. Machine learning and generalized linear model techniques to predict aboveground biomass in Amazon rainforest using LiDAR data. **Journal of Applied Remote Sensing**, v. 14, n. 03, 2020.

SCHULMAN, L.; RUOKOLAINEN, K.; JUNIKKA, L.; et al. Amazonian biodiversity and protected areas: Do they meet? **Biodiversity and Conservation**, out. 2007. Springer.

SCHWIEDER, M.; LEITÃO, P. J.; PINTO, J. R. R. R.; et al. Landsat phenological metrics and their relation to aboveground carbon in the Brazilian Savanna. **Carbon Balance and Management**, v. 13, n. 1, p. 1–15, 2018.

SFB. Serviço Florestal Brasileiro. **Sistema Nacional de Informações Florestais – SNIF**. 2021a. Disponível em: <<https://snif.florestal.gov.br/pt-br/os-biomas-e-suas-florestas>>. Acesso em: 24 mar. 2021.

SFB. Serviço Florestal Brasileiro. **Estoques das Florestas**. 2021b. Disponível em: <<https://snif.florestal.gov.br/pt-br/estoques-das-florestas>>. Acesso em: 25 mar. 2021.

SHERIDAN, R. D.; POPESCU, S. C.; GATZIOLIS, D.; et al. Modeling Forest Aboveground Biomass and Volume Using Airborne LiDAR Metrics and Forest Inventory and Analysis Data in the Pacific Northwest. **Remote Sensing**, v. 7, n. 1, p. 229–255, 2014.

SHIRATSUCHI, L. S.; BRANDÃO, Z. N.; VICENTE, L. E.; et al. Sensoriamento Remoto: conceitos básicos e aplicações na Agricultura de Precisão. *In: BERNARDI et al. Agricultura de precisão: resultados de um novo olhar*. Brasília, DF: Embrapa, 1ª edição ed., p.58–73, 2014.

SILVA, C. A.; KLAUBERG, C.; HUDAK, A. T.; et al. Predicting Stem Total and Assortment Volumes in an Industrial Pinus taeda L. Forest Plantation Using Airborne Laser Scanning Data and Random Forest. **Forests** 2017, v. 8, n. 7, p. 254, 2017.

SILVA, C.; HUDAK, A.; VIERLING, L.; et al. Impacts of Airborne Lidar Pulse Density on Estimating Biomass Stocks and Changes in a Selectively Logged Tropical Forest. **Remote**

**Sensing**, v. 9, n. 10, p. 1068, 2017. Disponível em: <<http://www.mdpi.com/2072-4292/9/10/1068>>. Acesso em: 3 nov. 2017.

SILVA, L. C.; ARAÚJO, E. J. G. DE; CURTO, R. D. A.; et al. Estoques De Biomassa E Carbono Em Unidade De Conservação No Bioma Mata Atlântica. **BIOFIX Scientific Journal**, v. 3, n. 2, p. 243, 2018.

SILVA, R. M. **Introdução ao Geoprocessamento: conceitos, técnicas e aplicações**. Novo Hamburgo, RS: Feevale: Feevale, 2007, 176 p.

SILVEIRA, P.; KOEHLER, H. S.; SANQUETTA, C. R.; ARCE, J. E. O Estado Da Arte Na Estimativa De Biomassa E Carbono Em Formações Florestais. **Floresta**, v. 38, n. 1, p. 185–206, 2008.

SIMOES, R.; PICOLI, M. C. A.; CAMARA, G.; et al. Land use and cover maps for Mato Grosso State in Brazil from 2001 to 2017. **Scientific Data**, v. 7, n. 1, p. 1–10, 2020.

SIST, P.; MAZZEI, L.; BLANC, L.; RUTISHAUSER, E. Large trees as key elements of carbon storage and dynamics after selective logging in the Eastern Amazon. **Forest Ecology and Management**, v. 318, p. 103–109, 2014.

SMITH, M. N.; STARK, S. C.; TAYLOR, T. C.; et al. Seasonal and drought-related changes in leaf area profiles depend on height and light environment in an Amazon forest. **New Phytologist**, v. 222, n. 3, p. 1284–1297, 2019.

SOLAR, R. R. DE C.; BARLOW, J.; ANDERSEN, A. N.; et al. Biodiversity consequences of land-use change and forest disturbance in the Amazon: A multi-scale assessment using ant communities. **Biological Conservation**, v. 197, p. 98–107, 2016.

STERCKX, S.; WOLTERS, E. Radiometric top-of-atmosphere reflectance consistency assessment for Landsat 8/OLI, sentinel-2/MSI, PROBA-V, and DEIMOS-1 over Libya-4 and RadCalNet calibration sites. **Remote Sensing**, v. 11, n. 19, 2019.

TANAGO, J. G. DE; LAU, A.; HARM, B.; et al. Estimation of above-ground biomass of large tropical trees with terrestrial LiDAR. In: D. Kriticos (Org.) **Methods in Ecology and Evolution**, John Wiley & Sons, v. 9, n. 2, p. 223–234, 2018.

TATSCH, J. D.; PAZ, A.; COLLISCHONN, W.; DA ROCHA, H. R. Comparação entre dois procedimentos de upscaling de redes de drenagem. In: XIV Simpósio Brasileiro de Sensoriamento Remoto. **Anais [...]**. Natal- RN, Brasil. p.4897–4904, 2009. Disponível em: <<http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2008/11.11.19.28/doc/4897-4904.pdf>>. Acesso em: 02 jun. 2021.

THENKABAIL, P. S. **Remote Sensing Handbook - Remotely sensed data characterization, classification, and accuracies**. Volume I ed. New York: CRC Press Taylor & Francis Group, 2016.

TIMOTHY, D.; MUTANGA, O.; CLETAH, S.; ADELABU, S.; TSITSI, B. Remote sensing of aboveground forest biomass: A review. **Tropical Ecology**, v. 57, n. 2, p. 125–132, 2016.

UNFCCC. United Nations Framework Convention on Climate Change. **COP 13 | UNFCCC**. 2007. Disponível em: <<https://unfccc.int/process-and-meetings/conferences/past->

conferences/bali-climate-change-conference-december-2007/cop-13>. Acesso em: 10 jul. 2021.

UNFCCC. United Nations Framework Convention on Climate Change. **COP 21 | UNFCCC**. 2015. Disponível em: <<https://unfccc.int/process-and-meetings/conferences/past-conferences/paris-climate-change-conference-november-2015/cop-21>>. Acesso em: 7 jul. 2021.

URBAZAEV, M.; THIEL, C.; CREMER, F.; et al. Estimation of forest aboveground biomass and uncertainties by integration of field measurements, airborne LiDAR, and SAR and optical satellite data in Mexico. **Carbon Balance and Management**, v. 13, n. 1, p. 5, 2018.

USGS. United States Geological Survey. **USGS.gov | Science for a changing world**. 2023a. Disponível em: <<https://www.usgs.gov/>>. Acesso em: 2 jul. 2023.

USGS. United States Geological Survey. **What are the band designations for the Landsat satellites? | U.S. Geological Survey**. 2023b. Disponível em: <<https://www.usgs.gov/faqs/what-are-band-designations-landsat-satellites>>. Acesso em: 5 set. 2023.

USGS. United States Geological Survey. **Landsat Collection 2 Surface Reflectance | U.S. Geological Survey**. 2023c. Disponível em: <<https://www.usgs.gov/landsat-missions/landsat-collection-2-surface-reflectance>>. Acesso em: 4 jul. 2023.

VALBUENA, R.; O'CONNOR, B.; ZELLWEGER, F.; et al. Standardizing Ecosystem Morphological Traits from 3D Information Sources. **Trends in Ecology and Evolution**, v. 35, n. 8, p. 656–667, 2020.

VELOSO, H. P.; FILHO, A. L. R. R.; LIMA, J. C. A. **Classificação da vegetação brasileira, adaptada a um sistema universal**. Rio de Janeiro: IBGE, 1991, 124 p.

VERMOTE, E.; JUSTICE, C.; CLAVERIE, M.; FRANCH, B. Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. **Remote Sensing of Environment**, v. 185, p. 46–56, 2016.

VERMOTE, E.; ROGER, J. C.; FRANCH, B.; SKAKUN, S. LASRC (Land Surface Reflectance Code): Overview, application and validation using MODIS, VIIRS, LANDSAT and Sentinel 2 data's. **International Geoscience and Remote Sensing Symposium (IGARSS)**, v. 2018-July, p. 8173–8176, 2018.

VIEIRA, S. A.; ALVES, L. F.; AIDAR, M.; et al. Estimation of biomass and carbon stocks: The case of the Atlantic Forest. **Biota Neotropica**, v. 8, n. 2, p. 21–29, 2008.

VOSSelman, G.; MASS, H.-G. **Airborne and Terrestrial Laser Scanning**. Whittles Publishing, CRC Press, 1 ed. 2010, 320 p.

WAGNER, W.; ULLRICH, A.; DUCIC, V.; MELZER, T.; STUDNICKA, N. Gaussian decomposition and calibration of a novel small-footprint full-waveform digitising airborne laser scanner. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 60, n. 2, p. 100–112, 2006.

WALKER, W. S.; GORELIK, S. R.; BACCINI, A.; et al. The role of forest conversion, degradation, and disturbance in the carbon dynamics of Amazon indigenous territories and protected areas. **Proceedings of the National Academy of Sciences of the United States of America**, v. 117, n. 6, p. 3015–3025, 2020.

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

WANG, Y.; WEINACKER, H.; KOCH, B. A Lidar point cloud based procedure for vertical canopy structure analysis and 3D single tree modelling in forest. **Sensors**, v. 8, n. 6, p. 3938–3951, 2008.

WATZLAWICK, L. F. **Estimativa de biomassa e carbono em Floresta Ombrófila Mista e plantações florestais a partir de dados de imagens do satélite Ikonos II**, 2003. Tese (Doutorado em Engenharia Florestal) - Universidade Federal do Paraná, Curitiba, PR, 2013.

WATZLAWICK, L. F.; SCHOENINGER, E. R.; KIRCHNER, F. F. **Elementos de Interpretação Fotográfica**. Guarapuava - PR: Editora Unicentro, 2007, 96 p.

WEAVER, R. Processing Levels. In: E. G. Njoku (Org.); **Encyclopedia of Remote Sensing**. New York, NY: Springer New York, p.517–520, 2014

WMO. WORLD METEOROLOGICAL ORGANIZATION. **WMO OSCAR | List of all Instruments**. Disponível em: <<https://space.oscar.wmo.int/instruments>>. Acesso em: 12 dez. 2022.

WU, C.; SHEN, H.; SHEN, A.; et al. Comparison of machine-learning methods for above-ground biomass estimation based on Landsat imagery. **Journal of Applied Remote Sensing**, v. 10, n. 3, p. 035010, 2016.

YADAV, S. Ground and Non-Ground Filtering for Airborne LIDAR Data. **International Journal of Advanced Remote Sensing and GIS**, v. 5, n. 1, p. 1500–1506, 2016.

ZHANG, K.; SHU-CHING CHEN; WHITMAN, D.; et al. A progressive morphological filter for removing nonground measurements from airborne LIDAR data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 4, p. 872–882, 2003.

ZHAO, P.; LU, D.; WANG, G.; et al. Examining spectral reflectance saturation in landsat imagery and corresponding solutions to improve forest aboveground biomass estimation. **Remote Sensing**, v. 8, n. 6, 2016. MDPI AG. Disponível em: <<https://doi.org/10.3390/rs8060469>>. Acesso em: 20 jul. 2023.

## APÊNDICE A - PROTOCOLO DESENVOLVIDO EM LINGUAGEM R COM AS ETAPAS DE PROCESSAMENTO DAS NUVENS DE PONTOS LIDAR

```

1  #Habilitar as ferramentas do pacote lidR para manipulação de dados LiDAR
2  library(lidR)
3  #Habilitar as ferramentas dos pacotes para manipulação de dados espaciais
4  library(sf)
5  library(raster)
6
7  #ETAPA 1
8  #Criar catálogo com os arquivos .las para processamento em lote
9  ctg <- readLAScatalog("C:/Diretorio/00_Dados/")
10 plot(ctg@data$geometry)
11 plot(ctg)
12
13 #ETAPA 2
14 #Checagem dos arquivos
15 las_check(ctg)
16 las_check(ctg, deep = TRUE) #checagem detalhada (arquivos individuais)
17
18 #ETAPA 3
19 #Homogeneização da nuvem de pontos
20 opt_output_files(ctg)="C:/Diretorio/01_Processamento/01_Thin/{*}_thin"
21 decimate_points(ctg, homogenize(12,25))
22
23 #ETAPA 4
24 #Classificação pontos do Terreno
25 rm(ctg)
26 thin=readLAScatalog("C:/Diretorio/01_Processamento/01_Thin/")
27 plot(thin)
28 opt_output_files(thin) <-
29 "C:/Diretorio/01_Processamento/02_Groundpoints/{*}_ground"
30 classify_ground(thin, algorithm = pmf(ws = 5, th = 3))
31
32 #ETAPA 5
33 #Criação do MDT
34 ground=readLAScatalog("C:/Diretorio/01_Processamento/02_Groundpoints/")
35 opt_output_files(ground) <- "C:/Diretorio/01_Processamento/03_DTM/{*}_dtm"
36 dtm=grid_terrain(ground, 1, tin())
37
38 #ETAPA 6
39 #Normalização das nuvens
40 opt_output_files(thin) <-
41 "C:/Diretorio/01_Processamento/04_Normalization/{*}_norm"
42 normalize_height(thin, dtm)
43
44 #ETAPA 7
45 #Recorte das parcelas
46 ctg_norm=readLAScatalog("C:/Diretorio/01_Processamento/04_Normalization/")
47 parcelas <- st_read("C:/Diretorio/00_Dados/SHP/parcelas.shp")
48 plot(ctg_norm)
49 plot(parcelas, add = TRUE, col = "red")
50 opt_output_files(ctg_norm) <-
51 "C:/Diretorio/01_Processamento/05_Clip/{full_code}"
52 #full_code: campo do shp com a identificação de cada parcela
53 clip_roi(ctg_norm, parcelas)
54
55 #ETAPA 8
56 #Cloud Metrics - Métricas sobre as nuvens de pontos nas parcelas recortadas
57 plots <- list.files("C:/Diretorio/01_Processamento/05_Clip/",full.names=
58 TRUE)
59 metrics <- lapply(plots, function(file){
60   las <- readLAS(file)
61   cloud_metrics(las, .stdmetrics)
62 })
63 metrics <- data.table::rbindlist(metrics)

```

```
60 metricas=data.frame(plots,metrics)
61 row.names(metricas)<-NULL
62 head(metricas)
63 #Exportar arquivo csv contendo as métricas a nível de parcela
64 write.table(metricas,
  "C:/Diretorio/01_Processamento/06_Cloud_Metrics/metricas.csv", row.names =
  F)
65
66 #ETAPA 9
67 #Grid Metrics - Raster com determinada métrica em toda área de estudo
68 ctg_norm=readLAScatalog("C:/Diretorio/01_Processamento/04_Normalization/")
69 opt_select(ctg_norm) <- "xyz"
70 # Raster de 50m com a elevação média
71 hmean <- grid_metrics(ctg_norm, ~mean(Z), 50)
72 plot(hmean, col = height.colors(50))
73 #Exportar raster
74 writeRaster(hmean,
  "C:/Diretorio/01_Processamento/07_Grid_Metrics/Elev.mean.tif")
```

## APÊNDICE B - PROTOCOLO EM LINGUAGEM JAVASCRIPT PARA PROCESSAMENTO DE IMAGENS OLI/LANDSAT-8 NA PLATAFORMA GOOGLE EARTH ENGINE

```

1 // Dados de entrada para processamento
2 // cobertura: poligono com a área de estudo
3 // dataset: Imagem OLI/Landsat-8 escolhida para o processamento
4 // parcelas: Unidades amostrais utilizadas na modelagem
5 // pontos_amostragem: Pontos aleatórios distribuídos na área de estudo
6
7 var cobertura = ee.FeatureCollection("projects/ee-mateuschuh/assets/Cobertura"),
8     dataset = ee.Image("LANDSAT/LC08/C02/T1_L2/LC08_223063_20141221"),
9     parcelas = ee.FeatureCollection("projects/ee-mateuschuh/assets/Parcelas_agb"),
10    pontos_amostragem = ee.FeatureCollection(
11        "projects/ee-mateuschuh/assets/pontos_amostragem_agb");
12
13 var geometry = cobertura;
14 // Apresentar quais imagens estão dentro da coleção
15 print(dataset);
16 //Aplicar os fatores de escala para distribuir os valores de reflectância entre 0 e
17 1
18 // (https://www.usgs.gov/faqs/how-do-i-use-scale-factor-landsat-level-2-science-produ
19 cts)
20 var dataset = dataset.multiply(0.0000275).add(-0.2);
21 var dataset = dataset.clip(geometry);
22 print(dataset);
23 // Apresentar quais imagens estão dentro da coleção
24 print('Coleção SR OLI - Escala radiométrica', dataset);
25 // Estas são as bandas que queremos que sejam exibidas
26 var OLI_bands = ['SR_B1', 'SR_B2', 'SR_B3', 'SR_B4', 'SR_B5', 'SR_B6', 'SR_B7'];
27 // Transformar toda a coleção OLI em apenas uma cena, encontrando o valor mediano
28 para cada pixel
29 var OLI_mosaic = dataset.select(OLI_bands).clip(cobertura);
30 print('Mosaico OLI', OLI_mosaic);
31 // Controlar como queremos que a imagem OLI seja exibida
32 var composicao = ['SR_B7', 'SR_B5', 'SR_B3'];
33 var OLI_display = {bands: composicao, min:0.1, max:0.7, gamma:1.8};
34 // Adicionar o OLI_mosaic ao mapa, usando os parâmetros visuais OLI_display e dando
35 a ele o nome "OLI_Image"
36 Map.addLayer(OLI_mosaic, OLI_display, "OLI_Image");
37 // Deslcoar automaticamente o mapa para o meio da área de interesse
38 Map.centerObject(cobertura, 14);
39 // Exibir sobre o mapa as parcelas de inventário
40 Map.addLayer(parcelas, {}, 'Parcelas');
41 //Map.addLayer(pontos_amostragem, {}, "Pontos Amostrais");
42
43 var indexes = {
44     'ATSAVI': "1.22 * ((b('SR_B5')-1.22*b('SR_B4')-0.03) / (1.22*b('SR_B5') +
45     b('SR_B4')-1.22*0.03 + 0.08*(1+1.22**2)))",
46     'AFRI1600': "b('SR_B5') - 0.66*(b('SR_B6')/(b('SR_B5')+0.66*b('SR_B6')))",
47     'ARVI2': "-0.18+1.77*((b('SR_B5')-b('SR_B4'))/(b('SR_B5')+b('SR_B4')))",
48     'BWDRAVI': "0.1*(b('SR_B5')-b('SR_B2')) / 0.1*(b('SR_B5')+b('SR_B2'))",
49     'CIGreen': "(b('SR_B5')/b('SR_B3'))-1",
50     'CVI': "b('SR_B5')*(b('SR_B4')/(b('SR_B3')**2))",
51     'SR': "b('SR_B5')/b('SR_B4')",
52     'NDVI': "(b('SR_B5') - b('SR_B4')) / (b('SR_B5') + b('SR_B4'))",
53     'CI': "(b('SR_B4')-b('SR_B2'))/b('SR_B4')",
54     'CTVI':
55     "( (b('SR_B5')-b('SR_B3')) / (b('SR_B5')+b('SR_B3')+0.5) / (abs((b('SR_B5')-b('SR_B3'))
56     ) / (b('SR_B5')+b('SR_B3')+0.5)) *
57     sqrt(abs((b('SR_B5')-b('SR_B3')) / (b('SR_B5')+b('SR_B3')+0.5)))",
58     'GDVI': "b('SR_B5')-b('SR_B3')",
59     'EVI': "2.5*((b('SR_B5')-b('SR_B4')) / ((b('SR_B5')+
60     6*b('SR_B4')-7.5*b('SR_B2')+1)))",
61     'n': "(2*((b('SR_B5')**2) - (b('SR_B4')**2)) + 1.5*b('SR_B5') + 0.5*b('SR_B4'))
62     / (b('SR_B5')+b('SR_B4')+0.5))",
63     'GEMI': "(2*((b('SR_B5')**2) - (b('SR_B4')**2)) + 1.5*b('SR_B5') +
64     0.5*b('SR_B4')) / (b('SR_B5')+b('SR_B4')+0.5))*((1 - 0.25*((b('SR_B5')**2) -
65     (b('SR_B4')**2)) + 1.5*b('SR_B5') + 0.5*b('SR_B4')) /
66     (b('SR_B5')+b('SR_B4')+0.5)) - ((b('SR_B4') - 0.125) / (1 - b('SR_B4')))",
67     'GLI': "(2*b('SR_B3') - b('SR_B4') - b('SR_B2')) / (2*b('SR_B3') + b('SR_B4') +
68     b('SR_B2'))",
69     'SAVI': "(b('SR_B5') - b('SR_B4')) / (b('SR_B5') + b('SR_B4') + 0.5)) * 1.5",
70     'GOSAVI': "(b('SR_B5') - b('SR_B3')) / (b('SR_B5') + b('SR_B3') + 0.16)",
71     'GSAVI': "(b('SR_B5') - b('SR_B3')) / (b('SR_B5') + b('SR_B3') + 0.5)) * 1.5",
72     'GBNDVI': "(b('SR_B5') - (b('SR_B3') + b('SR_B2'))) / (b('SR_B5') + (b('SR_B3') +
73     b('SR_B2')))",

```

```

57 'GRNDVI': "(b('SR_B5') - (b('SR_B3') + b('SR_B4')))) / (b('SR_B5') + (b('SR_B3') +
b('SR_B4')))",
58 'HUE': "atan(((2*b('SR_B4')-b('SR_B3')-b('SR_B2'))/30.5) *
(b('SR_B3')-b('SR_B2')))",
59 'IPVI': "(b('SR_B5') / (b('SR_B5') + b('SR_B4'))/2) * ((b('SR_B5') - b('SR_B3')) /
(b('SR_B5') + b('SR_B3')) + 1)",
60 'I': "(1/30.5)*(b('SR_B4')+b('SR_B3')+b('SR_B2'))",
61 'MVI': "b('SR_B5') / b('SR_B6')",
62 'MSAVI': "(2*b('SR_B5')+1 - sqrt((2*b('SR_B5')+1)**2 -
8*(b('SR_B5')-b('SR_B4'))))/2",
63 'NORMG': "b('SR_B3') / (b('SR_B5')+b('SR_B4')+b('SR_B3'))",
64 'NORMNIR': "b('SR_B5') / (b('SR_B5')+b('SR_B4')+b('SR_B3'))",
65 'NORMR': "b('SR_B4') / (b('SR_B5')+b('SR_B4')+b('SR_B3'))",
66 'NGRDI': "(b('SR_B3') - b('SR_B4')) / (b('SR_B3') + b('SR_B4'))",
67 'BNDVI': "(b('SR_B5') - b('SR_B2')) / (b('SR_B5') + b('SR_B2'))",
68 'GNDVI': "(b('SR_B5') - b('SR_B3')) / (b('SR_B5') + b('SR_B3'))",
69 'MNDVI': "(b('SR_B5') - b('SR_B7')) / (b('SR_B5') + b('SR_B7'))",
70 'RI': "(b('SR_B4') - b('SR_B3')) / (b('SR_B4') + b('SR_B3'))",
71 'PNDVI': "(b('SR_B5') - (b('SR_B3') + b('SR_B4') + b('SR_B2')))) / (b('SR_B5') +
(b('SR_B3') + b('SR_B4') + b('SR_B2')))",
72 'RBDNDVI': "(b('SR_B5') - (b('SR_B4') + b('SR_B2')))) / (b('SR_B5') + (b('SR_B4') +
b('SR_B2')))",
73 'IF': "(2*b('SR_B4')-b('SR_B3')-b('SR_B2')) / (b('SR_B3')-b('SR_B2'))",
74 'BGI': "b('SR_B1') / b('SR_B3')",
75 'SR560_658': "b('SR_B3') / b('SR_B4')",
76 'RDI': "b('SR_B7') / b('SR_B5')",
77 'GRVI': "b('SR_B5') / b('SR_B3')",
78 'RGR': "b('SR_B4') / b('SR_B3')",
79 'SLAVI': "b('SR_B5') / (b('SR_B4') + b('SR_B7'))",
80 'SBI': "0.3037*b('SR_B2') + 0.2793*b('SR_B3') + 0.4743*b('SR_B4') +
0.5585*b('SR_B5') + 0.5082*b('SR_B6') + 0.1863*b('SR_B7')",
81 'GVI': "-0.2848*b('SR_B2') - 0.2435*b('SR_B3') - 0.5436*b('SR_B4') +
0.7243*b('SR_B5') + 0.0840*b('SR_B6') - 0.1800*b('SR_B7')",
82 'WET': "0.1509*b('SR_B2') + 0.1973*b('SR_B3') + 0.3279*b('SR_B4') +
0.3406*b('SR_B5') - 0.7112*b('SR_B6') - 0.4572*b('SR_B7')",
83 'TVI': "sqrt(((b('SR_B4') - b('SR_B3')) / (b('SR_B4') + b('SR_B3')) + 0.5))",
84 'WDRVI': "(0.1*(b('SR_B5') - b('SR_B4')) / (0.1*(b('SR_B5') + b('SR_B4'))))",
85 'NDMI': "(b('SR_B5') - b('SR_B6')) / (b('SR_B5') + b('SR_B6'))"
86 };
87 var atsavi = OLI_mosaic.expression(indexes["ATSAVI"]).select([0], ['ATSAVI']);
88 var afril1600 = OLI_mosaic.expression(indexes["AFRI1600"]).select([0], ['AFRI1600'
]);
89 var arvi2 = OLI_mosaic.expression(indexes["ARVI2"]).select([0], ['ARVI2']);
90 var bwdrvi = OLI_mosaic.expression(indexes["BWDNDVI"]).select([0], ['BWDNDVI']);
91 var cigreen = OLI_mosaic.expression(indexes["CIGreen"]).select([0], ['CIGreen']);
92 var cvi = OLI_mosaic.expression(indexes["CVI"]).select([0], ['CVI']);
93 var sr = OLI_mosaic.expression(indexes["SR"]).select([0], ['SR']);
94 var ndvi = OLI_mosaic.expression(indexes["NDVI"]).select([0], ['NDVI']);
95 var ci = OLI_mosaic.expression(indexes["CI"]).select([0], ['CI']);
96 var ctvi = OLI_mosaic.expression(indexes["CTVI"]).select([0], ['CTVI']);
97 var gdvi = OLI_mosaic.expression(indexes["GDVI"]).select([0], ['GDVI']);
98 var evi = OLI_mosaic.expression(indexes["EVI"]).select([0], ['EVI']);
99 var gemi = OLI_mosaic.expression(indexes["GEMI"]).select([0], ['GEMI']);
100 var gli = OLI_mosaic.expression(indexes["GLI"]).select([0], ['GLI']);
101 var savi = OLI_mosaic.expression(indexes["SAVI"]).select([0], ['SAVI']);
102 var gosavi = OLI_mosaic.expression(indexes["GOSAVI"]).select([0], ['GOSAVI']);
103 var gsavi = OLI_mosaic.expression(indexes["GSAVI"]).select([0], ['GSAVI']);
104 var gbndvi = OLI_mosaic.expression(indexes["GBNDVI"]).select([0], ['GBNDVI']);
105 var grndvi = OLI_mosaic.expression(indexes["GRNDVI"]).select([0], ['GRNDVI']);
106 var hue = OLI_mosaic.expression(indexes["HUE"]).select([0], ['HUE']);
107 var ipvi = OLI_mosaic.expression(indexes["IPVI"]).select([0], ['IPVI']);
108 var i = OLI_mosaic.expression(indexes["I"]).select([0], ['I']);
109 var mvi = OLI_mosaic.expression(indexes["MVI"]).select([0], ['MVI']);
110 var msavi = OLI_mosaic.expression(indexes["MSAVI"]).select([0], ['MSAVI']);
111 var normg = OLI_mosaic.expression(indexes["NORMG"]).select([0], ['NORMG']);
112 var normnir = OLI_mosaic.expression(indexes["NORMNIR"]).select([0], ['NORMNIR']);
113 var normr = OLI_mosaic.expression(indexes["NORMR"]).select([0], ['NORMR']);
114 var ngrdi = OLI_mosaic.expression(indexes["NGRDI"]).select([0], ['NGRDI']);
115 var bndvi = OLI_mosaic.expression(indexes["BNDVI"]).select([0], ['BNDVI']);
116 var gndvi = OLI_mosaic.expression(indexes["GNDVI"]).select([0], ['GNDVI']);
117 var mndvi = OLI_mosaic.expression(indexes["MNDVI"]).select([0], ['MNDVI']);
118 var ri = OLI_mosaic.expression(indexes["RI"]).select([0], ['RI']);

```

```

119   var pndvi = OLI_mosaic.expression(indexes["PNDVI"]).select([0],['PNDVI']);
120   var rbandvi = OLI_mosaic.expression(indexes["RBNDVI"]).select([0],['RBNDVI']);
121   var iF = OLI_mosaic.expression(indexes["IF"]).select([0],['IF']);
122   var bgi = OLI_mosaic.expression(indexes["BGI"]).select([0],['BGI']);
123   var sr560_658 = OLI_mosaic.expression(indexes["SR560_658"]).select([0],[
124     'SR560_658']);
124   var rdi = OLI_mosaic.expression(indexes["RDI"]).select([0],['RDI']);
125   var grvi = OLI_mosaic.expression(indexes["GRVI"]).select([0],['GRVI']);
126   var rgr = OLI_mosaic.expression(indexes["RGR"]).select([0],['RGR']);
127   var slavi = OLI_mosaic.expression(indexes["SLAVI"]).select([0],['SLAVI']);
128   var sbi = OLI_mosaic.expression(indexes["SBI"]).select([0],['SBI']);
129   var gvi = OLI_mosaic.expression(indexes["GVI"]).select([0],['GVI']);
130   var wet = OLI_mosaic.expression(indexes["WET"]).select([0],['WET']);
131   var tvi = OLI_mosaic.expression(indexes["TVI"]).select([0],['TVI']);
132   var wdrvi = OLI_mosaic.expression(indexes["WDRVI"]).select([0],['WDRVI']);
133   var ndmi = OLI_mosaic.expression(indexes["NDMI"]).select([0],['NDMI']);
134
135   //Agrupar todos os índices de vegetação gerados em um único objeto, cuja classe é
136   "imagem".
136   var indices = ee.Image([]).addBands([atsavi, abril600, arvi2, bwdrvi, cigreen, cvi,
137     sr, ndvi, ci, ctvi, gdvi, evi, gemi, gli, savi, gosavi, gsavi, gbndvi, grndvi, hue,
138     ipvi, i, mvi,
139     msavi, normg, normnr, normr, ngrdi, bndvi, gndvi, mndvi, ri, pndvi, rbandvi, iF, bgi,
140     sr560_658, rdi, grvi, rgr, slavi, sbi, gvi, wet, tvi, wdrvi, ndmi  ]);
138   print('Índices de vegetação', indices);
139   //Paleta de cores adotada para a representação dos índices de vegetação
140   var greenPalette = ['DF923D', 'F1B555', 'FCD163', '99B718', '74A901', '66A000',
141     '529400', '3E8601', '207401',
142     '056201', '004C00', '023B01', '012E01', '011D01', '011301'];
141   //Apresentar no mapa os índices ATSAVI e NDVI
142   //Map.addLayer(indices.select('ATSAVI'), {min: 0, max: 1, palette: greenPalette},
143   'ATSAVI OLI', true);
144   Map.addLayer(indices.select('NDVI'), {min: 0.6, max: 1, palette: greenPalette},
145   'NDVI OLI', true);
145   //Criar e apresentar a lista com os nomes dos índices de vegetação criados
146   var lista_indices = indices.bandNames();
147   print(lista_indices);
148   //Agrupar no mesmo objeto "Imagem" as bandas OLI e os índices de vegetação gerados
149   var IVs_bandas = OLI_mosaic.addBands(indices);
150   print('Índices de vegetação e bandas', IVs_bandas);
151
152   //Extrair das bandas e dos índices de vegetação o valor médio dos pixels presentes
153   dentro das parcelas do inventário
153   var plotData = IVs_bandas.reduceRegions({
154     collection: parcelas,
155     reducer: ee.Reducer.mean(),
156     scale: 50});
157   print(plotData);
158
159   //Exportar a tabela para o drive
160   Export.table.toDrive({
161     collection: plotData,
162     description: 'dados_parcelas_gee_final',
163     folder: 'BD_Cauaxi',
164     fileFormat: 'CSV'});
165
166   //Extrair das bandas e dos índices de vegetação o valor dos pixels nos pontos
167   amostrais
167   var sampled_points = IVs_bandas.sampleRegions({
168     collection: pontos_amostragem,
169     scale: 50});
170
171   //Exportar a tabela para o drive
172   Export.table.toDrive({
173     collection: sampled_points,
174     description: 'pontos_amostragem_gee',
175     folder: 'BD_Cauaxi',
176     fileFormat: 'CSV'});

```

## APÊNDICE C - PROTOCOLO DESENVOLVIDO EM LINGUAGEM R PARA MODELAGEM E MAPEAMENTO DA AGB FLORESTAL A PARTIR DA ASSOCIAÇÃO ENTRE DADOS DE CAMPO E DE SENSORES REMOTOS

```

1  #Habilitar ferramentas dos seguintes pacotes de manipulação de dados
    espaciais
2  library(raster)
3  library(rgdal)
4
5  #####
6  #Importação da tabela de entrada
7  #####
8  # A tabela de entrada contém as amostras tomadas sobre os dados dos
    sensores remotos e sua correspondência com a biomassa
9  # As amostras podem ser tanto a nível de parcela quanto pontos aleatórios
10 # A variável biomassa deve estar posicionada na primeira coluna da tabela
11
12 db_modelagem=read.csv("C:/Diretorio_Tabela/dados_agb_sensores.csv");
13 # Inspeccionar o arquivo
14 head(db_modelagem)
15
16 #####
17 #Seleção de variáveis por correlação
18 #####
19 # Função genérica para calcular a correlação de n variáveis em relação a
    uma variável de interesse
20 corr=function(dados) {
21     r=0
22     p=0
23     for(i in 1:dim(dados)[2]){
24         cortest=cor.test(dados[[1]],dados[[i]],method = "spearman")
25         r[i]=cortest[[4]][[1]]
26         p[i]=cortest[[3]][[1]]
27         correlacao=data.frame(names(dados), r,p)
28         correlacao=correlacao[order(correlacao$r,decreasing = T),]
29         return(correlacao)}
30
31 # Aplicar a função corr a base de dados
32 # A variável de interesse deve estar posicionada na primeira coluna da
    tabela
33 correlacao=data.frame(corr(db_modelagem))
34 correlacao
35
36 #Resgatar as variaveis com correlacao significativa em funcao da
    probabilidade
37 significativas=subset(correlacao, p<=0.05)
38 significativas
39
40 # Filtrar a base de dados de entrada mantendo somente as variáveis com
    correlação significativa
41 selecao=db_modelagem[,significativas[,1]]
42 names(selecao)
43
44 #####
45 # Importar apenas os rasters selecionados pela análise da correlacao
46 #####
47 # Criar o caminho para importar os arquivos raster dos sensores remotos
48 caminho=paste("C:/Diretorio_Raster/", names(selecao[-1]), sep="" )
49 arquivos=paste(caminho, ".tif", sep "");arquivos
50
51 #Empilhar arquivos raster contidos no diretório:
52 Rasters <- stack(arquivos);names(Rasters); plot(Rasters)
53
54 #Converter o raster em uma tabela de dados com as coordenadas:
55 Rasters.df = as.data.frame(Rasters, xy = TRUE, na.rm = TRUE)
56 head(Rasters.df)
57

```

```

58 #####
59 # Criação do modelo
60 #####
61
62 #Habilitar pacote para implementação do algoritmo SVM
63 library(e1071)
64
65 # Bootstrapping
66 Dados_tot = selecao
67 N = length(Dados_tot[,1]) # número de observações conforme os dados
68 B = 500 #Definição do número de iterações da reamostragem bootstrap
69
70 #Definição dos hiperparâmetros do modelo SVM
71 custo=10
72 gamma=0.1
73 kernel="radial"
74
75 # Predição para a área total
76 Pred.map<-list()
77 ID.map<-list()
78 for(i in 1:B){
79   idx = sample(1:N, N, replace = T)
80   train = Dados_tot[idx,]
81   ID<-Rasters.df$x
82   ID.map [[i]]<-ID
83   svm <- svm(campo.TAGB ~., data = train, cost = custo, gamma = gamma,
84             kernel = kernel)
85   Pred<-predict(svm, newdata=Rasters.df) # Predição de AGB para a
86     paisagem
87   Pred.map[[i]]<-Pred
88 }
89
90 #Transformar em tabela:
91 Pred.map.data <- data.frame(Pred.map)
92 dim(Pred.map.data)
93 names(Pred.map.data)
94
95 #####
96 #Geração do mapa de biomassa média:
97 #####
98
99 #Calcular a média das 500 iterações:
100 mean.map <- rowMeans(Pred.map.data)
101 #Salvar apenas x, y e a média na tabela:
102 mean.map <- data.frame(cbind(Rasters.df[,c(1,2)], mean.map))
103 #Transformar para raster a partir da tabela:
104 mean.map <- rasterFromXYZ(mean.map)
105 plot(mean.map)
106 #Atribuir um sistema de coordenadas ao raster:
107 proj4string(mean.map)=CRS("+proj=utm +zone=22 +south +datum=WGS84 +units=m
108 +no_defs
109 +ellps=WGS84 +towgs84=0,0,0 ")
110 #Exportar o raster gerado:
111 writeRaster(mean.map, filename="C:/Diretorioi_Saida/mean.map_agb.tif",
112 format="GTiff", overwrite=TRUE)
113
114 #####
115 #Geração do mapa de desvio padrão da biomassa:
116 #####
117
118 #Calcular o desvio padrão das 500 iterações:
119 sd.map <- apply(Pred.map.data,1, sd)
120 #Salvar apenas x, y e a média na tabela:

```

```
117 sd.map <- data.frame(cbind(Rasters.df[,c(1,2)], sd.map))
118 #Transformar para raster a partir da tabela:
119 sd.map <- rasterFromXYZ(sd.map)
120 plot(sd.map)
121 #Atribuir um sistema de coordenadas ao raster:
122 proj4string(sd.map)=CRS("+proj=utm +zone=22 +south +datum=WGS84 +units=m
+no_defs
123                               +ellps=WGS84 +towgs84=0,0,0 ")
124 #Exportar o raster gerado:
125 writeRaster(sd.map, filename="C:/Diretorioi_Saida/sd.map_agb.tif", format=
"GTiff", overwrite=TRUE)
```

## ANEXO A – PROCESSAMENTO INVENTÁRIO FLORESTAL

Tabela 1 - Descrição das equações utilizadas no processamento dos dados do inventário florestal

(continua)

Parâmetro	Expressão matemática	Descrição
Média aritmética	$\bar{x} = \frac{\sum_{i=1}^n x_i}{n}$	$\bar{x}$ = Média aritmética $x_i$ = Variável amostrada $n$ = Número de unidades amostrais
Variância	$S_x^2 = \left[ \sum_{i=1}^n (x_i - \bar{x})^2 \right] / (n-1)$	$S_x^2$ = Variância da variável $\bar{x}$ = Média aritmética $x_i$ = Variável amostrada $n$ = Número de unidades amostrais
Variância da média (população infinita)	$S_{\bar{x}}^2 = \frac{S_x^2}{n}$	$S_{\bar{x}}^2$ = Variância da média $S_x^2$ = Variância da variável $n$ = Número de unidades amostrais
Desvio Padrão	$S_x = \pm \sqrt{S_x^2}$	$S_x$ = Desvio padrão $S_x^2$ = Variância da variável
Erro Padrão	$S_{\bar{x}} = \pm \sqrt{S_{\bar{x}}^2}$	$S_{\bar{x}}$ = Erro padrão da média $S_{\bar{x}}^2$ = Variância da média
Erro amostral	$E = t \cdot S_{\bar{x}}$ $t(0,05;84) = 1,9886$	$E$ = Erro amostral absoluto $t$ = Valor tabelado $S_{\bar{x}}$ = Erro padrão da média
Erro amostral relativo	$E_r = \frac{t \cdot S_{\bar{x}}}{\bar{x}} \cdot 100$ $t(0,05;84) = 1,9886$	$E_r$ = Erro de amostragem relativo $t$ = Valor tabelado $S_{\bar{x}}$ = Erro padrão da média $\bar{x}$ = Média aritmética
Coefficiente de variação	$CV (\%) = \frac{S_x}{\bar{x}} \cdot 100$	$CV (\%)$ = Coeficiente de variação $S_x$ = Desvio padrão $\bar{x}$ = Média aritmética
Intervalo de confiança para média	$\bar{x} \pm t \cdot S_{\bar{x}}$ ou $\bar{x} - t \cdot S_{\bar{x}} \leq \mu \leq \bar{x} + t \cdot S_{\bar{x}}$ $t(0,05;84) = 1,9886$	$\bar{x}$ = Média aritmética $S_{\bar{x}}$ = Erro padrão da média $t$ = Valor tabelado

Tabela 1 - Descrição das equações utilizadas no processamento dos dados do inventário florestal  
(conclusão)

Parâmetro	Expressão matemática	Descrição
Intervalo de confiança para o total da população	$X \pm N. t. S_{\bar{x}}$ ou $X - N. t. S_{\bar{x}} \leq X \leq X + N. t. S_{\bar{x}}$ $t(0,05;84) = 1,9886$	X = AGB total da população N = Número total de unidades amostrais na população $S_{\bar{x}}$ = Erro padrão da média t = Valor tabelado
Número ótimo de unidades amostrais (população infinita)	$n = \frac{t^2 \cdot CV\%^2}{E\%^2}$ $t(0,05;84) = 1,9886$	t = Valor tabelado CV% = Coeficiente de variação E% = Limite de erro admitido

Fonte: Adaptado de Péllico Netto e Brena (1997).