



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES



sid.inpe.br/mtc-m21d/2021/08.13.17.44-TDI

USO DE DADOS LIDAR, SAR E SENTINEL-2 PARA ESTIMATIVA DA BIOMASSA FLORESTAL ACIMA DO SOLO NA FLORESTA NACIONAL DO TAPAJÓS

Gabriel Oliveira Chagas

Dissertação de Mestrado do
Curso de Pós-Graduação
em Sensoriamento Remoto,
orientada pelo Dr. Yosio Edemir
Shimabukuro, aprovada em 17 de
agosto de 2021.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/4593M6E>>

INPE
São José dos Campos
2021

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE
Coordenação de Ensino, Pesquisa e Extensão (COEPE)
Divisão de Biblioteca (DIBIB)
CEP 12.227-010
São José dos Campos - SP - Brasil
Tel.:(012) 3208-6923/7348
E-mail: pubtc@inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):

Presidente:

Dra. Marley Cavalcante de Lima Moscati - Coordenação-Geral de Ciências da Terra (CGCT)

Membros:

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação (CPG)
Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia, Tecnologia e Ciência Espaciais (CGCE)
Dr. Rafael Duarte Coelho dos Santos - Coordenação-Geral de Infraestrutura e Pesquisas Aplicadas (CGIP)
Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon
Clayton Martins Pereira - Divisão de Biblioteca (DIBIB)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)

EDITORAÇÃO ELETRÔNICA:

Ivone Martins - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES



sid.inpe.br/mtc-m21d/2021/08.13.17.44-TDI

USO DE DADOS LIDAR, SAR E SENTINEL-2 PARA ESTIMATIVA DA BIOMASSA FLORESTAL ACIMA DO SOLO NA FLORESTA NACIONAL DO TAPAJÓS

Gabriel Oliveira Chagas

Dissertação de Mestrado do
Curso de Pós-Graduação
em Sensoriamento Remoto,
orientada pelo Dr. Yosio Edemir
Shimabukuro, aprovada em 17 de
agosto de 2021.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/4593M6E>>

INPE
São José dos Campos
2021

Dados Internacionais de Catalogação na Publicação (CIP)

Chagas, Gabriel Oliveira.

C346u Uso de dados LiDAR, SAR e Sentinel-2 para estimativa da biomassa florestal acima do solo na Floresta Nacional do Tapajós / Gabriel Oliveira Chagas. – São José dos Campos : INPE, 2021.

xxvi + 106 p. ; (sid.inpe.br/mtc-m21d/2021/08.13.17.44-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2021.

Orientador : Dr. Yosio Edemir Shimabukuro.

1. Sensoriamento remoto. 2. Floresta Amazônica.
3. Degradação florestal. 4. Modelagem de AGB. 5. Random forest. I.Título.

CDU 528.8.044(292.88)



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**
Serviço de Pós-Graduação - SEPGR**DEFESA FINAL DE DISSERTAÇÃO DE GABRIEL OLIVEIRA CHAGAS**
BANCA Nº 206/2021, REG 790636/2019

No dia 17 de agosto de 2021, as 14h00min, por teleconferência, o(a) aluno(a) mencionado(a) acima defendeu seu trabalho final (apresentação oral seguida de arguição) perante uma Banca Examinadora, cujos membros estão listados abaixo. O(A) aluno(a) foi APROVADO(A) pela Banca Examinadora, por unanimidade, em cumprimento ao requisito exigido para obtenção do Título de Mestre em Sensoriamento Remoto. O trabalho precisa da incorporação das correções sugeridas pela Banca Examinadora e revisão final pelo(s) orientador(es).

Título: “USO DE DADOS LIDAR, SAR E SENTINEL-2 PARA ESTIMATIVA DA BIOMASSA FLORESTAL ACIMA DO SOLO NA FLORESTA NACIONAL DO TAPAJÓS”

Observações da banca: As correções serão realizadas pelo aluno dentro prazo da PGSER e conferidas pelo seu orientador (Dr. Yosio Edemir Shimabukuro).

Membros da banca:

Dr. Fábio Furlan Gama - Presidente - INPE
Dr. Yosio Edemir Shimabukuro - Orientador - INPE
Dr. Edson Eyji Sano - Membro Externo - Embrapa Cerrados



Documento assinado eletronicamente por **Fábio Furlan Gama, Tecnologista**, em 19/08/2021, às 14:21 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Yosio Edemir Shimabukuro, Pesquisador**, em 19/08/2021, às 14:24 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **EDSON EYJI SANO (E), Usuário Externo**, em 19/08/2021, às 15:08 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site <http://sei.mctic.gov.br/verifica.html>, informando o código verificador **7971480** e o código CRC **B163EDC9**.

“Nessa pizza pode colocar catchup?”

Zaqueu Maia Chagas

À memória de meu pai, Zaqueu Maia Chagas
Para minha mãe Irene, meu irmão Guilherme e meu noivo Victor

AGRADECIMENTOS

Agradeço imensamente ao meu orientador Dr. Yosio Edemir Shimabukuro por me ensinar, conduzir e auxiliar durante todo o mestrado. Ao Dr. Edson Eyji Sano pela concessão das imagens SAR, possibilitando a realização deste estudo. Ao Dr. Fábio Furlan Gama e à Dra. Luciane Yumie Sato, pelos ensinamentos sobre radar e LiDAR, pela participação na banca de proposta desta dissertação e pela disponibilização dos dados SAR e LiDAR. E a todos os professores do INPE, pelos ensinamentos passados durante as aulas.

Agradeço também a cada pessoa que, de alguma forma, me ajudou durante minha jornada no mestrado. Agradeço, de forma especial, ao Victor Mendes de Oliveira Pinto, pela amizade e por toda a assistência durante todas as etapas de processamento desta pesquisa. Sua ajuda foi essencial para a conclusão desta dissertação. À Natalia Cristina Wiederkehr, por todo o auxílio com o processamento SAR, sua ajuda foi fundamental durante o meu mestrado. Ao Felipe Carvalho de Souza, por toda assistência no software R, principalmente com o algoritmo Random Forest e com a validação cruzada. Às amigas Tânia Beatriz Hoffmann e Carolina Gomes Vergeti Amim, pelas companhias durante as aulas no INPE e por toda ajuda nas disciplinas do mestrado.

Agradeço aos meus pais, Irene Maria de Oliveira Chagas e Zaqueu Maia Chagas, que se esforçaram muito para me oferecerem condições de chegar até aqui. Fico muito feliz por tido essas duas pessoas em minha caminhada. Ao meu irmão, Dr. Guilherme Oliveira Chagas pelos conselhos e amparos. Sou muito grato por tudo que essa pessoa fez por mim.

Agradeço também aos projetos Paisagens Sustentáveis e Melhoria dos Métodos de Estimativa de Biomassa e de Modelos de Estimativa de Emissões por Mudança de Uso da Terra pela disponibilização de seus dados. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), Código de Financiamento 001.

RESUMO

A Floresta Amazônica, a maior área de floresta contínua do mundo, tem um papel importante na regulação do clima local e regional, e na ciclagem da água. Além disso, a Amazônia detém um grande estoque de carbono em sua área florestal, mas o desflorestamento, a extração seletiva da madeira, os incêndios florestais e a fragmentação florestal têm contribuído para a redução desse estoque na região. Desta maneira, os dados de campo são fundamentais para mensurar a magnitude e a extensão desses impactos na floresta e entender a dinâmica das áreas degradadas. Esses dados também permitem a geração de modelos preditivos de biomassa florestal acima do solo (AGB). A AGB permite identificar áreas prioritárias para a atuação de projetos de conservação florestal, visto que a biomassa está relacionada com os estoques de carbono. Contudo, devido à extensão da Floresta Amazônica, a extrapolação dos dados de campo é limitada pelo número de amostras, pela área das parcelas de campo e pelo tempo gasto na amostragem de campo. Desse modo, o uso de dados de campo em conjunto com dados de sensoriamento remoto é uma alternativa para melhorar as estimativas de AGB. Todavia, devido à extensão da Floresta Amazônica, à variabilidade de sua estrutura e aos diferentes graus de degradação florestal, existem várias incertezas nas estimativas de AGB disponíveis na literatura. Assim, o presente trabalho teve como objetivo estimar a AGB para a Floresta Nacional do Tapajós e áreas adjacentes, considerando os diferentes graus de intervenção humana, utilizando dados dos sensores LiDAR (GEDI e ALS), SAR (PALSAR-2) e ópticos (Sentinel-2). Inicialmente, a AGB foi calculada com uma equação alométrica, utilizando dados de campo, para compor a variável dependente do modelo. As variáveis independentes do modelo obtidas neste estudo foram: as variáveis biofísicas da vegetação e as métricas derivadas dos sensores remotos utilizados (altura do dado GEDI e as métricas que descrevem a nuvem de pontos do LiDAR ALS); as decomposições polarimétricas SAR; os coeficientes de retroespalhamento, os índices e razões SAR disponíveis na literatura; os índices de vegetação do Sentinel-2 disponíveis na literatura e as imagens fração do modelo linear de mistura espectral (MLME). A seguir o algoritmo Random Forest foi usado para modelar a relação entre variáveis preditivas e a AGB. Os melhores modelos de AGB, com resoluções espaciais de 16,62 m, 50 m e 555,55 m, apresentaram RMSE de 60,35 Mg ha⁻¹ (23,07%), 75,88 Mg ha⁻¹ (26,42%) e 89,87 Mg ha⁻¹ (28,04%), e um R² de 0,72, 0,66 e 0,57, respectivamente. De acordo com a análise das estimativas de AGB, os modelos ótimos obtidos neste estudo foram capazes de descrever a AGB de acordo com o grau de degradação florestal. Os resultados demonstram o potencial dos dados GEDI, LiDAR ALS, SAR e ópticos para estimar a AGB em áreas de floresta tropical de acordo com a variabilidade da estrutura florestal.

Palavras-chave: Sensoriamento Remoto. Floresta Amazônica. Degradação florestal. Modelagem de AGB. Random Forest.

THE USE OF LIDAR, SAR AND SENTINEL-2 DATA TO ESTIMATE FOREST ABOVEGROUND BIOMASS IN TAPAJÓS NATIONAL FOREST

ABSTRACT

The world's largest continuous forest area, the Amazon rainforest, plays an important role in regulating local and regional climate and water cycling. In addition, the Amazon rainforest has a large carbon stock in its forest area, but deforestation, logging, forest fires, and forest fragmentation have contributed to the reduction of its carbon stock. Thus, field data are essential to measure the magnitude and extent of these impacts on forests and to understand the dynamics of degraded areas. These data also allow the generation of forest aboveground biomass (AGB) predictive models. The AGB allows identifying priority areas for the development of forest conservation projects since biomass is related to carbon stocks. However, due to the extension of the Amazon rainforest, the extrapolation of field data is limited by the number of samples, the area of the sample plots, and the time spent in field sampling. Thereby, the use of field data together with remote sensing data is an alternative to improve AGB estimates. Although, due to the extension, variability of the Amazon rainforest structure, and different degrees of forest degradation, there are several uncertainties in the AGB estimates available in the literature. Thus, the present work aimed to estimate AGB for the Tapajós National Forest and adjacent areas, considering the different degrees of forest degradation, using data from the sensors LiDAR (GEDI and ALS), SAR (PALSAR-2), and optical (Sentinel-2). Initially, the AGB was calculated with an allometric equation using field data to compose the dependent variable of the model. The independent variables of the model obtained in this study were: the vegetation biophysical variables and the metrics derived from LiDAR sensors (height of the GEDI data and the metrics that describe the LiDAR ALS point cloud); polarimetric SAR decompositions; backscatter coefficients, SAR indexes, and ratios available in the literature; Sentinel-2 vegetation indexes available in the literature and fraction images from linear spectral mixing model. Then, the Random Forest algorithm was used to model the relationship between predictive variables and AGB. The best AGB estimates with spatial resolution of 16.62m, 50m and 555.55m had RMSE of 60.35 Mg ha⁻¹ (23.07%), 75.88 Mg ha⁻¹ (26.42%) and 89.87 Mg ha⁻¹ (28.04%), and an R² of 0.72, 0.66 and 0.57, respectively. According to the AGB estimates analysis, the optimal models obtained in this study were able to describe the AGB according to the degree of forest degradation. The results demonstrate the potential of GEDI, LiDAR ALS, SAR, and optical data to estimate AGB in tropical forest areas according to the variability of the forest structure.

Keywords: Remote sensing. Amazon rainforest. Forest degradation. AGB Modeling. Random Forest.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 – Ilustração dos componentes de um sistema LiDAR ALS.	12
Figura 2.2 – Representação do modelo digital de terreno (DTM) (A) e do modelo de altura da copa (CHM) (B), com um metro de resolução espacial, de uma região da Floresta Nacional do Tapajós.	13
Figura 2.3 – Representação dos mecanismos de espalhamento mais comuns na superfície terrestre.	16
Figura 3.1 – Localização da área de estudo.	18
Figura 3.2 – Localização dos transectos GEDI e das parcelas de campo na área de estudo.	21
Figura 3.3 – Localização dos seis transectos LiDAR ALS do projeto Paisagens Sustentáveis e das parcelas de campo na área de estudo. (A) Transecto TAP1. (B) Transecto SAN2. (C) Transecto TAP5. (D) Transecto TAP4. (E) Transecto SAN1. (F) Transecto ANA.	23
Figura 3.4 – Localização dos transectos LiDAR do projeto Estimativa de Biomassa da Amazônia.	25
Figura 3.5 – Precipitação média entre os dias 08 e 17/04/2016 da versão 7 do produto TRMM 3B42.	29
Figura 3.6 – Precipitação média entre os dias 22/04 e 01/05/2016 da versão 7 do produto TRMM 3B42.	29
Figura 3.7 – Fluxograma geral das etapas metodológicas desse trabalho.	31
Figura 3.8 – Fluxograma do processamento dos dados LiDAR adotado.	33
Figura 3.9 – Divisão do transecto LiDAR ALS TAP1 em blocos de 800 x 800m com <i>buffer</i> de 100m.	34
Figura 3.10 – Fluxograma do pré-processamento das imagens ALOS PALSAR-2 utilizadas neste trabalho.	40
Figura 3.11 – Ilustração do processo de validação cruzada por <i>k-fold</i>	46
Figura 4.1 – Relevância das variáveis LiDAR ALS, SAR e ópticas com 16,62 m de resolução espacial para estimar a AGB de acordo com o algoritmo Boruta	49

Figura 4.2 – Relevância das variáveis LiDAR ALS, SAR e ópticas com 50 m de resolução espacial para estimar a AGB de acordo com o algoritmo Boruta. ...	50
Figura 4.3 – Relevância das variáveis GEDI, LiDAR ALS, SAR e ópticas com 555,55 m de resolução espacial para estimar a AGB de acordo com o algoritmo Boruta.....	52
Figura 4.4 – Relevância das variáveis GEDI, SAR e ópticas com 555,55 m de resolução espacial para estimar a AGB de acordo com o algoritmo Boruta. ...	53
Figura 4.5 – Relevância das variáveis LiDAR ALS, SAR e ópticas com 555,55 m de resolução espacial para estimar a AGB de acordo com o algoritmo Boruta.....	54
Figura 4.6 – Relevância das variáveis LiDAR ALS, SAR e ópticas com 555,55 m de resolução espacial para estimar a AGB, com 65 amostras, de acordo com o algoritmo Boruta.	55
Figura 4.7 – Valores observados de AGB pelos valores preditos de AGB com variáveis de 16,62 m de resolução. A linha vermelha representa o ajuste linear	58
Figura 4.8 – Valores observados de AGB pelos valores preditos de AGB com variáveis de 50m de resolução. A linha vermelha representa o ajuste linear. ...	60
Figura 4.9 – Valores observados de AGB pelos valores preditos de AGB com dados GEDI, LiDAR ALS, SAR e imagens ópticas de 555,55 m de resolução espacial. A linha vermelha representa o ajuste linear.	64
Figura 4.10 – Valores observados de AGB pelos valores preditos de AGB com dados LiDAR ALS, SAR e imagens ópticas de 555,55 m de resolução espacial. A linha vermelha representa o ajuste linear.	65
Figura 4.11 – Valores observados de AGB pelos valores preditos de AGB com dados GEDI, SAR e imagens ópticas de 555,55 m de resolução espacial. A linha vermelha representa o ajuste linear.....	66
Figura 4.12 – (A) Valores de AGB preditos pelo algoritmo <i>Random Forest</i> , com dados LiDAR ALS, PALSAR-2 e Sentinel-2, em uma região da Flona do Tapajós. (B) CHM do dado LiDAR ALS. (C) Componente de espalhamento volumétrico de Freeman-Durden. (D) Composição das bandas 665 nm, 560 nm	

e 490 nm dos dados do Sentinel-2. As Figuras A, B, C e D estão com uma resolução espacial de 16,62 m.....	68
Figura 4.13 – (A) Valores de AGB preditos pelo algoritmo <i>Random Forest</i> , com dados LiDAR ALS, PALSAR-2 e Sentinel-2, em uma região da Flona do Tapajós. (B) CHM do dado LiDAR ALS. (C) Componente de espalhamento volumétrico de Freeman-Durden. (D) Composição das bandas 665 nm, 560 nm e 490 nm dos dados do Sentinel-2. As Figuras A, B, C e D estão com uma resolução espacial de 50 m.....	69
Figura 4.14 – (A) Valores de AGB preditos pelo algoritmo <i>Random Forest</i> , com dados LiDAR ALS do projeto Estimativa de Biomassa da Amazônia, PALSAR-2 e Sentinel-2, em uma região da Flona do Tapajós. (B) CHM do dado LiDAR ALS. (C) Componente de espalhamento volumétrico de Freeman-Durden. (D) Composição das bandas 665 nm, 560 nm e 490 nm dos dados do Sentinel-2. As Figuras A, B, C e D estão com uma resolução espacial de 16,62 m.	70
Figura 4.15 – (A) Valores de AGB preditos pelo algoritmo <i>Random Forest</i> , com dados LiDAR ALS do projeto Estimativa de Biomassa da Amazônia, PALSAR-2 e Sentinel-2, em uma região da Flona do Tapajós. (B) CHM do dado LiDAR ALS. (C) Componente de espalhamento volumétrico de Freeman-Durden. (D) Composição das bandas 665 nm, 560 nm e 490 nm dos dados do Sentinel-2. As Figuras A, B, C e D estão com uma resolução espacial de 16,62 m.	71
Figura 4.16 – Valores de AGB preditos pelo algoritmo <i>Random Forest</i> , com o dado GEDI, em uma região da Flona do Tapajós. A AGB está com uma resolução espacial de 555,55 m.....	72
Figura A.1 – Valores observados de AGB pelos valores preditos de AGB com as métricas LiDAR ALS de 555,55m de resolução e 65 pontos amostrados. A linha vermelha representa o ajuste linear.....	100
Figura B.1 – Precipitação total diária entre os dias 08 e 17/04/2016 da estação Belterra/PA.....	105
Figura B.2 – Precipitação total diária entre os dias 22/04 e 01/05/2016 da estação Belterra/PA.	105

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 3.1 – Características das bandas espectrais do sentinel-2.	26
Tabela 3.2 – Características dos modos de imageamento do PALSAR-2.	27
Tabela 3.3 – Características das bandas espectrais do sentinel-2.	28
Tabela 3.4 – Métricas extraídas das nuvens de pontos LiDAR ALS.	35
Tabela 3.5 – Índices de vegetação que foram obtidos neste estudo.....	37
Tabela 3.6 – Coeficientes de retroespalhamento, razões, índices e decomposições polarimétricas utilizados neste trabalho.....	41
Tabela 4.1 – Desempenho médio do modelo para cada fonte de dado, com resolução espacial de 16,62 m, pelo método validação cruzada por <i>k-fold</i>	56
Tabela 4.2 – Desempenho médio do modelo com variáveis LiDAR ALS, SAR e ópticas de 16,62 m de resolução espacial para cada repetição da validação cruzada por <i>k-fold</i>	57
Tabela 4.3 – Desempenho médio do modelo para cada fonte de dado, com resolução espacial de 50m, pelo método validação cruzada por <i>k-fold</i>	59
Tabela 4.4 – Desempenho médio do modelo para cada fonte de dado, com resolução espacial de 555,55 m, pelo método validação cruzada por <i>k-fold</i> . ..	61
Tabela 4.5 – Valores máximos, mínimos e médios obtidos na estimativa da AGB usando os grupos de teste da validação cruzada por <i>k-fold</i> . As variáveis aplicadas possuem 555,55 m de resolução espacial.	63
Tabela A.1 – Informações sobre a aquisição dos dados LiDAR do projeto Paisagens Sustentáveis da região ANA.	101
Tabela A.2 – Informações sobre a aquisição dos dados LiDAR do projeto Paisagens Sustentáveis da região SAN1.	101
Tabela A.3 – Informações sobre a aquisição dos dados LiDAR do projeto Paisagens Sustentáveis da região SAN2.	102
Tabela A.4 – Informações sobre a aquisição dos dados LiDAR do projeto Paisagens Sustentáveis da região TAP1.	102
Tabela A.5 – Informações sobre a aquisição dos dados LiDAR do projeto Paisagens Sustentáveis da região TAP4.	103

Tabela A.6 – Informações sobre a aquisição dos dados LiDAR do projeto Paisagens Sustentáveis da região TAP5.	103
Tabela A.7 – Características da aquisição dos dados LiDAR do projeto Estimativa de Biomassa da Amazônia.	104

LISTA DE SIGLAS E ABREVIATURAS

ACD	Densidade de carbono acima do solo
AGB	Biomassa Florestal Acima do Solo
ALOS-2	<i>Advanced Land observing Satellite-2</i>
ALS	<i>Airborne Laser Scanning</i>
BNDES	Banco Nacional do Desenvolvimento
CHM	Modelo de Altura de Copa
DAP	Diâmetro à Altura do Peito
DTM	Modelo Digital do Terreno
EIR	Extração de Impacto Reduzido
Embrapa	Empresa Brasileira de Pesquisa Agropecuária
ENVI	<i>Environment for Visualizing Images</i>
ESA	<i>European Space Agency</i>
FAO	<i>Food and Agriculture Organization</i>
Flona	Floresta Nacional
Funcate	Fundação de Ciência, Aplicações e Tecnologia
GEDI	Global Ecosystem Dynamics Investigation
GPS	<i>Global Positioning System</i>
ICMBio	Instituto Chico Mendes de Conservação da Biodiversidade
IMU	Unidade de Medição Inercial
INMET	Instituto Nacional de Meteorologia
INPE	Instituto Nacional de Pesquisas Espaciais
IPCC	<i>Intergovernmental Panel on Climate Change</i>

IV	Índice de Vegetação
JERS	<i>Japanese Earth Resource Satellite</i>
LiDAR	<i>Light Detection And Ranging</i>
LP DAAC	<i>Land Processes Distributed Active Archive Center</i>
MAE	Erro médio absoluto
MFS	Manejo Florestal Sustentável
MLME	Modelo Linear de Mistura Espectral
MSA	Monitoramento Ambiental por Satélite no Bioma Amazônia
MSI	<i>MultiSpectral Instrument</i>
MZSA	Maior valor Z encontrado entre os atributos sombra
N	Norte
PALSAR-2	<i>Phased Array L-band Synthetic Aperture Radar-2</i>
PPCDAm	Plano de Ação para Prevenção e Controle do Desmatamento na Amazônia Legal
PRODES	Monitoramento do Desmatamento da Floresta Amazônica Brasileira por Satélite
R^2	Coefficiente de Determinação
R^2_{adj}	Coefficiente de Determinação Ajustado
Radar	<i>Radio Detection and Ranging</i>
REDD+	Redução de Emissões provenientes de Desmatamento e Degradação florestal, para a conservação dos estoques de carbono florestal, manejo sustentável de florestas e aumento dos estoques de carbono florestal
RF	<i>Random Forest</i>
RMSE	Raiz do Erro Médio Quadrático
S	Sul

SAR	<i>Synthetic Aperture Radar</i>
SNAP	<i>Sentinel Application Platform</i>
TIFF	<i>Tagged Image File Format</i>
TLS	<i>Terrestrial Laser Scanning</i>
TRMM	<i>Tropical Rainfall Measuring Mission</i>
UC	Unidade de Conservação
USAID	Agência dos Estados Unidos para o Desenvolvimento Internacional
UTM	Universal Transversa de Mercator
σ^0	Coeficiente de retroespalhamento
ρ	Densidade da Madeira

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1 Objetivos.....	2
2 FUNDAMENTAÇÃO TEÓRICA	4
2.1 Biomassa florestal	4
2.2 Fatores que afetam a AGB da Floresta Amazônica.....	5
2.2.1 Desflorestamento	5
2.2.2 Degradação florestal	6
2.2.2.1 Fragmentação florestal	6
2.2.2.2 Incêndios florestais	7
2.2.2.3 Exploração seletiva.....	8
2.3 LiDAR	10
2.4 Radar.....	14
3 MATERIAL E MÉTODOS.....	18
3.1 Área de estudo	18
3.2 Base de dados.....	19
3.2.1 Dados de campo	19
3.2.2 Dados LiDAR	20
3.2.2.1 GEDI	20
3.2.2.2 Projeto Paisagens Sustentáveis	21
3.2.2.3 Projeto Estimativa da Biomassa na Amazônia.....	24
3.2.3 Imagens ópticas	25
3.2.4 Dados ALOS PALSAR-2.....	26
3.2.5 Dados auxiliares.....	28
3.3 Metodologia	30
3.3.1 Cálculo da biomassa florestal acima do solo	32
3.3.2 Processamento dos dados LiDAR	33
3.3.3 Processamento das imagens ópticas.....	37
3.3.4 Pré-processamento das imagens ALOS PALSAR-2	40
3.3.5 Desenvolvimento dos modelos de AGB e seleção das variáveis	44

4	RESULTADOS E DISCUSSÃO	48
4.1	Seleção das variáveis para estimar a AGB.....	48
4.1.1	Seleção das variáveis de 16,62m e 50m de resolução espacial	48
4.1.2	Seleção das variáveis de 555,55 m de resolução espacial	51
4.2	Desempenho das fontes de dado para estimar a AGB.....	55
4.2.1	Variáveis de 16,62m de resolução espacial	55
4.2.2	Variáveis de 50m de resolução espacial	58
4.2.3	Variáveis de 555,55 m de resolução espacial	61
4.3	Predição da AGB	67
5	CONCLUSÃO.....	73
	REFERÊNCIAS BIBLIOGRÁFICAS.....	75
	APÊNDICE A – VALORES PREDITOS DE AGB.....	100
	ANEXO A – INFORMAÇÕES SOBRE A AQUISIÇÃO DOS DADOS LIDAR	101
	ANEXO B – PRECIPITAÇÃO TOTAL DIÁRIA.....	105

1 INTRODUÇÃO

A Floresta Amazônica, a maior área de floresta contínua do mundo, ocupa aproximadamente 5 milhões de km² do território brasileiro (Amazônia Legal). Em vista disso, a floresta tem um papel importante na regulação do clima local e regional, no armazenamento de carbono e na ciclagem da água. Além disso, a Amazônia detém um grande estoque de carbono em sua área florestal, mas os eventos climáticos e as atividades humanas como o desflorestamento, a extração seletiva da madeira, os incêndios e a fragmentação florestal têm contribuído para a redução desse estoque de carbono na Amazônia Legal (LEAN; WARRILOW, 1989; PAN et al., 2011; ARAGÃO et al., 2014; ALVES et al., 2017).

Neste contexto, os dados de campo são fundamentais para mensurar a magnitude e a extensão desses impactos na floresta e entender a dinâmica das áreas degradadas. Com esses dados, é possível gerar modelos preditivos de biomassa florestal acima do solo (AGB), a qual está relacionada com os estoques de carbono na floresta. Os dados de campo também são utilizados na validação das estimativas de AGB e nas análises de incertezas desses modelos. Evidencia-se, deste modo, a importância do tamanho amostral na precisão da AGB. Entretanto, devido à extensão da Amazônia Legal, a extrapolação dos dados de campo fica limitada pelo número de amostras, pela área das parcelas e pelo tempo de amostragem (LU et al., 2016; SULLIVAN et al., 2018).

Dessa maneira, a utilização dos dados de campo em conjunto com os diversos dados de sensoriamento remoto, é uma alternativa para a melhoria das estimativas de AGB (D'OLIVEIRA et al., 2012; BISPO et al., 2014; CASSOL et al., 2019, 2021; ALMEIDA et al., 2019). Dentre os dados utilizados para esse fim, podem-se citar os dados multiespectrais (PANDIT; TSUYUKI; DUBE, 2018), hiperespectrais (ALMEIDA et al., 2019), *Light Detection And Ranging* (LiDAR) (D'OLIVEIRA et al., 2012) e *radio detection and ranging* (radar) (BISPO et al., 2014).

Os dados multiespectrais convertidos em imagens fração por meio do modelo linear de mistura espectral (MLME) e em índices de vegetação são exemplos de

variáveis que podem ser aplicadas na modelagem da biomassa florestal (GHOSH; BEHERA, 2018; SANTOS et al., 2019). Todavia, imagens de sensores ópticos livres de nuvens, em regiões tropicais, podem não estar disponíveis muitas das vezes. Por isso, uma alternativa é a utilização de dados de radar de abertura sintética (SAR) nas estimativas de AGB, em virtude da capacidade dos sensores de radar em operar sob diferentes condições climáticas (BERNINGER et al., 2018). No entanto, diversos estudos relataram problema de saturação nessas estimativas com dados SAR em áreas com grandes volumes de AGB (YU; SAATCHI, 2016; ZHAO et al., 2016; JOSHI et al., 2017).

Por outro lado, é possível realizar estimativas em florestas com elevada quantidade de AGB por meio de dados LiDAR do tipo *Airborne Laser Scanning* (ALS), uma vez que as estimativas de AGB com esse sensor apresentam menor problema de saturação. Suas medidas tridimensionais possibilitam a obtenção de informações de florestas intactas e de áreas com diferentes graus de degradação. Todavia, a disponibilidade limitada desse tipo de dados impede sua aplicação de forma extensiva (LU et al., 2016). Em contrapartida, o recém lançado sensor LiDAR *Global Ecosystem Dynamics Investigation* (GEDI) não possui essa limitação, posto que esse sensor fornece medidas entre as latitudes 51,6° norte e 51,6° sul do globo terrestre (QI; DUBAYAH, 2016; GEDI ECOSYSTEM LIDAR, 2018).

Devido à extensão, à variabilidade da estrutura florestal amazônica e aos diferentes graus de intervenção humana, várias incertezas permanecem nos modelos de AGB disponíveis na literatura. Além disso, não existem, na literatura, estudos que analisam e comparam o desempenho dos dados GEDI, LiDAR ALS, SAR e imagens ópticas, individuais ou combinados, para estimar AGB na Floresta Amazônica. Diante disso, este trabalho visa avaliar o desempenho da combinação desses dados para estimar AGB em uma região da Amazônia brasileira, considerando os diversos níveis de intervenção humana.

1.1 Objetivos

O objetivo geral do trabalho é estimar a AGB da Floresta Nacional do Tapajós e áreas adjacentes por meio dos dados GEDI, LiDAR ALS, SAR e Sentinel-2,

considerando-se os diversos graus de intervenção humana no local. Os objetivos específicos da pesquisa são:

- Selecionar as variáveis de maior importância, derivadas dos dados GEDI, LiDAR ALS, SAR e Sentinel-2, para estimar AGB;
- Analisar o desempenho dos dados GEDI, LiDAR ALS, SAR e Sentinel-2, individuais, combinadas e de diferentes resoluções espaciais, para estimar AGB; e
- Estimar AGB em áreas com diferentes graus de degradação florestal por meio dos melhores modelos ajustados.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Biomassa florestal

A biosfera terrestre, onde ocorre a liberação e a absorção de gases de efeito estufa como o dióxido de carbono (CO₂), o metano (CH₄) e o óxido nitroso (N₂O), tem um papel fundamental na regulação do clima e na composição atmosférica. Atividades antrópicas têm contribuído para alterar os fluxos de gases de efeito estufa, principalmente como fonte e sumidouro de CO₂ (LOVELOCK; MARGULIS, 1974; BROWN, 1997; TIAN et al., 2016).

Segundo Harris et al. (2012), a mudança na cobertura vegetal foi responsável por 7% a 14% da emissão global do gás de efeito estufa, entre 2000 e 2005 e por $1,3 \pm 0,7$ Pg C (petagrama de carbono), por ano, entre 1990 e 2007, de acordo com as estimativas de Pan et al. (2011). Segundo esses mesmos autores, estima-se que 861 ± 66 Pg C estão armazenados nas florestas ao redor do globo. Desse total, aproximadamente 14%, 32% e 55% estão armazenados em florestas temperadas, boreais e tropicais, respectivamente.

A característica de sumidouro de carbono da floresta está relacionada com a biomassa, a qual é definida como o montante de matéria orgânica viva acima do solo nos indivíduos arbóreos, expressa em toneladas secas por unidade de área. É importante destacar que mais de 50% da biomassa consiste de carbono (LOVELOCK; MARGULIS, 1974; BROWN, 1997; TIAN et al., 2016).

Desta maneira, a quantificação da AGB possibilita identificar áreas prioritárias para redução de emissões provenientes de desmatamento e degradação florestal (REDD+), conservação e aumento de estoques de carbono florestal e manejo sustentável de florestas. Os países têm doado milhões de dólares para dar suporte a projetos de conservação florestal do programa REDD+ (LAING; TASCHINI; PALMER, 2016; BNDES, 2020).

Uma forma de calcular a AGB é por meio do volume dos indivíduos arbóreos. O volume é obtido por meio de uma equação biométrica e da densidade da madeira (ρ), a qual é um importante fator para realizar a conversão do volume em

biomassa (CANNELL, 1984; FEARNSTIDE, 1997). A unidade de medida utilizada para representar a AGB é Mg ha^{-1} .

2.2 Fatores que afetam a AGB da Floresta Amazônica

Os eventos climáticos, as atividades humanas e a regeneração florestal podem impactar positiva e negativamente a AGB. Desta forma, detalham-se, nesta Seção, os principais fatores que afetam a AGB na Floresta Amazônica, como o desflorestamento, exposto na Subseção 2.2.1, e a degradação florestal, abordado na Subseção 2.2.2.

2.2.1 Desflorestamento

Desde a década de 1970, a Amazônia Legal tem sofrido mudanças ambientais e sociais que foram fomentadas pelas políticas governamentais daquela década, tais como incentivo de imigração de pequenos e grandes agricultores, crescimento da infraestrutura local para colonização e instalação de empresas. Um dos principais componentes responsáveis pelo desflorestamento nessa região é a demanda dos mercados nacional e internacional por carne bovina e grãos (MORAN, 1993; BARONA et al., 2010).

Dentre os efeitos do desflorestamento, podem-se citar: as mudanças nos climas local e regional; a extinção de espécies; o aumento da vulnerabilidade do habitat; e o processo de fragmentação (SKOLE; TUCKER, 1993; MALHI et al., 2008; TAPIA- ARMIJOS et al., 2015). Vale ressaltar que, no processo de remoção da cobertura florestal, ocorre a liberação de gases de efeito estufa pela decomposição da biomassa e pela queima da vegetação. Em contrapartida, após o abandono de áreas desflorestadas, ocorre a remoção de CO_2 da atmosfera em razão do crescimento da vegetação secundária. Todavia, o estoque de carbono no solo e na vegetação florestal pode levar décadas para atingir o novo equilíbrio após o desflorestamento (RAMANKUTTY et al., 2007).

As taxas de desflorestamento na Amazônia Legal têm variado nas últimas três décadas. De acordo com o Monitoramento do Desmatamento da Floresta Amazônica Brasileira por Satélite (PRODES), no período de 1990 a 2004, as taxas de desflorestamento apresentaram crescimento acelerado, com picos em 1995 (29.059 km^2) e em 2004 (27.772 km^2). Após esse período, as taxas

apresentaram uma progressiva queda, com uma baixa histórica de 4.571 km² no ano de 2012 devido às ações implementadas pelo Plano de Prevenção e Controle do Desmatamento na Amazônia Legal (PPCDAm), criado em 2004. Entretanto, esse cenário tem-se revertido nos últimos nove anos, com o máximo valor alcançado em 2019 (9.762 km²) (INPE, 2019).

2.2.2 Degradação florestal

A degradação florestal é geralmente definida como a alteração de atributos específicos de uma área florestal. Entretanto, essa definição varia de acordo com o contexto político, com o objetivo de estudo e com a fitofisionomia da região. Na literatura, por exemplo, é possível encontrar diversas definições de degradação florestal (PUTZ; REDFORD, 2010; ROMERO-SANCHEZ; PONCE-HERNANDEZ, 2017; BULLOCK; WOODCOCK; OLOFSSON, 2020).

A *Food and Agriculture Organization* (FAO), por exemplo, define esse termo como a redução da capacidade da floresta em fornecer bens e serviços (KILLMANN et al., 2002). Para o *Intergovernmental Panel on Climate Change* (IPCC), a degradação florestal é a redução, a longo prazo, dos estoques de carbono sem que a cobertura florestal seja classificada como desflorestamento, de acordo com as definições aceitas na Conferência de Marraquexe (PENMAN et al., 2003).

A perda gradual, a longo prazo, das funções ecológicas e do sistema florestal, devido ao corte seletivo e às queimadas, é o conceito de degradação florestal adotado por INPE (2008). Essa relação entre degradação florestal e fragmentação florestal, incêndio florestal e extração seletiva da madeira legal e ilegal também foi feita por outros estudos realizados na Amazônia brasileira (SHIMABUKURO et al., 2014; DA SILVA et al., 2018; SILVÉRIO et al., 2019).

2.2.2.1 Fragmentação florestal

A fragmentação é a redução de uma cobertura florestal contínua em manchas menores. Uma das consequências da fragmentação é a perda de AGB nos anos iniciais, após o fracionamento da paisagem, e ao longo do tempo, em decorrência da exposição das bordas e do aumento dos riscos de incêndios e de atividades antrópicas nesses locais (LAURANCE et al., 1997; NUMATA et al.,

2017). Os efeitos da fragmentação florestal também incluem o aumento na taxa de mortalidade de indivíduos arbóreos, a mudança na composição de espécies vegetais e animais e o aumento da caça e da extração de recursos florestais (AUGUSTO; TABANEZ; VIANA, 2000; PERES, 2001; HERRERÍAS-DIEGO et al., 2008).

Segundo a estimativa de Aragão et al. (2014), o comprimento das bordas florestais na Amazônia Legal aumentou de 150.704 km em 1976 para 730.607 km em 2010, enquanto o número de fragmentos aumentou em 35.669 km nesse mesmo período. Conforme explicado por Aragão e Shimabukuro (2010), embora as taxas de desflorestamento tenham diminuído de 1998 a 2007 na Amazônia, o aumento de 60% na incidência de fogo neste período, pode estar ligado ao aumento da fragmentação e das bordas florestais.

2.2.2.2 Incêndios florestais

O fogo altera a composição e a estrutura de áreas florestais, afetando também o solo e o ciclo hidrológico do local. Geralmente o fogo está relacionado com atividades antrópicas, como a prática de apropriação de terra e de manejo de eliminação de resíduos agrícolas. O fogo utilizado nessas atividades pode penetrar nas florestas que foram impactadas pelo corte seletivo, intensificando a vulnerabilidade dessas florestas a futuras queimadas. Ademais, o fogo também pode adentrar em florestas intactas em estações de seca severa (COCHRANE; SCHULZE, 1999; NEPSTAD et al., 1999).

A relação entre desflorestamento, seca e fogo tem sido reportada como retroalimentação positiva (COCHRANE et al., 1999; LAURANCE; WILLIAMSON, 2001; ARAGÃO et al., 2008). As secas contribuem para a abertura do dossel florestal, devido ao aumento da mortalidade das árvores, principalmente aquelas presentes nas bordas das florestas, à redução da taxa de crescimento dos indivíduos arbóreos e ao aumento da queda das folhas. Dessa forma, a consequente insolação do sub-bosque propicia a secagem da serrapilheira e de outros resíduos presentes nesse ambiente. A combinação dessas condições com outros tipos de degradação florestal aumenta o risco de ocorrência dos

incêndios florestais (COCHRANE; LAURANCE, 2002; ARMENTERAS; GONZÁLEZ; RETANA, 2013).

A conversão florestal em larga escala para outro tipo de cobertura de terras e a fumaça produzida pelo fogo podem contribuir para a redução da pluviosidade na região afetada (ROSENFELD, 1999; ZEMP et al., 2017). Os resultados encontrados por Aragão et al. (2008) elucidaram a interação entre as condições climáticas e o processo de mudança no uso da terra. Segundo esses autores, as maiores taxas de desflorestamento ocorrem aproximadamente três meses após o pico da estação chuvosa, deixando a madeira e os resíduos secarem até o mês mais seco do ano. Quando os valores de pluviosidade chegam em seu mínimo, colocam fogo no material seco. Esses eventos geram retroalimentação positiva, aumentando a vulnerabilidade da Amazônia às mudanças climáticas. É importante salientar que os incêndios florestais foram responsáveis pela emissão média de 989 ± 504 Tg CO₂ por ano na Amazônia Legal, no período de 2003 a 2015, segundo Aragão et al. (2018).

2.2.2.3 Exploração seletiva

A exploração seletiva da madeira pode ser praticada de forma predatória ou por meio do manejo florestal sustentável (MFS). Dentre os impactos do corte seletivo, podem-se citar a morte e os danos nos indivíduos arbóreos que não foram cortados durante o processo de derrubada de árvores e extração de madeira. A atividade favorece o aumento dos resíduos de madeira, o aparecimento de clareiras e de vegetação herbácea, intensificando a vulnerabilidade desses locais ao fogo (COCHRANE; SCHULZE, 1999).

O MFS tem como definição a gestão de florestas visando o equilíbrio dos aspectos sociais, econômicos e ambientais, de acordo com os princípios de desenvolvimento sustentável (HICKEY, 2008). Dentre os interesses dessa atividade pode-se citar o aprimoramento de várias funções relacionadas à floresta, como a conservação da biodiversidade, a proteção do solo e dos recursos hídricos, e a extração de madeira e de produtos florestais não madeireiros. Além disso, o MFS auxilia na prevenção do desflorestamento, mantendo e aumentando os sumidouros de carbono (WANG; WILSON, 2007).

A extração de impacto reduzido (EIR), a qual se refere ao conjunto de práticas de manejo para melhorar a sustentabilidade da extração da madeira, é uma das possíveis atividades do MFS (CANOVA; HICKEY, 2012). Essa prática é aplicada antes e após o corte seletivo, buscando proteger a vegetação em regeneração, minimizando os danos no solo e nas espécies remanescentes (ROS-TONEN et al., 2008; VIDAL; WEST; PUTZ, 2016). O aumento das atividades de EIR se deu após a aprovação da Lei Federal nº 11.284, de 2 de março de 2006, a qual permite a colheita sustentável em florestas públicas (BRASIL, 2006a). A EIR tem sido considerada como uma importante ferramenta de redução nas taxas de desflorestamento em áreas de floresta tropical (SASAKI et al., 2016).

Dentre as demandas da EIR, é importante destacar a provisão contínua de serviços ecossistêmicos e rendimento sustentável de madeira, assegurando a regeneração de espécies comerciais a cada ciclo de corte. Com o intuito de propiciar essas condições, a EIR permite um ciclo de corte de no mínimo 25 anos e de no máximo 35 anos para uma intensidade máxima de colheita de 30 m³ de madeira por hectare, e de 10 anos para o MSF de baixa intensidade (10 m³ ha⁻¹), demonstrando vantagem em comparação com o ciclo de regeneração de 100 anos de corte seletivo não planejado (BRASIL, 2006b). Dentre os planejamentos necessários para realizar a EIR, podem-se mencionar: inventário da área de exploração; delineamento de trilhas e estradas; planejamento de queda das árvores; e outras atividades de manejo florestal, como o corte de cipós, que tem o objetivo de minimizar a abertura do dossel (SIST, 2000; KLEINSCHROTH; HEALEY, 2017).

Alguns autores argumentam que as técnicas de exploração seletiva não garantem a manutenção da biodiversidade e da sustentabilidade do processo (LACERDA; KANASHIRO; SEBBENN, 2008; CASTRO-ARELLANO et al., 2009; BURIVALOVA; ŞEKERCIOĞLU; KOH, 2014; FRANÇA et al., 2016; CHAVES; SIEVING; FLETCHER, 2017). Alguns estudos têm enfatizado a criação de diferentes condições ambientais decorrente da queda de árvores e do movimento de máquinas em áreas de EIR (SIST, 2000; CAMBI et al., 2015; KLEINSCHROTH; HEALEY, 2017). Essas diferentes condições interferem na

sobrevivência e no estabelecimento de espécies arbóreas (PARK; JOAQUIN JUSTINIANO; FREDERICKSEN, 2005).

Embora alguns estudos indiquem a sustentabilidade do ciclo da EIR com base na recuperação da AGB (WEST; VIDAL; PUTZ, 2014) e na regeneração natural de espécies comerciais (CARVALHO et al., 2017), existem evidências de que o atual ciclo de corte não é suficiente para o restabelecimento da floresta (HAWTHORNE et al., 2012; PUTZ et al., 2012; AVILA et al., 2017; NUMAZAWA et al., 2017). Esses ciclos não consideram os impactos do corte seletivo nas diferentes espécies arbóreas e nas taxas de regeneração dessas espécies. Schulze et al. (2008), por exemplo, mostraram que a dinâmica da população de *Tabebuia* spp. na Amazônia não permite manter o atual ciclo de exploração. Outros estudos mostraram que o habitat se torna menos adequado para a regeneração de algumas espécies arbóreas em regiões que foram impactadas pela EIR (DARRIGO; VENTICINQUE; DOS SANTOS, 2016).

Os impactos da extração seletiva da madeira são de difícil detecção e quantificação por meio de imagens ópticas, devido à dificuldade das imagens bidimensionais em registrar os impactos nas camadas abaixo do dossel (ELLIS et al., 2016). Dessa maneira, a utilização de dados auxiliares se faz necessário. O *Global Positioning System* (GPS) e o inventário de parcelas são exemplos de dados auxiliares para a mensuração de estruturas como estradas, pátios de estocagem de madeira, ramais de arraste e abertura do dossel florestal. Os dados LiDAR e SAR são considerados alternativos ou complementares para a detecção desses impactos ambientais devido à capacidade desses sensores em monitorar e quantificar a estrutura vertical e horizontal de extensas áreas florestais (D'OLIVEIRA et al., 2012; ELLIS et al., 2016; LEI et al., 2018; RANGEL PINAGÉ et al., 2019).

2.3 LiDAR

O LiDAR é um sensor ativo que coleta informações tridimensionais derivadas da velocidade e do pulso do laser. O pulso se refere ao tempo que o laser leva para atingir o objeto, ser retroespalhado e retornar para o sensor. Dessa forma,

conhecendo a velocidade da luz ($3 \times 10^8 \text{ m s}^{-1}$), é possível calcular essa distância, conforme mostrado na Equação 2.1 (HERITAGE; LARGE, 2009).


$$\text{Distância} = \frac{\text{Velocidade da luz} * \text{Tempo de retorno do sinal}}{2} \quad (2.1)$$

A tecnologia LiDAR varia de acordo com o tipo de sensor e plataforma, podendo ser de estação terrestre fixa ou móvel ou de plataforma móvel como aviões e satélites. Dentre os diferentes tipos de LiDAR, podem-se citar o *Terrestrial Laser Scanning* (TLS) e o ALS. O TLS possui uma densidade de nuvens de pontos bastante alta, da ordem de milhões de pontos por posição do scanner, permitindo a estimativa do volume de madeira por meio de reconstrução 3D da arquitetura do indivíduo arbóreo. O sensor ALS possui densidade menor em comparação com o TLS, onde cada célula de resolução contém uma amostra de possíveis retornos (BREDE et al., 2017).

Em estudos sobre vegetação, a faixa do comprimento de onda de operação do ALS tende a ser de 900 nm a 1.064 nm (faixa espectral do infravermelho próximo), devido à maior reflectância da vegetação nessa região do espectro eletromagnético, portanto, com maior sinal de retorno para o LiDAR. Outras vantagens da operação do sensor no infravermelho próximo são: ocorrência de menor absorção e espalhamento pela atmosfera; menores custos da matéria-prima para a produção dos sensores; e maior segurança ocular (LEFSKY et al., 2002; HOPKINSON et al., 2016).

Conforme mostrado na Figura 2.1, o equipamento ALS de varredura a laser coleta uma nuvem de pontos, cada ponto com a sua respectiva posição geográfica (x, y e z). Cada medida é corrigida pelas informações de movimento da aeronave denominada de *Inertial Measurement Unit* (IMU), como arfagem, rolagem e guinada, e pelas informações do GPS. As mensurações são feitas de um lado para o outro, ao longo do caminho de passagem da aeronave, sendo que as medidas da linha central são mais precisas em comparação àquelas próximas das bordas (HERITAGE; LARGE, 2009).

Figura 2.1 – Ilustração dos componentes de um sistema LiDAR ALS.



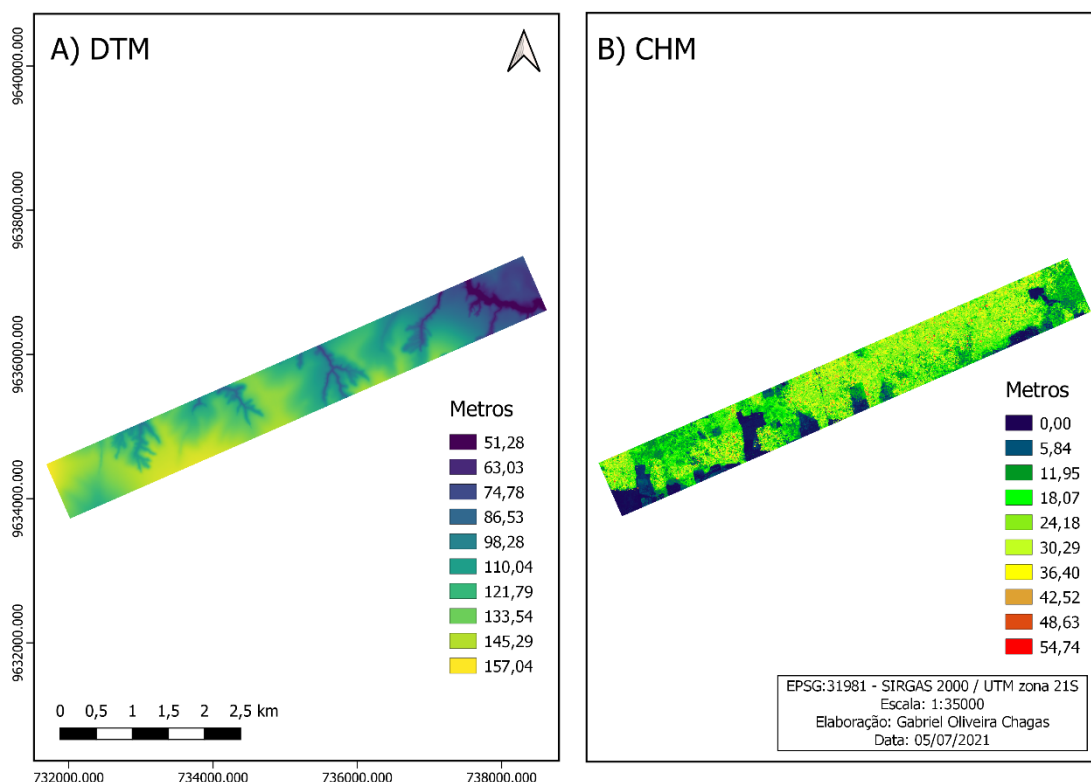
Fonte: Adaptada de Shan e Toth (2018).

Durante o processo de mensuração, os sensores LiDAR podem receber múltiplos retornos. O primeiro retorno do pulso indica o objeto mais próximo do sensor, enquanto o último retorno indica o objeto mais distante. Dessa maneira, o modelo de altura de copa (CHM) e de árvores individuais pode ser obtida a partir do primeiro conjunto de pulsos que retornam para o sensor, enquanto que o modelo digital do terreno (DTM) é obtido por meio do último conjunto que é retornado (Figura 2.2) (SHERIDAN et al., 2015).

Vários estudos têm usado dados LiDAR para caracterizar e monitorar a estrutura florestal (DALPONTE; COOMES, 2016; SULLIVAN et al., 2017). Esses dados são uma alternativa para a obtenção de informações confiáveis sobre a vegetação, como o número de indivíduos, o diâmetro e volume de copa e a altura de dossel e de árvores individuais. Com esses dados, é possível obter estimativas de AGB, volume, carbono estocado e área basal, diâmetro à altura

do peito (DAP), material combustível e índice de área foliar (IAF) de forma indireta (KORHONEN et al., 2011; SHERIDAN et al., 2015; VÉGA et al., 2016).

Figura 2.2 – Representação do modelo digital de terreno (DTM) (A) e do modelo de altura da copa (CHM) (B), com um metro de resolução espacial, de uma região da Floresta Nacional do Tapajós.



Fonte: Produção do autor.

Ellis et al. (2016), por exemplo, analisaram a eficiência dos dados LiDAR na detecção de distúrbios causados pelo corte seletivo em uma área florestal localizada em Bornéu com EIR. Por meio de um modelo de distúrbio derivado do LiDAR e de dados de campo, os autores geraram um mapa de impacto causado pela extração de madeira, observando-se a presença de estradas e ramais de arraste. Os autores encontraram 220 ha de áreas impactadas pelo corte seletivo utilizando dados LiDAR. Esse resultado teve boa concordância com os mapas feitos com dados de campo (217 ha, raiz do erro médio quadrático (RMSE) de 6 ha ou 3%).

Pinagé et al. (2019) investigaram os efeitos da EIR na estrutura florestal e na densidade de carbono acima do solo (ACD) em uma região do leste do estado

do Pará. Os autores detectaram uma perda na ACD de $12,4 \pm 3,16 \text{ Mg C ha}^{-1}$ e de $8,3 \pm 2,14 \text{ Mg C ha}^{-1}$ pelas colheitas realizadas em 2012 e 2013, respectivamente. Os resultados desse estudo mostraram que a abertura de copa das áreas intactas foi significativamente menor em comparação com outras áreas, mostrando a eficiência da utilização dos dados multitemporais do LiDAR ALS para caracterização da degradação florestal.

D'Oliveira et al. (2012) também utilizaram dados LiDAR para identificação de áreas impactadas por corte seletivo. Esses autores usaram os dados derivados do sensor Optech ALTM 3100EA (ALS) para identificar estruturas como estradas, ramais de arraste e aterragens na floresta estadual do Antimary no Acre. Os autores analisaram também a relação entre as métricas da nuvem de pontos LiDAR e AGB em áreas com alto nível de fechamento de copa, obtendo-se uma biomassa média de $231,6 \text{ Mg ha}^{-1}$. A AGB das áreas degradadas foi estatisticamente menor em comparação com as áreas intactas.

Almeida et al. (2019) investigaram a capacidade dos dados LiDAR, imagens hiperespectrais e combinação delas em estimar AGB na Amazônia brasileira. Dentre os algoritmos de modelagem aplicados no estudo, podem-se citar o *Support Vector Regression* e o *Random Forest*. Os autores selecionaram 333 métricas para otimizar os modelos de AGB. O melhor modelo foi ajustado com as variáveis independentes dos dois dados, apresentando um coeficiente de determinação (R^2) de 0,70, RMSE de $57,70 \text{ Mg ha}^{-1}$ e RMSE relativa de 31%.

Uma fonte de dados LiDAR para realizar a estimativa de AGB é o Global Ecosystem Dynamics Investigation (GEDI), posto que esse sensor fornece as medidas da superfície da Terra entre as latitudes $51,6^\circ \text{ N}$ e $51,6^\circ \text{ S}$ e seus dados estão disponíveis gratuitamente. Ademais, o GEDI provê informações para o estudo da estrutura das florestas do globo, embora o sensor apresente lacunas entre os lasers e as faixas de imageamento (GEDI ECOSYSTEM LIDAR, 2018; QI; DUBAYAH, 2016).

2.4 Radar

O radar é um sensor que emite pulsos no comprimento de onda maior que 1 mm e mede os sinais refletidos, ou espalhados, pela superfície de interesse.

Classificado como um sensor ativo, o radar tem a capacidade de operar independentemente de fontes de energia eletromagnética externas (como a luz solar) e sob diferentes condições climáticas (WOODHOUSE, 2017; FRANCESCHETTI; LANARI, 2018).

O SAR dispõe de algumas vantagens sobre os dados ópticos, como a capacidade de obter dados durante o dia e a noite e em diferentes condições climáticas. Além disso, as ondas eletromagnéticas do SAR são sensíveis às irregularidades da superfície, propriedades dielétricas, umidade, polarização e frequência, possibilitando realizar análises volumétricas dos alvos (SINHA et al., 2015; WOODHOUSE, 2017; FRANCESCHETTI; LANARI, 2018).


A resolução espacial dos dados SAR varia em alcance e em azimute. Além disso, os dados SAR podem ser obtidos nas bandas K, X, C, L e P e em diferentes polarizações. É importante destacar que cada banda interage de forma distinta para cada tipo de superfície. A banda X, por exemplo, interage principalmente com as folhas e com a cobertura do topo do dossel, permitindo estudos da camada superficial da copa das árvores. Por outro lado, a banda C penetra pelas folhas e é espalhada pelos pequenos ramos. A banda L, por ter uma boa capacidade penetrativa, o seu sinal é espalhado pelos ramos principais e pelo tronco. A banda P também tem uma boa capacidade penetrativa, por isso, o sinal é retroespalhado pelo tronco e pela interação entre solo e tronco. Dessa forma, as bandas L e P são frequentemente usadas nos estudos de biomassa florestal (SINHA et al., 2015).

A polarização das ondas eletromagnéticas se refere à direção do campo elétrico do sinal emitido e retroespalhado, podendo variar pela orientação do sinal e pelas estruturas na superfície. Os sinais podem ser emitidos e retroespalhados nas polarizações horizontal (H) e vertical (V), possibilitando quatro combinações: HH, VV, HV e VH. Os sinais que são emitidos e retroespalhados na mesma polarização são denominados de polarização paralela (HH e VV) e os sinais que são emitidos e retroespalhados em polarizações diferentes são denominados de polarização cruzada (HV e VH) (SINHA et al., 2015).

O sensor do sistema de imageamento SAR opera com uma visada lateral de iluminação perpendicular à direção da linha de voo. Cada *pixel* da imagem SAR é composto pelas informações de amplitude e fase (números complexos) associadas com a reflectividade de todos os alvos contidos na célula da imagem. Devido às interferências construtivas e destrutivas dos elementos dispersores, ocorre, nas imagens SAR, um ruído de aspecto granuloso denominado de ruído *speckle*. A variação da intensidade entre os *pixels* favorece a manifestação desse ruído, dificultando a interpretação e a análise da imagem. A redução do ruído *speckle* pode ser realizada por meio da filtragem e pela etapa de pré-processamento denominada *multilooking* (LEE; POTTIER, 2017).

O espalhamento superficial, a reflexão de canto e o espalhamento volumétrico são os tipos de mecanismos de espalhamento do radar mais comuns da superfície terrestre. O espalhamento superficial é a dispersão ou a reflexão da energia que ocorre em uma superfície definida. A reflexão de canto é a dispersão da energia por duas superfícies perpendiculares, enquanto o espalhamento volumétrico é a dispersão da energia por uma diversidade de elementos, sendo comum a sua ocorrência em áreas de floresta (RICHARDS, 2009). Esses mecanismos estão mostrados na Figura 2.3.

Figura 2.3 – Representação dos mecanismos de espalhamento mais comuns na superfície terrestre.



Fonte: Adaptada de Richards (2009).

Os coeficientes de retroespalhamento e as análises polarimétricas são exemplos de variáveis utilizadas na estimativa de AGB (SINHA et al., 2015). Vários estudos

estimaram AGB de florestas tropicais por meio de dados SAR (MITCHARD et al., 2009; CARREIRAS; MELO; VASCONCELOS, 2013; VILLARD et al., 2016; TREUHAFI et al., 2017; BERNINGER et al., 2018). Alguns estudos integraram dados SAR e LiDAR para obter estimativas de AGB (HYDE et al., 2007; MITCHARD et al., 2012; TSUI et al., 2012, 2013).

Bispo et al. (2014) geraram um modelo preditivo de biomassa na Floresta Nacional do Tapajós utilizando dados do PALSAR que opera na banda L. Nesse estudo, foram geradas as decomposições polarimétricas de Cloude e Pottier (1997), decomposição de Freeman e Durden (1998), razão da polarização paralela e da polarização cruzada, índices de Pope, Rey-Benayas e Paris (1994), variáveis geomorfométricas e os dados de campo para modelar a AGB por meio de uma regressão linear múltipla. O estudo teve, como resultado, uma equação com um R^2 de 0,79 e um coeficiente de determinação ajustado (R^2_{adj}) de 0,74.

Cassol et al. (2021) usaram os dados de polarização quádrupla do ALOS PALSAR-2 para modelar a AGB de florestas secundárias em uma região central da Amazônia brasileira. O melhor modelo explicou 65% da variabilidade da AGB e teve um RMSE de $8,8 \pm 3,0 \text{ Mg ha}^{-1}$, com uma RMSE relativa de 8,8%. As variáveis mais explicativas no ajuste do modelo de AGB nesse estudo foram aquelas derivadas do espalhamento múltiplo, volumétrico e reflexão de canto.

Pereira et al. (2018) aplicaram os dados do TerraSAR-X, Radarsat-2 e ALOS PALSAR-1 de dupla e quádrupla polarização para estimar AGB e IAF em uma área de várzea na Floresta Amazônica. Os resultados mostraram que as variáveis do ALOS PALSAR-1 proveram as melhores estimativas de AGB. Dentre as melhores variáveis para estimar a AGB, esteve a componente SAR de espalhamento volumétrico. O desempenho do modelo de AGB apresentou RMSE de $74,6 \text{ Mg ha}^{-1}$, RMSE relativa de 0,88% e R^2 de 0,46%.

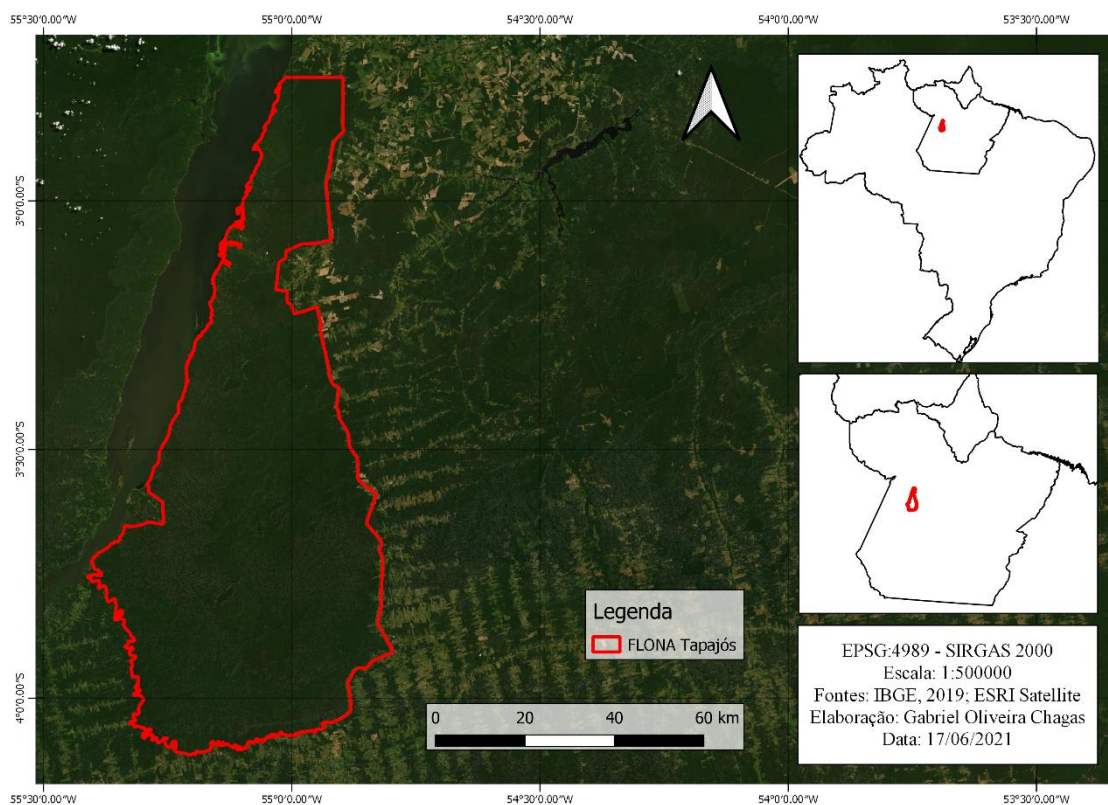
3 MATERIAL E MÉTODOS

Neste capítulo estão expostos os procedimentos metodológicos utilizados para a modelagem da AGB. Apresenta-se e descreve-se, na Seção 3.1, a área de estudo. Na Seção 3.2 estão discriminados os dados que foram utilizados neste trabalho. Apresenta-se, na Seção 3.3, os detalhes dos procedimentos empregados neste trabalho.

3.1 Área de estudo

A área de estudo corresponde à Floresta Nacional do Tapajós e arredores e situa-se nos municípios de Aveiro, Belterra, Placas e Rurópolis, no estado do Pará (Figura 3.1). A Floresta Nacional do Tapajós é uma unidade de conservação (UC) que foi criada por meio do Decreto Federal nº 73.684, de 19 de fevereiro de 1974, com uma área aproximada de 527.319 ha. O órgão gestor da UC é o Instituto Chico Mendes de Conservação da Biodiversidade (ICMBIO, 2019).

Figura 3.1 – Localização da área de estudo.



Fonte: Produção do autor.

O clima do local é classificado como Ami segundo a classificação de Köppen, com uma temperatura média de 25,5 °C e uma pluviosidade média anual de 1500 mm a 2500 mm. A estação seca está concentrada nos meses de julho a novembro, com precipitação mensal inferior a 100 mm (VIEIRA et al., 2004). Argissolo Vermelho Amarelo distrófico, Latossolo Amarelo distrófico e Neossolo Quartzarênico órtico são os tipos de solos predominantes da região, com topografia local variando entre plano e fortemente ondulada (IBGE, 2008).

A vegetação predominante do local é a floresta ombrófila densa, caracterizada pela dominância de indivíduos arbóreos de grande porte e pela presença de lianas lenhosas, palmeiras e epífitas. A vegetação do local também é formada por florestas ombrófilas abertas e, principalmente no entorno da Flona, por florestas secundárias e áreas antropizadas (agricultura e pastagem) (VELOSO; RANGEL-FILHO; LIMA, 1991; GONÇALVES; SANTOS, 2008; CARREIRAS et al., 2014; SAUER, 2018; CASSOL et al., 2019).

3.2 Base de dados

Nesta Seção são apresentados os dados de campo, Subseção 3.2.1, os dados LiDAR, Subseção 3.2.2, as imagens ópticas, Subseção 3.2.3, os dados SAR, Subseção 3.2.4, e os dados auxiliares, Subseção 3.2.5, que foram empregados nos procedimentos deste trabalho.

3.2.1 Dados de campo

Para a obtenção da variável dependente do modelo, isto é, AGB em Mg ha⁻¹, foram selecionadas 55 parcelas de campo no acervo do projeto Paisagens Sustentáveis, sendo 49 parcelas de 0,25 ha e seis de 0,85 ha. No acervo, estão disponibilizadas, para cada indivíduo com DAP ≥ 10 cm, as seguintes informações: data de coleta do dado; DAP; altura total; altura comercial; nome científico, nome popular; família; mortalidade do indivíduo; medidas de raio da copa (norte, sul, leste e oeste); e coordenadas Universal Transversa de Mercator (UTM) (DOS SANTOS; KELLER; MORTON, 2019; EMBRAPA, 2020).

Do total de parcelas selecionadas, 41 parcelas (35 de 0,25 ha e seis de 0,85 ha) estiveram localizadas dentro dos transectos do GEDI, portanto, foram consideradas durante a modelagem da AGB com essa variável. Das 55 parcelas

obtidas dentro dos transectos LiDAR ALS, seis foram medidas em 2011, três em 2014, oito em 2016 e 38 em 2018.

3.2.2 Dados LiDAR

Nesta Subseção são apresentados os dados do GEDI, presente na Subseção 3.2.2.1, do projeto Paisagens Sustentáveis, abordado na Subseção 3.2.2.2, e do projeto Estimativa da biomassa na Amazônia, exposto na Subseção 3.2.2.3.

3.2.2.1 GEDI

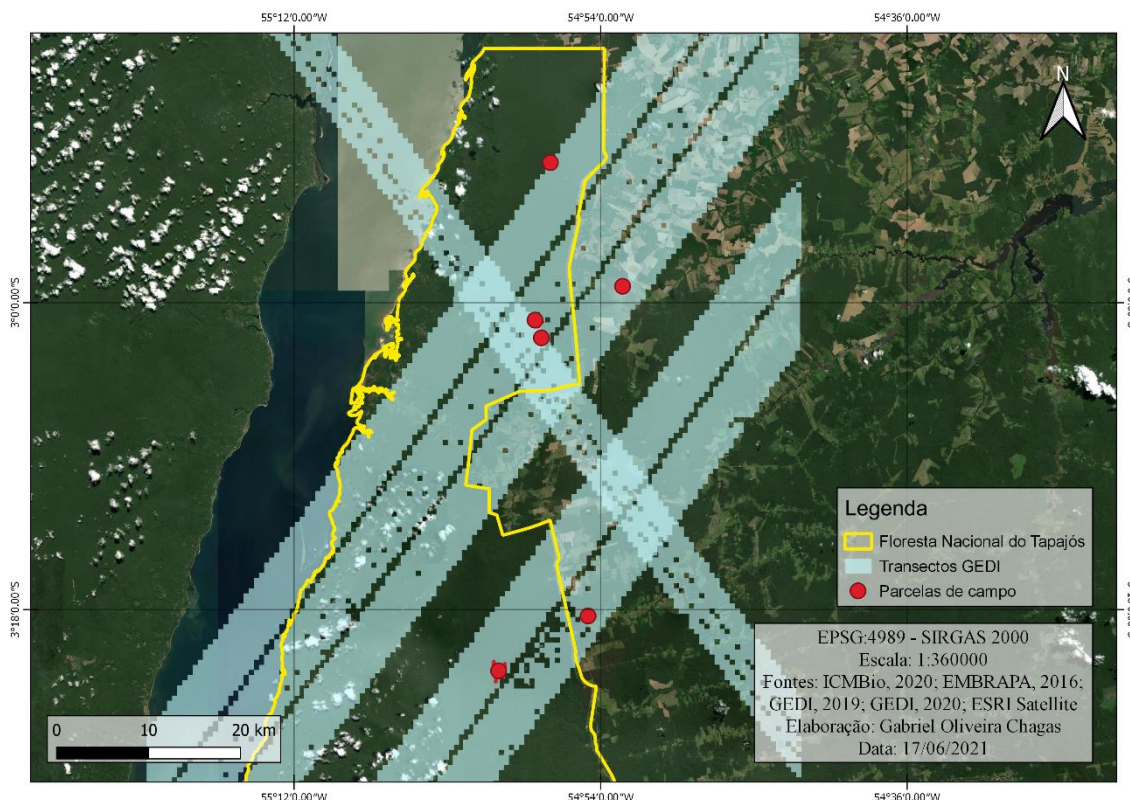
O GEDI é um instrumento de classe geodésica, a bordo da estação espacial internacional, que coleta observações LiDAR *full waveform*. O instrumento é constituído por três lasers que produzem oito trilhas paralelas de observação, sendo que cada laser dispara 242 vezes por segundo, iluminando uma região de 25 m de diâmetro (*footprint*) e obtendo, por conseguinte, a estrutura 3D do local. Cada *footprint* é separado por 60 m ao longo da trilha, com uma distância transversal de aproximadamente 600 m entre cada uma das oito trilhas (GEDI ECOSYSTEM LIDAR, 2018).

Os lasers do GEDI operam no comprimento de onda de 1064 nm e os pulsos têm uma potência de 10 mJ, sendo disparados em um intervalo de 14 ns. O GPS permite localizar a órbita do GEDI em relação à superfície terrestre, enquanto que os componentes *star trackers* fornecem informações sobre a orientação do instrumento (GEDI ECOSYSTEM LIDAR, 2018).

Os dados do GEDI foram disponibilizados gratuitamente pelo *Land Processes Distributed Active Archive Center* (LP DAAC) no dia 21 de janeiro de 2020, sendo eles: os dados da forma da onda geolocalizados (Level 1B *Geolocated Waveform Data* - GEDI01_B); as métricas de altura e elevação (Level 2A *Elevation and Height Metrics Data* - GEDI02_A); e as métricas da cobertura do dossel e do perfil vertical (Level 2B *Canopy Cover and Vertical Profile Metrics Data* - GEDI02_B). Diante disso, o instrumento GEDI tornou-se uma importante ferramenta para caracterizar a biodiversidade e o habitat, bem como nos estudos dos processos de ciclagem do carbono e da água (GEDI ECOSYSTEM LIDAR, 2018).

Durante a aquisição dos dados GEDI, foram verificados todos os transectos com pelo menos uma parcela de campo e sem nuvem na região da parcela. Dessa forma, foram adquiridos seis transectos GEDI com 41 parcelas de campo (Figura 3.2). Os dados foram adquiridos pelo instrumento GEDI nos dias 23/05/2019, 18/06/2019, 13/07/2019, 11/10/2019, 03/11/2019 e 10/06/2020.

Figura 3.2 – Localização dos transectos GEDI e das parcelas de campo na área de estudo.



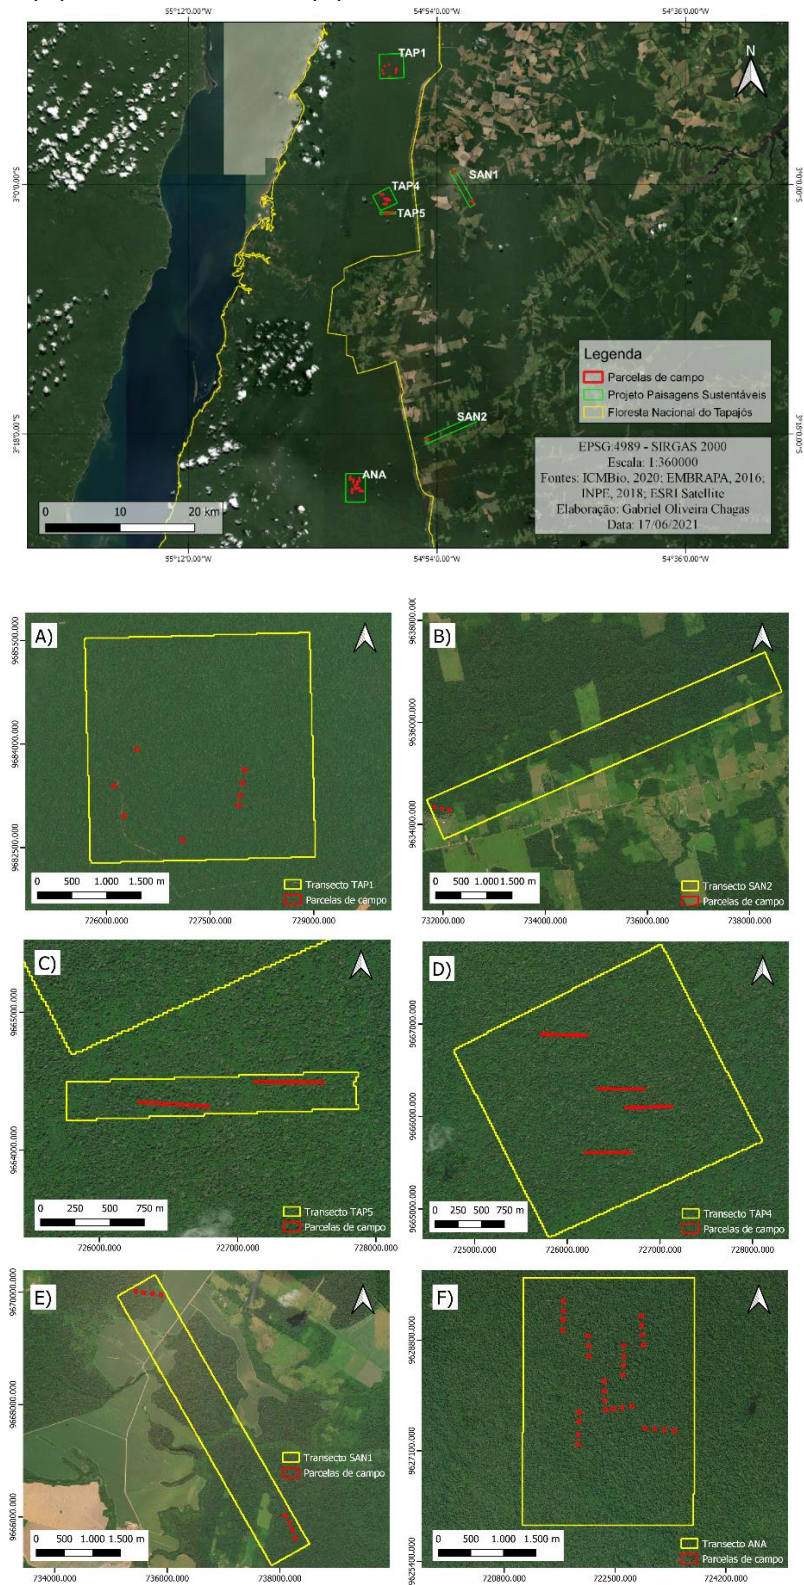
Fonte: Produção do autor.

3.2.2.2 Projeto Paisagens Sustentáveis

O projeto Paisagens Sustentáveis é o resultado da cooperação entre o Serviço Florestal dos Estados Unidos e a Empresa Brasileira de Pesquisa Agropecuária (Embrapa), com o apoio da Agência dos Estados Unidos para o Desenvolvimento Internacional (USAID) e do Departamento de Estado dos Estados Unidos. Os dados de inventário florestal e do LiDAR ALS coletados pelo projeto estão disponíveis gratuitamente no acervo do projeto (DOS-SANTOS; KELLER; MORTON, 2019; EMBRAPA, 2020). A localização das parcelas de campo e dos transectos LiDAR ALS do projeto paisagens sustentáveis, utilizados

neste trabalho, estão exibidas na Figura 3.3. Nas Tabelas A.1, A.2, A.3, A.4, A.5 e A.6 (Anexo A), estão apresentadas as informações detalhadas desses transectos.

Figura 3.3 – Localização dos seis transectos LiDAR ALS do projeto Paisagens Sustentáveis e das parcelas de campo na área de estudo. (A) Transecto TAP1. (B) Transecto SAN2. (C) Transecto TAP5. (D) Transecto TAP4. (E) Transecto SAN1. (F) Transecto ANA.



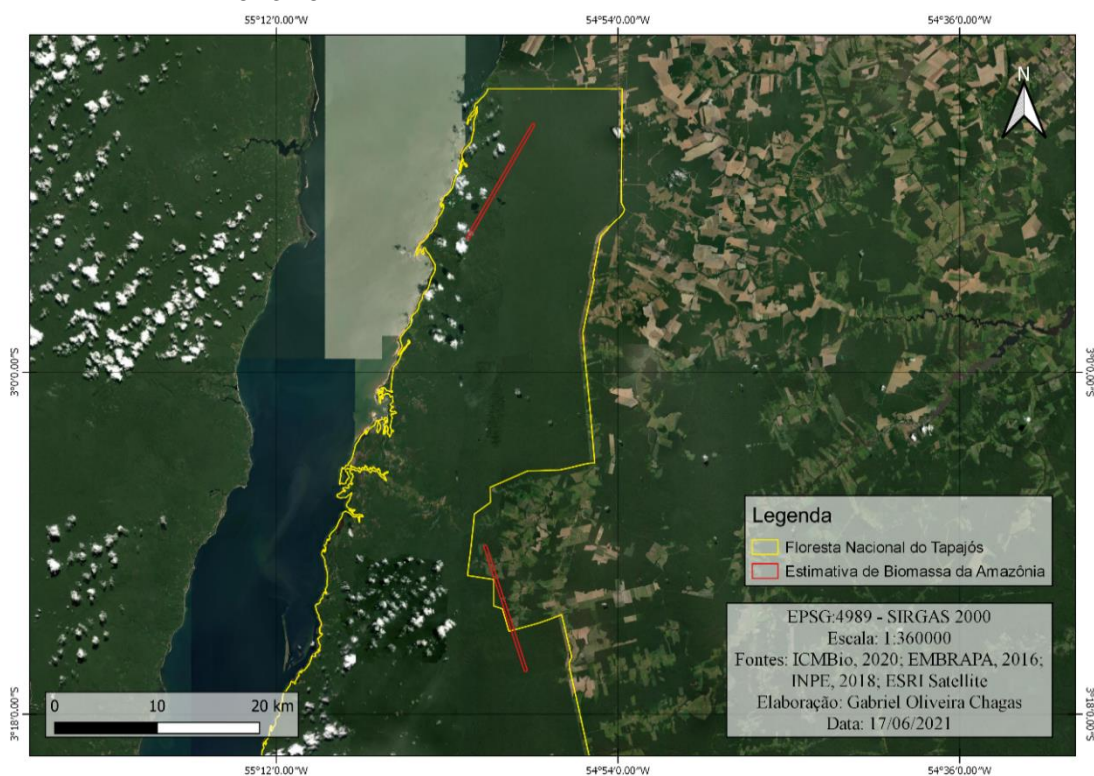
Fonte: Produção do autor.

3.2.2.3 Projeto Estimativa da Biomassa na Amazônia

Neste trabalho, também foram utilizados os transectos LiDAR ALS do projeto Estimativa de Biomassa da Amazônia distribuídos sobre a área de estudo. O projeto, também denominado de Subprojeto 7 (Melhoria dos Métodos de Estimativa de Biomassa e de Modelos de Estimativa de Emissões por Mudança de Uso da Terra), é um dos componentes do projeto Monitoramento Ambiental por Satélite no Bioma Amazônia (MSA), desenvolvido pelo Instituto Nacional de Pesquisas Espaciais (INPE) e pela Fundação de Ciência, Aplicações e Tecnologia (Funcate), com apoio do Fundo Amazônia e recursos do Banco Nacional do Desenvolvimento (BNDES). O objetivo desse projeto é propor aperfeiçoamentos nas estimativas de biomassa e nos modelos de estimativa de emissões derivadas da mudança do uso da terra (INPE, 2018).

Os dados do projeto Estimativa de Biomassa da Amazônia foram coletados em transectos com dimensões de 300 m de largura por 12,5 km de comprimento (INPE, 2018). Na Figura 3.4 é exibida a localização de cada transecto da nuvem de pontos utilizado neste trabalho do projeto Estimativa de Biomassa da Amazônia. As características do sensor e dos voos realizados pelo projeto estão apresentadas na Tabela A.7 (Anexo A).

Figura 3.4 – Localização dos transectos LiDAR do projeto Estimativa de Biomassa da Amazônia.



Fonte: Produção do autor.

3.2.3 Imagens ópticas

A missão Sentinel-2, componente espacial da família Copernicus, compreende dois satélites (Sentinel-2A e Sentinel-2B) de órbita polar, aparelhados com imageador multiespectral (MSI) que visa o monitoramento das mudanças na superfície terrestre. As unidades dessa missão estão a 786 km de altitude, têm um plano orbital sol-síncrona, diferença de fase de 180° entre elas, largura da faixa de imageamento de 290 km e tempo de revisita de cinco dias no equador, considerando-se ambos os satélites (ESA, 2020). Os limites da cobertura dos satélites estão entre as latitudes 56° S e 84° N e o cruzamento dos satélites no equador ocorre às 10h30 do horário local (DRUSCH et al., 2012).

Cada uma das unidades da missão carrega um sensor MSI com 13 bandas espectrais, sendo quatro bandas com resolução espacial de 10 m, seis bandas com 20 m e três bandas com 60 m (Tabela 3.1) (DRUSCH et al., 2012; ESA, 2020). As imagens são disponibilizadas gratuitamente, ortorretificadas e

convertidas em reflectância no topo da atmosfera (produto Level-1C) (ESA, 2020).

Tabela 3.1 – Características das bandas espectrais do sentinel-2.

Nº da Banda	Nome da Banda	Comprimento de Onda Central (nm)	Resolução Espacial (m)
1	<i>Aerossol</i>	443	60
2	<i>Blue</i>	490	10
3	<i>Green</i>	560	10
4	<i>Red</i>	665	10
5	<i>Red Edge 1</i>	705	20
6	<i>Red Edge 2</i>	740	20
7	<i>Red Edge 3</i>	783	20
8	NIR	842	10
8a	<i>Red Edge 4</i>	865	20
9	<i>Water Vapor</i>	940	60
10	Cirrus	1.375	60
11	SWIR 1	1.610	20
12	SWIR 2	2.190	20

Fonte: ESA (2020).

3.2.4 Dados ALOS PALSAR-2

O sensor *Phased Array L-band Synthetic Aperture Radar-2* (PALSAR-2), a bordo do *Advanced Land Observing Satellite-2* (ALOS-2), opera na banda L e, assim, permite o monitoramento e identificação de sumidouros de carbono. O satélite foi lançado em maio de 2014, dando continuidade à missão *Japanese Earth Resource Satellite* (JERS). O ALOS-2 opera a 628 km de altitude e com um tempo de revisita de 14 dias (JAXA, 2014).

O PALSAR-2 possui modos de polarização única (HH ou VV ou HV), dupla (HH + HV ou VV + VH), quádrupla (HH + HV + VV + VH) e polarimetria compacta, isto é, transmitido nas polarizações H e V simultaneamente (Tabela 3.2). Os dados do satélite estão disponíveis em diferentes níveis de processamento: 1.1 (*Single Look Complex*), em que as informações de magnitude e fase encontram-se preservadas; 1.5 (nesse nível foi realizada a conversão de *slant range* para

ground range); 2.1 (nesse nível o dado está ortorretificado); e 3.1 (correções foram aplicadas na qualidade da imagem).

Tabela 3.2 – Características dos modos de imageamento do PALSAR-2.

Modo	Ângulo Incidente	Resolução Espacial (m)	Largura de Faixa (km)	Polarização	
<i>Spotlight</i>	8° - 70°	3 x 1	25 x 25	SP	
<i>Stripmap</i>	<i>Ultrafine</i>	3	50	SP/DP	
	<i>High</i>	6	50	SP/DP/CP	
	<i>sensitive</i>	6	40	FP	
	<i>Fine</i>	10	70	SP/DP/CP	
ScanSAR		10	30	FP	
	Normal	8° - 70°	100 (3 <i>looks</i>)	350	SP/DP
	Wide	8° - 70°	60	490	SP/DP

SP (Single Polarization - Polarização Simples): HH, VV ou HV; DP (Dual Polarization - Polarização Dupla): HH+HV ou VV+HV; FP (Full Polarization - Polarização Quádrupla): HH, HV, VH e VV; CP (Compact polarization): modo experimental.

Fonte: Adaptada de JAXA (2014).

Para este trabalho, foram adquiridas três imagens *Stripmap* no modo de operação quádrupla SM2 (HH, HV, VV e VH) com nível de processamento 1.1. As três imagens foram adquiridas com direção de órbita ascendente e com um espaçamento entre pixel de 3,13 m em alcance e de 2,86 m em azimute. É importante destacar que os dados SM2 com nível de processamento 1.1 são disponibilizados com a correção radiométrica do padrão de elevação da antena e dos efeitos *cross-talk* e *channel imbalance* (LAVALLE; WRIGHT, 2009). As características das imagens utilizadas neste trabalho estão expostas na Tabela 3.3.

Tabela 3.3 – Características das bandas espectrais do sentinel-2.

ID	Data de aquisição	Ângulo de incidência no centro da faixa	N.º de linhas	N.º de colunas
2102617130	17/04/16	33,872°	22608	8112
2104687120	01/05/16	31,088°	23209	7496
2104687130	01/05/16	31,091°	23209	7496


Fonte: Produção do autor.

3.2.5 Dados auxiliares

Os dados da versão 7 do produto *Tropical Rainfall Measuring Mission* (TRMM) 3B42 e os parâmetros meteorológicos do Instituto Nacional de Meteorologia (INMET) foram utilizados para obtenção da precipitação média e acumulada durante os 10 dias anteriores à aquisição das imagens do PALSAR-2. Essa etapa foi necessária para investigar a influência da umidade nos dados SAR, visto que o mesmo alvo pode apresentar respostas radiométricas diferentes em espaço e tempo distintos. Isso ocorre devido à influência da umidade nas propriedades dielétricas dos materiais e no retroespalhamento SAR (RIGNOT et al., 1994; WANG et al., 1994; LIESENBERG; DE SOUZA FILHO; GLOAGUEN, 2016).


É possível observar valores de precipitação média de 7,42 mm a 11,78 mm, entre os dias 08 e 17/04/2016, e um total de 1 mm no dia 17/04/2016 (Figuras 3.5 e B.1). É possível ainda verificar valores de precipitação média de 11,05 mm a 16,27 mm entre os dias 22/04 e 01/05/2016, e um total de 22,6 mm no dia 01/05/2016 (Figuras 3.6 e B.2).

Figura 3.5 – Precipitação média entre os dias 08 e 17/04/2016 da versão 7 do produto TRMM 3B42.



Fonte: Produção do autor.

Figura 3.6 – Precipitação média entre os dias 22/04 e 01/05/2016 da versão 7 do produto TRMM 3B42.



Fonte: Produção do autor.

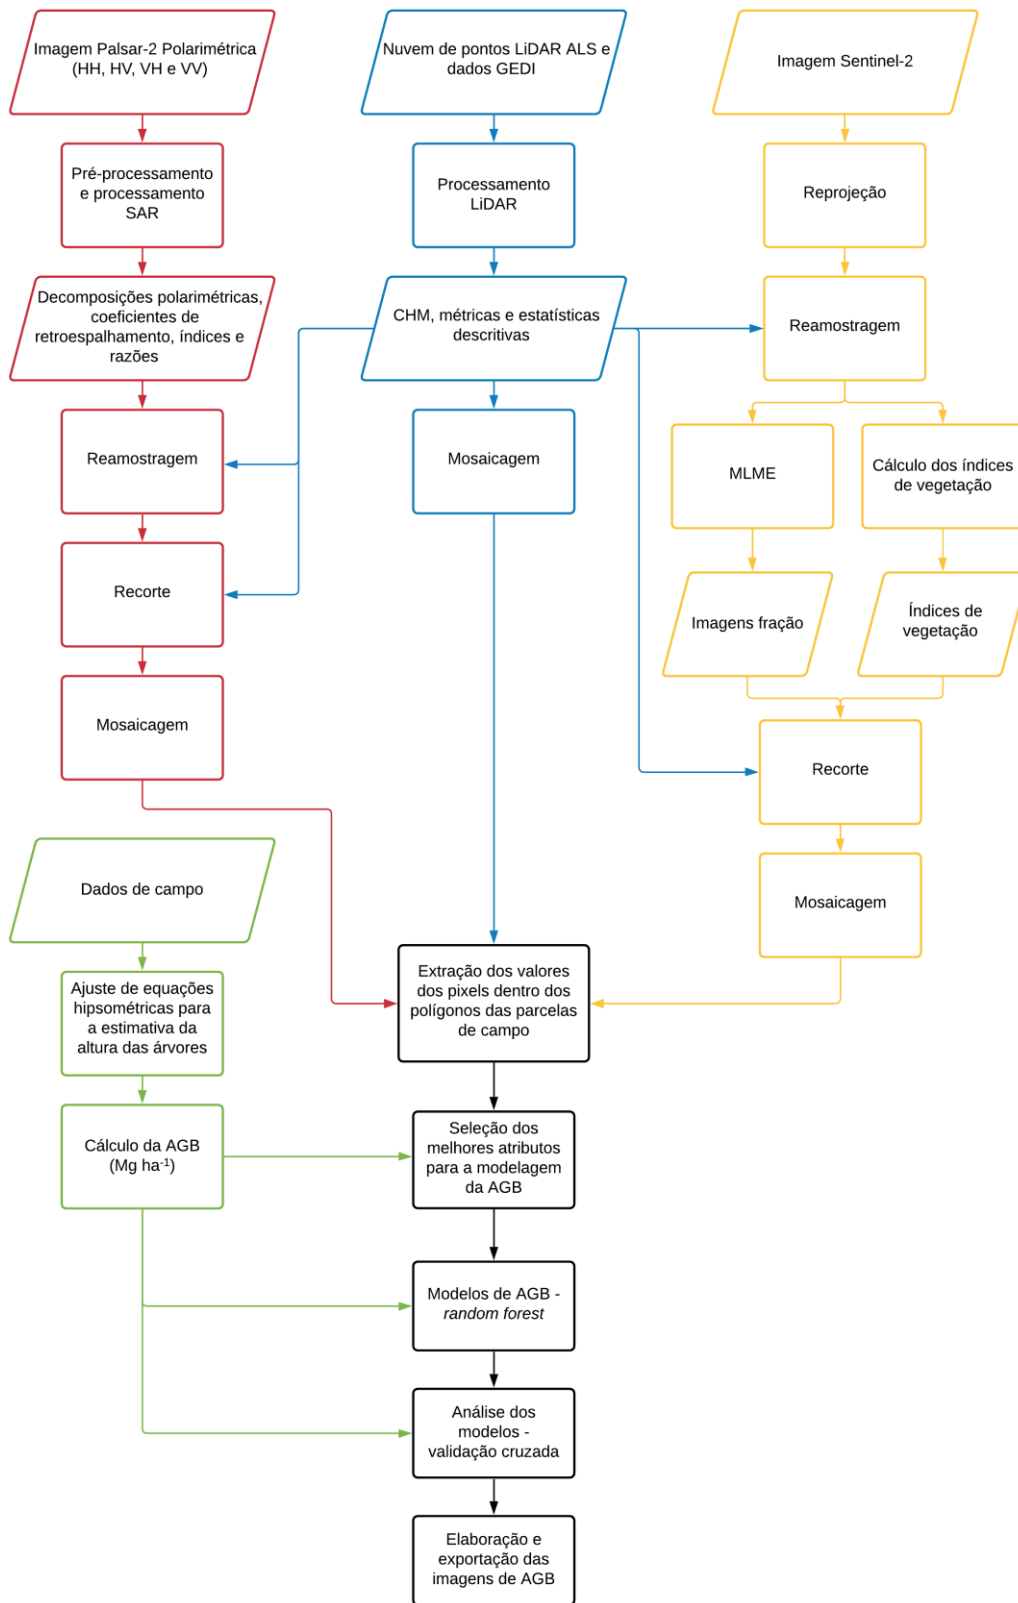
Além disso, considerando-se a dinâmica de uso e cobertura da terra devido ao intervalo de tempo entre os dados de campo, LiDAR, SAR e imagens ópticas e sua influência na variação de AGB ao longo do tempo, foi necessário realizar uma aferição temporal. Para isso, foi preciso obter as séries temporais do índice de vegetação por diferença normalizada (NDVI) e índice de vegetação realçado (EVI) do sensor *Moderate Resolution Imaging Spectroradiometer* (MODIS), disponibilizadas pela plataforma de visualização de dados MODIS da Embrapa Informática Agropecuária denominada de SATVeg e imagens multiespectrais do Landsat-5/TM e Landsat-8/OLI ao longo do período de 2011 e 2020 (EMBRAPA, 2021).

A aferição temporal consistiu na análise das séries temporais e da sobreposição das parcelas de campo e transectos de pontos LiDAR com as imagens ópticas supracitadas. Com base na aferição temporal, foi possível verificar que não houve mudanças significativas na cobertura da terra dentro das parcelas de campo.

3.3 Metodologia

Os procedimentos metodológicos que foram utilizados neste trabalho estão apresentados na Figura 3.7. Na Subseção 3.3.1, estão detalhados os procedimentos realizados para a obtenção da variável dependente e nas Subseções 3.3.2, 3.3.3 e 3.3.4, os procedimentos para a obtenção das variáveis independentes dos modelos. Na Subseção 3.3.5, está descrita a etapa de modelagem da AGB desenvolvida neste trabalho.

Figura 3.7 – Fluxograma geral das etapas metodológicas desse trabalho.



Fonte: Produção do autor.

3.3.1 Cálculo da biomassa florestal acima do solo

A primeira etapa da metodologia para obtenção de AGB em cada parcela de campo consistiu na estimativa da altura das árvores sempre que havia falta dessa informação no acervo de dados de campo. Para isso, as equações hipsométricas foram ajustadas no software R versão 4.0.3 (R CORE TEAM, 2021). A escolha da melhor equação foi baseada na análise do coeficiente de determinação (R^2), do erro padrão residual e do gráfico de resíduos. A Equação 3.1 de Stoffels e Soest (1953) foi a que apresentou os melhores resultados.

$$\ln(H_i) = \beta_0 + \beta_1 \ln(\text{DAP}_i) + \varepsilon_i \quad (3.1)$$

Onde: H_i é a altura total do i -ésimo indivíduo (m); DAP é o diâmetro à altura do peito do i -ésimo indivíduo (cm); β_0 e β_1 são os coeficientes ajustáveis da regressão; ε_i é o erro do i -ésimo indivíduo.

Com as informações de altura e DAP de todos os indivíduos, foi possível calcular a AGB. A Equação 3.2 de Chave et al. (2014) foi utilizada para computar a AGB de cada parcela de campo.

$$\text{AGB} = 0,0673 \cdot (\rho \cdot \text{DAP}^2 \cdot H)^{0,976} \quad (3.2)$$

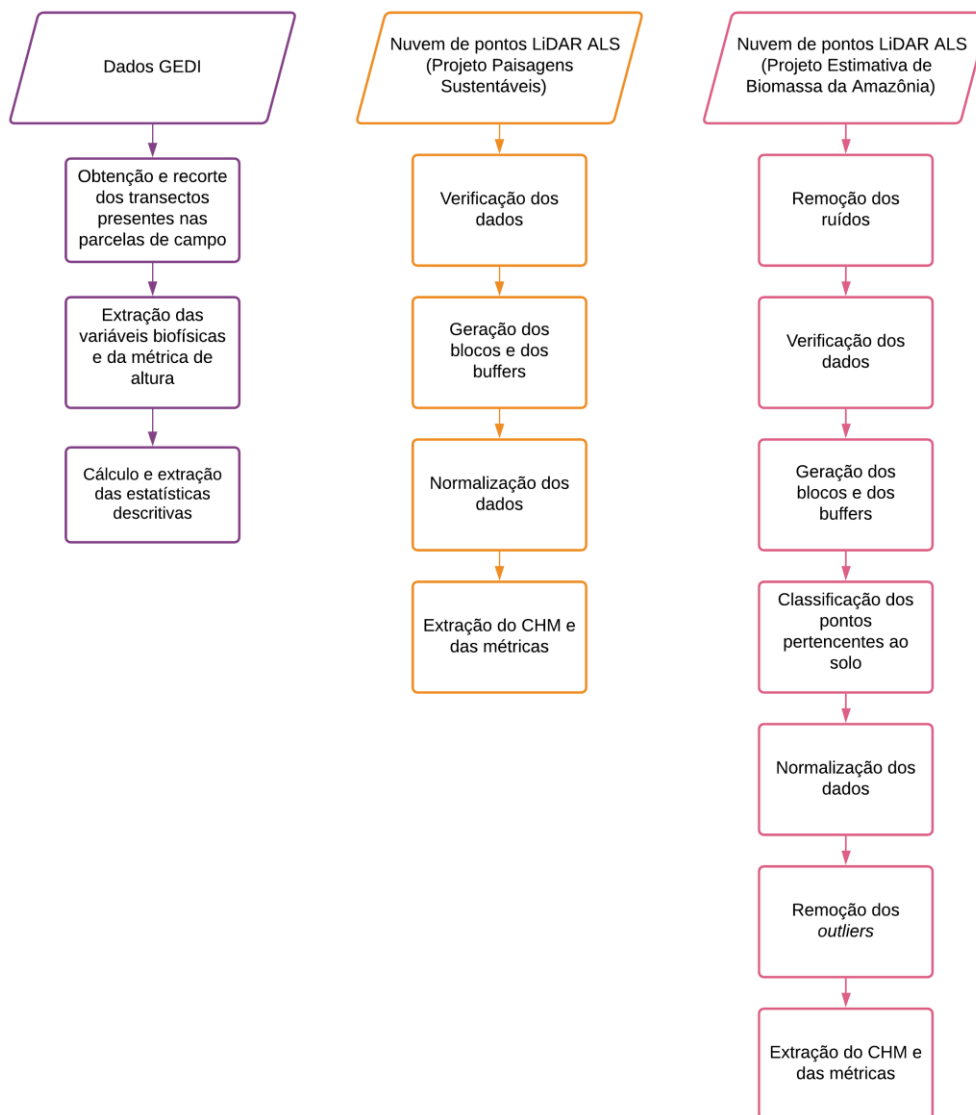
Onde: AGB é a biomassa florestal acima do solo (Kg); DAP é o diâmetro à altura do peito (cm); ρ é a densidade básica da madeira ($\text{g} \cdot \text{cm}^{-3}$); e H é a altura total (m).

Os valores de densidade básica da madeira foram adquiridos no acervo de Zanne et al. (2009). Na pesquisa pela densidade da madeira na base de dados, considerou-se o menor nível taxonômico disponível para o indivíduo na ausência de sua espécie. Por fim, os valores de AGB calculados para cada parcela foram extrapolados para Mg ha^{-1} e utilizados na seleção das melhores variáveis independentes, nas análises estatísticas dos modelos de predição de AGB e nos ajustes finais dos modelos.

3.3.2 Processamento dos dados LiDAR

As etapas metodológicas do processamento dos dados LiDAR estão apresentadas na Figura 3.8. Todas as etapas presentes nesta Subseção foram realizadas no *software* R versão 4.0.3 com o auxílio do pacote *lidR* (ROUSSEL et al., 2020) e *rGEDI* (SILVA et al., 2020).

Figura 3.8 – Fluxograma do processamento dos dados LiDAR adotado.




Fonte: Produção do autor.

Para diminuir o consumo de memória do computador, as etapas de processamento dos dados LiDAR ALS foram realizadas em conjunto com o mecanismo *LAScatalog* do pacote *lidR*, que lê todos os cabeçalhos dos arquivos

do formato LAS de um diretório e retorna os limites e a localização geográfica de cada nuvem de pontos. Além disso, esse mecanismo tem a capacidade de gravar os resultados gerados no armazenamento em disco, ao invés de mantê-los na memória (ROUSSEL et al., 2020). O primeiro estágio do processamento dos dados LiDAR ALS consistiu na remoção dos ruídos da nuvem de pontos do projeto Estimativa da Biomassa na Amazônia, uma vez que esses dados se apresentaram menos apurados.

Para garantir que todos os dados estivessem completos e válidos, aplicou-se a função *las_check()* para inspecionar a consistência dos arquivos no mecanismo *LAScatalog*. Conforme ilustrado na Figura 3.9, para diminuir ainda mais o uso da memória e acelerar o processamento computacional, cada transecto LiDAR ALS foi dividido em blocos de 800 m por 800 m ou 1111,10 m por 1111,10 m com uma adição de *buffer* de 100 m.

Figura 3.9 – Divisão do transecto LiDAR ALS TAP1 em blocos de 800 x 800m com *buffer* de 100m.



Fonte: Produção do autor.

Para distinguir os pontos dos transectos do projeto Estimativa da Biomassa na Amazônia entre solo e não solo, aplicou-se a função *classify_ground*, utilizando-se do algoritmo *Cloth Simulation Function* (CSF). Essa etapa foi importante para

a criação de um modelo contínuo de elevação do terreno. Dessa forma, foi possível realizar a normalização baseada na nuvem de pontos por meio da função *normalize_height*, com a abordagem do k vizinho mais próximo com a ponderação do inverso da distância (KNNIDW). Essa função é superior em termos de precisão computacional em comparação com o método baseado em *raster*, entretanto, essa função exige maior processamento computacional, uma vez que arquivos *raster* podem ser armazenados em disco e não precisam ser recalculados para cada nuvem de pontos (ROUSSEL et al., 2020).

Para eliminar os *outliers* dos dados do projeto Estimativa da Biomassa na Amazônia, um filtro foi aplicado para remover os pontos acima de 65 m e abaixo de 2 m, com o intuito de desconsiderar arbustos e outras vegetações herbáceas. Enfim, obteve-se o CHM e os parâmetros estatísticos apresentados na Tabela 3.4, que descrevem a nuvem de pontos (métricas LiDAR ALS), com as resoluções espaciais de 16,62 x 16,62m, 50 x 50m e 555,55 x 555,55m. As imagens foram exportadas em formato *Tagged Image File Format* (TIFF).

Tabela 3.4 – Métricas extraídas das nuvens de pontos LiDAR ALS.

Métrica	Descrição
n	Número de pontos
area	Área real aproximada do <i>raster</i>
angle	Ângulo de varredura absoluto médio
zmax	Altura máxima
zmean	Altura média
zsd	Desvio padrão da distribuição da altura
zskew	Assimetria da distribuição da altura
zkurt	Curtose da distribuição da altura
zentropy	Entropia da distribuição da altura
pzabovemean	Porcentagem de retornos acima da altura média
pzabovex	Porcentagem de retornos acima de x

continua

Tabela 3.4 – Conclusão.

Métrica	Descrição
zqx	X-ésimo percentil (quantil) de distribuição da altura
zpcumx	Porcentagem cumulativa de retornos na camada i-ésima de acordo com Wood e Treitz (2008)
itot	Soma das intensidades para cada retorno
imax	Intensidade máxima
imean	Intensidade média
isd	Desvio padrão da intensidade
iskew	Assimetria da distribuição da intensidade
ikurt	Curtose da distribuição da intensidade
ipground	Porcentagem da intensidade retornada pelos pontos classificados como solo
ipcumzqx	Porcentagem da intensidade retornada abaixo do k-ésimo percentil de altura
ip1st	Porcentagem da intensidade regressada pelos primeiros retornos
ip2nd	Porcentagem da intensidade regressada pelos segundos retornos
ip3rd	Porcentagem da intensidade regressada pelos terceiros retornos
ipxth	Porcentagem da intensidade regressada pelos x-ésimos retornos
pxth	Porcentagem de x-ésimos retornos
pground	Porcentagem de retornos classificados como solo

Fonte: Adaptada de Roussel et al. (2020).

Por meio do pacote rGEDI, foi possível extrair as seguintes variáveis biofísicas da vegetação: cobertura total do dossel (*cover*), *foliage height diversity index* normalizado (*fhd_normal*), índice de área total da planta (PAI), probabilidade de lacuna (*pgap_theta*) e métrica de altura acima do solo do primeiro sinal recebido (*rh100*) dos dados GEDI. Posteriormente, as estatísticas descritivas (média, desvio-padrão e valores máximo e mínimo observados) da métrica e das

variáveis supramencionadas foram calculadas com uma resolução espacial de 555,55 m. As imagens foram exportadas em formato TIFF.

3.3.3 Processamento das imagens ópticas

O processamento das imagens do Sentinel-2 foi iniciado com a reprojeção e reamostragem dos *pixels* para 16,62 m, 50 m e 555,55 m pelo método do vizinho mais próximo, usando-se, como referência, cada transecto LiDAR isoladamente. As etapas subsequentes foram compostas pelo cálculo dos índices de vegetação nos softwares R versão 4.0.3 e no *Sentinel Application Platform* (SNAP) versão 8.0 e pela extração das imagens-fração derivadas do MLME no software ENVI versão 5.1.

O índice de vegetação é um método de avaliação da cobertura vegetal, discriminação de culturas e detecção de mudança no uso da terra. Devido ao comportamento espectral da vegetação ser única em relação aos outros componentes da superfície, como a absorção da radiação eletromagnética na faixa espectral do vermelho (630 nm - 690 nm) pela clorofila e alta reflexão da radiação no infravermelho próximo (760 nm - 900 nm) pelas estruturas celulares da folha, o cálculo dos índices de vegetação é feito a partir da combinação de duas ou mais bandas do espectro eletromagnético (BANNARI et al., 1995; FORMAGGIO; SANCHES, 2017). Os índices de vegetação calculados neste trabalho estão apresentados na Tabela 3.5.

Tabela 3.5 – Índices de vegetação que foram obtidos neste estudo.

Índice de Vegetação	Bandas dos Sentinel-2 Utilizadas	Referências
ARVI	$\frac{NIR - (2Red - Blue)}{NIR + (2Red - Blue)}$	Kaufman e Tanre (1992)
Cl ₇₀₅ , Cl ₇₄₀ e Cl ₇₈₃	$\frac{NIR}{Red\ Edge} - 1$	Gitelson, Gritz e Merzlyak (2003)
DVI	$NIR - Red$	Clevers (1988)
EVI	$2,5 \frac{(NIR - Red)}{(NIR + 6Red - 7,5Blue + 1)}$	Huete et al. (1997)

continua

Tabela 3.5 – Continuação.

Índice de Vegetação	Bandas dos Sentinel-2 Utilizadas	Referências
GEMI	$\frac{n(1 - 0,25n) - Red - 0,125}{1 - Red}$ onde $n = \frac{2(NIR^2 - Red^2) + 1,5NIR}{1 - Red}$	Pinty e Verstraete (1992)
GNDVI	$\frac{NIR - Green}{NIR + Green}$	Gitelson e Kaufman (1998)
GRVI	$\frac{NIR}{Green}$	Tucker (1979)
IPVI	$\frac{NIR}{NIR + Red}$	Crippen (1990)
IRECI	$\frac{Red\ Edge\ 3 - Red}{\frac{Red\ Edge\ 1}{Red\ Edge\ 2}}$	Frampton et al. (2013)
MCARI	$[(Red\ Edge\ 1 - Red) - 0,2(Red\ Edge\ 1 - Green)] \frac{Red\ Edge\ 1}{Red}$	Daughtry et al.(2000)
MSAVI	$\frac{2NIR + 1 - \sqrt{(2NIR + 1)^2 - 8(NIR - Red)}}{2}$	Qi et al. (1994)
MTCI	$\frac{NIR - Red\ Edge\ 1}{Red\ Edge\ 1 - Red}$	Dash e Curran (2004)
MTVI2	$\frac{1,5[1,2(NIR - Green) - 2,5(Red - Green)]}{\sqrt{(2NIR + 1)^2 - (6NIR - 5\sqrt{Red})} - 0,5}$	Liu, Pattey e Jégo (2012)
NDI45	$\frac{Red\ Edge\ 1 - Red}{Red\ Edge\ 1 + Red}$	Delegido et al. (2011)
NDII	$\frac{NIR - SWIR\ 1}{NIR + SWIR\ 1}$	Hardisky, Klemas e Smart (1983)
NDVI	$\frac{NIR - Red}{NIR + Red}$	Rouse et al. (1973)
NDVI RE	$\frac{NIR - Red\ Edge}{NIR + Red\ Edge}$	Gitelson e Merzlyak (1994)
NDWI	$\frac{NIR - SWIR}{NIR + SWIR}$	Gao (1996)
PSRI	$\frac{Red - Blue}{Red\ Edge\ 2}$	Merzlyak et al. (1999)
PSSRa	$\frac{Red\ Edge\ 3}{Red}$	Blackburn (1998)
PVI	$\sqrt{(0,355NIR - 0,149Red)^2 + (0,355Red - 0,852NIR)^2}$	Richardson e Wiegand (1977)
REIP	$700 + 40 \frac{\left(\frac{Red + Red\ Edge\ 3}{2}\right) - Red\ Edge\ 1}{Red\ Edge\ 2 - Red\ Edge\ 1}$	Guyot e Baret (1988)

continua

Tabela 3.5 – Conclusão.

Índice de Vegetação	Bandas dos Sentinel-2 Utilizadas	Referências
RVI_optico	$\frac{NIR}{Red}$	Birth e McVey (1968)
S2REP	$705 + 35 \left[\frac{(Red\ Edge\ 3 + Red) - Red}{(Red\ Edge\ 2 - Red\ Edge\ 1)} \right]$	Frampton et al. (2013)
SAVI	$\frac{NIR - Red}{NIR + Red + 0,5} (1,5)$	Huete (1988)
TNDVI	$\sqrt{\frac{NIR - Red}{NIR + Red} + 0,5}$	Deering (1975)
TSAVI	$\frac{a^1(NIR - aRed - b^1)}{Red + a(NIR - b) + X(1 + a^2)}$	Baret e Guyot (1991)
WDVI	$NIR - aRed$	Clevers (1989)

¹ a e b é a inclinação e o ponto de interseção da linha do solo, respectivamente.

Fonte: Produção do autor.

De acordo com Shimabukuro e Ponzoni (2018), a fração solo gerada pelo MLME auxilia na identificação de áreas com exploração seletiva. Segundo Shimabukuro e Smith (1991), o MLME se baseia na relação linear para representar a resposta espectral dos elementos presentes no *pixel*. Dessa forma, para cada *pixel* da imagem, o MLME pode ser apresentado como na Equação 3.3.

$$r_i = \sum_{j=1}^n (a_{ij}x_j) + e_i \quad (3.3)$$

Onde: r_i é a reflectância espectral para a *i*-ésima banda espectral de um *pixel* que abrange um ou mais elementos; a_{ij} é a reflectância espectral do *j*-ésimo elemento do *pixel* para a *i*-ésima banda espectral; x_j é valor proporcional do *j*-ésimo elemento do *pixel*; e_i é erro para a *i*-ésima banda espectral; *j* é o número de elementos; e *i* é o número de bandas espectrais.

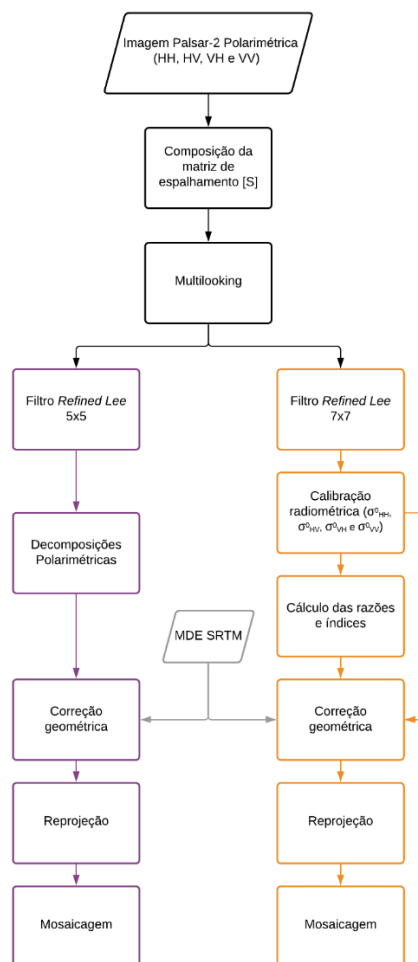
Desse modo, os *endmembers* de cada alvo foram coletados em cada uma das imagens ópticas para aplicação do MLME e, assim, obter as quatro imagens-

frações correspondentes à vegetação verde, solo, sombra e erro derivados do MLME (erromlme). Posteriormente, as imagens-fração e os índices de vegetação foram recortados utilizando-se, como referência, os transectos das métricas LiDAR ALS. Por fim, foi realizado o mosaico de cada fragmento de uma mesma variável para formar arquivos únicos.

3.3.4 Pré-processamento das imagens ALOS PALSAR-2

As etapas metodológicas do pré-processamento das imagens ALOS PALSAR-2 estão apresentadas na Figura 3.10. Todas as etapas presentes nesta Subseção foram feitas nos softwares SNAP (*Sentinel Application Platform*) versão 8.0 e R versão 4.0.3.

Figura 3.10 – Fluxograma do pré-processamento das imagens ALOS PALSAR-2 utilizadas neste trabalho.



Fonte: Produção do autor.

A primeira etapa do pré-processamento foi a obtenção dos elementos complexos, os quais são representados pela matriz de espalhamento [S]. Com o propósito de diminuir o ruído *speckle* e de tornar as dimensões dos *pixels* regulares, foi utilizada a filtragem *multilooking* com uma janela de 3 *pixels* por 3 *pixels*.

A etapa seguinte do pré-processamento foi dividida em duas partes, uma para a obtenção das decomposições polarimétricas e outra para a obtenção dos coeficientes de retroespalhamento, índices e razões. Também com o objetivo de reduzir o ruído *speckle*, foi aplicado o filtro *Refined Lee* com uma janela de tamanho 5 *pixels* por 5 *pixels* nas matrizes de covariância e coerência para executar a decomposição polarimétrica. Para gerar os coeficientes de retroespalhamento, índices e razões foi aplicado o mesmo filtro com uma janela de 7 *pixels* por 7 *pixels*.

Os coeficientes de retroespalhamento (σ_{HH}^0 , σ_{HV}^0 , σ_{VH}^0 e σ_{VV}^0) foram obtidos pela função de calibração radiométrica. A calibração radiométrica possibilita a transformação dos números digitais da imagem em valores de retroespalhamento por unidade de área no alcance do terreno (σ^0). Além disso, com base nesses coeficientes, foram obtidos os seguintes produtos: razão de polarização cruzada HH e VV; razão de polarização paralela; *Radar Forest Degradation Index* (RFDI); *Biomass Index* (BMI); *Canopy Structure Index* (CSI); *Total power* (Pt); *Radar Vegetation Index* (RVI); e *Vegetation Scattering Index* (VSI) (Tabela 3.6).

Tabela 3.6 – Coeficientes de retroespalhamento, razões, índices e decomposições polarimétricas utilizados neste trabalho.

Atributo extraído	Sigla	Fonte
Coeficiente de retroespalhamento HH	sigma0 hh	Woodhouse (2006)
Coeficiente de retroespalhamento HV	sigma0 hv	
Coeficiente de retroespalhamento VH	sigma0 vh	
Coeficiente de retroespalhamento VV	sigma0 vv	
<i>Total power</i> ($\sigma_{HH}^0 + \sigma_{HV}^0 + \sigma_{VH}^0 + \sigma_{VV}^0$)	pt	

continua

Tabela 3.6 – Continuação.

Atributo extraído		Sigla	Fonte
	Razão de polarização cruzada	Cross pol ratio	Henderson e Lewis (1998)
	Razão de polarização paralela	Parallel pol ratio	
	<i>Vegetation Scattering Index</i>	vsi	Pope, Rey-Benayas e Paris (1994)
	<i>Biomass Index</i>	bmi	
	<i>Canopy Structure Index</i>	csi	
	<i>Radar Vegetation Index</i>	rvi	Kim e Van Zyl (2009)
	<i>Radar Forest Degradation Index</i>	rfdi	Mitchard et al. (2011)
Cloude-Pottier	Ângulo alfa (α)	alpha	Cloude e Pottier (1996)
	Entropia (H)	entropy	
	Anisotropia (A)	anisotropy	
Cloude	Espalhamento volumétrico	cloude vol	Cloude (1985) e Cloude e Pottier (1996)
	Reflexão de canto	cloude dbl	
	Espalhamento superficial	cloude surf	
Freeman-Durden	Espalhamento volumétrico	freeman vol	Freeman e Durden (1998)
	Reflexão de canto	freeman dbl	
	Espalhamento superficial	freeman surf	
<i>Generalized Freeman-Durden</i>	Espalhamento volumétrico	generalized freeman_vol	Freeman (2007)
	Reflexão de canto	generalized freeman dbl	
	Espalhamento superficial	generalized freeman surf	
Van Zyl	Espalhamento volumétrico	vanzyl vol	van Zyl, Arie e Kim (2011)
	Reflexão de canto	vanzyl dbl	
	Espalhamento superficial	vanzyl surf	

continua

Tabela 3.6 – Conclusão.

Atributo extraído	Sigla	Fonte	
Yamaguchi	Espalhamento volumétrico	yamaguchi vol	Yamaguchi et al.(2005)
	Reflexão de canto	yamaguchi dbl	
	Espalhamento superficial	yamaguchi surf	
	Espalhamento em forma de hélice	yamaguchi hlx	
Pauli	Espalhamento de polarização ortogonal	pauli g	Cloude e Pottier (1996)
	<i>Single-bounce ou odd-bounce</i>	pauli r	
	Reflexão de canto ou <i>even-bounce</i>	pauli b	
Sinclair	$ (S_{hv} + S_{vh})/2 ^2$	sinclair g	Krogager, Boerner e Madsen (1997)
	$ S_{vw} ^2$	sinclair r	
	$ S_{hh} ^2$	sinclair b	
Touzi	Ângulo de orientação (Ψ)	psi	Touzi (2007)
	Helicidade (τ)	tau	
	Magnitude do tipo de espalhamento simétrico (α)	alpha touzi	
	Fase do tipo de espalhamento simétrico (Φ)	phi	

Fonte: Produção do autor.

As decomposições polarimétricas de Cloude, Cloude-Pottier, Freeman-Durden, *generalized* Freeman-Durden, Pauli, Sinclair, Touzi, van Zyl e Yamaguchi foram extraídas das matrizes de covariância e coerência filtradas. Tanto para coeficientes de retroespalhamento, razões e índices, quanto para as decomposições polarimétricas, foi feita a correção geométrica por meio da operação *Range Doppler Terrain Correction*, utilizando-se do modelo digital de elevação obtido pela *Shuttle Radar Topography Mission* (SRTM) com uma

resolução de 30m. Essa operação resultou em imagens com 16,62m de resolução espacial.

Posteriormente, realizou-se o mosaico das imagens e executou-se a reprojeção para o mesmo sistema de coordenadas das métricas LiDAR ALS. Foi realizada, ainda, a reamostragem e o recorte das imagens utilizando-se como referência as métricas e estatísticas descritivas LiDAR ALS de cada transecto isoladamente. Por fim, realizou-se a união de cada fragmento de uma mesma imagem para formar arquivos únicos.

3.3.5 Desenvolvimento dos modelos de AGB e seleção das variáveis

A primeira etapa consistiu na extração dos valores dos *pixels* das variáveis independentes do modelo inseridos nos polígonos das parcelas de campo. Para garantir que o máximo possível de *pixels* presentes nos polígonos fosse selecionado na modelagem, distribuiu-se aleatoriamente 1.000 pontos para cada uma das parcelas de campo. Com base na coordenada geográfica de cada ponto, foi feita a extração e a exportação dos valores de cada *pixel*, com pelo menos um ponto inserido, para uma tabela.

Esse processo foi realizado para todas as variáveis independentes do modelo. Para evitar que valores iguais de uma mesma variável estivessem associados ao mesmo polígono durante a modelagem, manteve-se um dos valores e removeu-se o restante. Com isso, foram coletadas 400, 294 e 49 amostras para o ajuste com variáveis de 16,62 m, 50 m e 555,55 m, respectivamente. Ademais, foram obtidas 65 amostras para verificar o desempenho da modelagem com os dados LiDAR ALS, SAR e imagens ópticas com 555,55 m de resolução espacial para verificar o desempenho do modelo utilizando todas as 55 parcelas disponíveis.

A etapa seguinte consistiu na modelagem da relação entre as variáveis preditivas e a AGB através do algoritmo *Random Forest* (RF). Para isso, foi empregado o pacote *randomForest* no *software* R versão 4.0.3. Esse algoritmo foi escolhido devido às suas estimativas de AGB serem mais precisas em comparação com as outras técnicas (KARLSON et al., 2015; LI et al., 2018; SILVEIRA et al., 2019).

O RF é uma técnica de modelagem que utiliza um grande conjunto de árvores de decisão (500, por exemplo) para realizar uma previsão (BREIMAN, 2001). Cada árvore é construída independentemente com uma amostragem aleatória dos dados de treinamento. Em cada nó das árvores, um subconjunto das variáveis preditoras é usado para identificar a divisão mais eficiente (BREIMAN, 2001; KARLSON et al., 2015).

Os parâmetros que devem ser definidos para construir a árvore de decisão são o Ntree (número de árvores a serem geradas) e o Mtry (número de variáveis a serem testadas). O resultado é um conjunto de árvores de regressão de baixo viés e alta variância, em que as previsões finais são derivadas da média das previsões das árvores individuais (BREIMAN, 2001; KARLSON et al., 2015). Os melhores valores de Mtry para as resoluções espaciais de 16,62 m, 50 m e 555,55 m, com base no menor valor da RMSE observado, foram 33, 15 e 4, respectivamente. O melhor valor observado para Ntree foi 500 para todos os ajustes.

Com o intuito de melhorar a interpretabilidade e o desempenho do modelo e acelerar o processo de aprendizagem, foi aplicado o algoritmo de filtragem Boruta para a seleção das variáveis de maior relevância na modelagem. O algoritmo amplia o sistema de informação por meio da adição de cópias das variáveis, realiza a permutação de seus recursos para remover suas correlações com a variável resposta e obtém os atributos sombra (*shadow attributes*). Com a execução de um classificador RF e com o sistema de informações estendido, o algoritmo calcula e coleta as pontuações Z de cada variável (KURSA; RUDNICKI, 2010).

As variáveis com uma pontuação Z significativamente superior que o maior valor Z encontrado entre os atributos sombra (MZSA) são classificadas como “importantes”. Aquelas com uma importância significativamente menor que o MZSA são classificadas como “sem importância” e removidas do sistema de informação. Para os atributos com importância indeterminada, o algoritmo executa um teste bilateral com o MZSA para determinar se esses atributos devem ou não permanecer no sistema de informação. Por fim, os atributos

sombra são removidos do sistema de informação e o processo é repetido até que a importância seja atribuída a todas variáveis ou até que o limite pré-definido de execuções do RF seja atingido (KURSA; RUDNICKI, 2010).

Para realizar a análise do desempenho de cada modelo gerado, foi utilizada uma abordagem do tipo validação, a qual consiste na divisão dos dados de treinamento em duas partes, no conjunto de treinamento e no conjunto de validação. Nesse tipo de abordagem, a modelagem é feita pelo novo conjunto de treinamento e a análise do desempenho do modelo é feita pelo conjunto de validação. O método de validação empregado neste trabalho foi a validação cruzada por *k-fold*.

Esse método consiste em dividir aleatoriamente os dados de treinamento do modelo em *k* grupos (*folds*) de tamanhos aproximadamente iguais. Conforme ilustrado na Figura 3.11, o treinamento do modelo é feito com *k* grupos menos um e a validação é feita com o grupo remanescente (grupo de teste). Esse processo é repetido *k* vezes. A cada ocasião um novo grupo é tratado como o conjunto de validação e o restante como o conjunto de treinamento. Com base na média das *k* estimativas do erro de generalização produzidas por essa abordagem, é possível obter uma aproximação do erro esperado quando o modelo for utilizado em dados não aplicados no ajuste (BOEHMKE; GREENWELL, 2019). No presente trabalho, o *k* foi definido como 10 e o processo da validação foi repetido 10 vezes.

Figura 3.11 – Ilustração do processo de validação cruzada por *k-fold*.



Fonte: Adaptada de Boehmke e Greenwell (2019).

Para a avaliação e comparação dos modelos em cada uma das repetições da validação cruzada, foi calculado o R^2 , que relata a capacidade do modelo em explicar a variabilidade, a RMSE, a qual mede a diferença média entre os valores preditos pelo modelo e as observações, e o erro médio absoluto (MAE), que calcula a diferença absoluta média entre os valores observados e previstos. É importante salientar que os resultados do cálculo do MAE enfatizam menos os grandes erros em comparação com a RMSE.

Além dessas métricas estatísticas, a avaliação dos modelos foi feita por meio da análise visual dos gráficos de dispersão entre os valores de AGB observados e os valores preditos pelos modelos. Assim, através do modelo ótimo, foi realizado o mapeamento da AGB nas localidades com a disponibilidade das variáveis independentes e as imagens foram exportadas em formato TIFF. Vale enfatizar que todos os processos realizados nesta Subseção foram feitos no *software* R versão 4.0.3.

4 RESULTADOS E DISCUSSÃO

Neste capítulo são apresentados os resultados e a discussão deste trabalho. Apresenta-se, na Seção 4.1, a seleção das variáveis de maior importância para as modelagens, com diferentes fontes de dados e resoluções espaciais. Na Seção 4.2 são mostrados os desempenhos dos modelos, após a seleção das variáveis, com diferentes fontes de dados e resoluções espaciais. Na Seção 4.3, estão dispostos os mapeamentos de AGB feitos pelos modelos obtidos neste trabalho em diversas áreas da região de estudo.

4.1 Seleção das variáveis para estimar a AGB


4.1.1 Seleção das variáveis de 16,62m e 50m de resolução espacial

As variáveis de 16,62m e 50m de resolução espacial com maior valor de importância para os ajustes estão exibidas nas Figuras 4.1 e 4.2. As componentes de espalhamento volumétrico das decomposições polarimétricas de Freeman-Durden, *generalized* Freeman-Durden, Yamaguchi e van Zyl foram as variáveis SAR com maior importância na modelagem da AGB.

A seleção dessas componentes na modelagem da AGB pode estar relacionada com a capacidade delas em discriminar floresta primária e secundária de outros tipos de uso e cobertura da terra, visto que a quantidade de AGB é maior nessas tipologias florestais. Vários estudos avaliaram a capacidade dessas componentes em identificar regiões de floresta primária e secundária (KUPLICH et al., 2009; NARVAES; DOS SANTOS; DA SILVA, 2010; WIEDERKEHR et al., 2019).


Além dessas variáveis, as componentes reflexão de canto de Freeman-Durden e *generalized* Freeman-Durden e a componente de espalhamento superficial de Freeman-Durden também estão entre as melhores variáveis SAR de 16,62 m de resolução para o ajuste do modelo de AGB. Outros autores também observaram a correlação dessas constituintes SAR com a AGB (GONÇALVES; SANTOS; TREUHAFT, 2011; BISPO et al., 2014; CASSOL et al., 2019).

Figura 4.1 – Relevância das variáveis LiDAR ALS, SAR e ópticas com 16,62 m de resolução espacial para estimar a AGB de acordo com o algoritmo Boruta.



Fonte: Produção do autor.

Figura 4.2 – Relevância das variáveis LiDAR ALS, SAR e ópticas com 50 m de resolução espacial para estimar a AGB de acordo com o algoritmo Boruta.



Fonte: Produção do autor.

As métricas LiDAR ALS de intensidade (isd, imean, itot, iskew e ikurt) também constituíram o grupo de variáveis com maior importância para estimar a AGB (Figuras 4.1 e 4.2). As métricas de porcentagem de retorno (p2th e p1th), de altura (zmax e zmean) e de percentil de distribuição da altura (zq35 – zq95) também foram classificadas como importantes. Outros estudos observaram a correlação dessas variáveis LiDAR com a AGB e com as medidas dendrométricas das árvores (ALMEIDA et al., 2019; CORTE et al., 2020; MARTINS-NETO et al., 2021).


Dentre as variáveis derivadas das imagens ópticas, o NDWI, o NDII, as imagens-fração solo e erro do MLME foram selecionados de acordo com o valor de importância para estimar a AGB. A seleção delas pelo algoritmo Boruta pode estar atrelada à capacidade do MLME em detectar a variação na vegetação oriunda da degradação florestal (ARAI et al., 2019; SHIMABUKURO et al., 2019a, 2019b, 2020).

4.1.2 Seleção das variáveis de 555,55 m de resolução espacial

O resultado da seleção das melhores variáveis para estimar a AGB com dados GEDI, LiDAR ALS, SAR e imagens ópticas está disposto na Figura 4.3. As componentes provenientes dos dados GEDI rh100 (média), fhd normal (média e valores máximos), cover (média e valores mínimos), pgap theta (média e valores máximos) e PAI (valores mínimos) foram selecionadas pelo algoritmo Boruta.

A seleção dessas variáveis pode estar relacionada com a capacidade delas em considerar a estrutura florestal e detectar a degradação florestal dentro do pixel. O índice PAI, por exemplo, considera em seu cálculo todos os elementos da estrutura do dossel, como troncos, galhos e folhas. A obtenção de seus valores mínimos possibilita a observação da estrutura florestal e, por consequência, a detecção da escala dos valores de AGB (TANG et al., 2012; ALMEIDA et al., 2016; DA SILVA et al., 2020).

Figura 4.3 – Relevância das variáveis GEDI, LiDAR ALS, SAR e ópticas com 555,55 m de resolução espacial para estimar a AGB de acordo com o algoritmo Boruta.



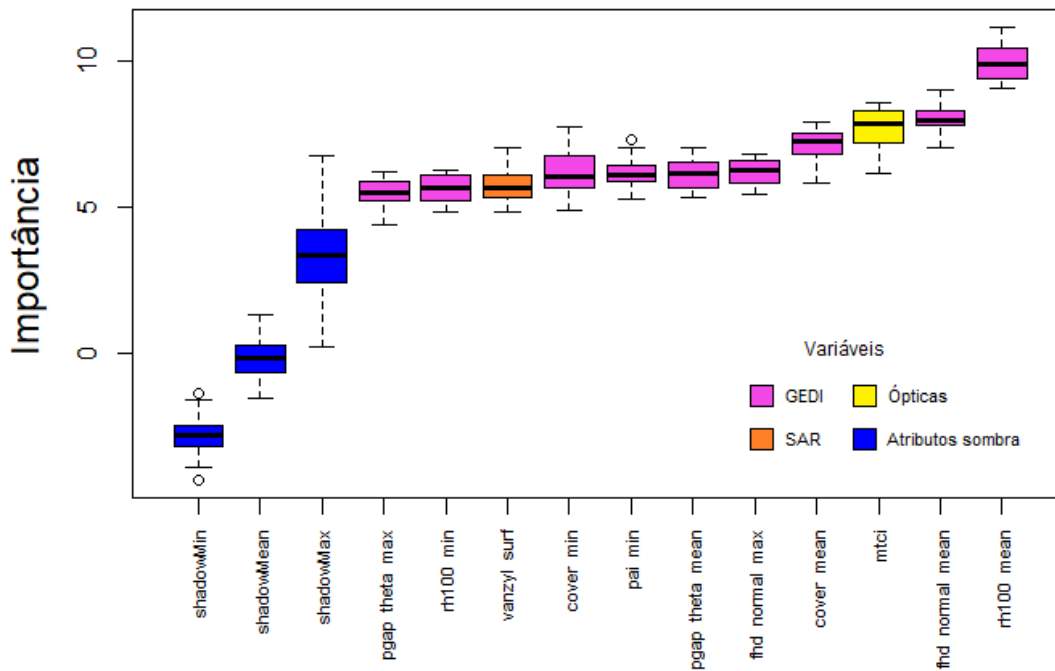
Fonte: Produção do autor.

As métricas fhd normal, pgap theta e rh100 também foram as variáveis com maior importância nos ajustes feitos por Campbell et al. (2021). Os autores observaram o desempenho dos dados GEDI e imagens ópticas do Landsat-8/OLI, isoladamente e em conjunto, na modelagem da AGB em uma região semiárida com baixa cobertura de dossel. No trabalho feito por Dorado-Roda et al. (2021), as variáveis PAI, pgap theta e fhd normal também tiveram importância significativa na predição da AGB em uma região da Espanha com vegetação mediterrânea.

As métricas LiDAR ALS escolhidas pelo algoritmo foram as relacionadas com o solo (pground e ipground), de intensidade (iskew), de porcentagem de retorno (p2th) e de altura (zmax). Dentre as variáveis derivadas dos dados SAR e ópticos, apenas o índice MTCI foi selecionado.

O resultado da seleção das variáveis GEDI, SAR e imagens óptica está exposto na Figura 4.4. Diferente do resultado da Figura 4.3, a componente de espalhamento da superfície de van Zyl e valores mínimos de rh100 foram escolhidos pelo algoritmo.

Figura 4.4 – Relevância das variáveis GEDI, SAR e ópticas com 555,55 m de resolução espacial para estimar a AGB de acordo com o algoritmo Boruta.




Fonte: Produção do autor.

Para a modelagem da AGB com os dados LiDAR ALS, SAR e imagens ópticas, a componente de espalhamento da superfície de van Zyl também foi selecionada (Figura 4.5). De forma similar aos resultados encontrados na Figura 4.3, as métricas LiDAR ALS relacionadas com o solo (pground e ipground) também foram escolhidas. Como imagens de resoluções espaciais baixas (555,55 m) têm maior probabilidade de ter mais elementos associados ao pixel em comparação com resoluções maiores, as métricas relacionadas com o solo auxiliam na identificação de solo exposto dentro do *pixel* e as relaciona com baixos valores de AGB (SHIMABUKURO et al., 2019b).

Além disso, as métricas de intensidade (iskew), as métricas de porcentagem de retornos (p2th e p1th), de altura (zskew e zkurt) e de percentil de distribuição da altura (zq65, zq70 e zq75) também foram eleitos. Não houve variáveis ópticas selecionadas nesse ajuste.

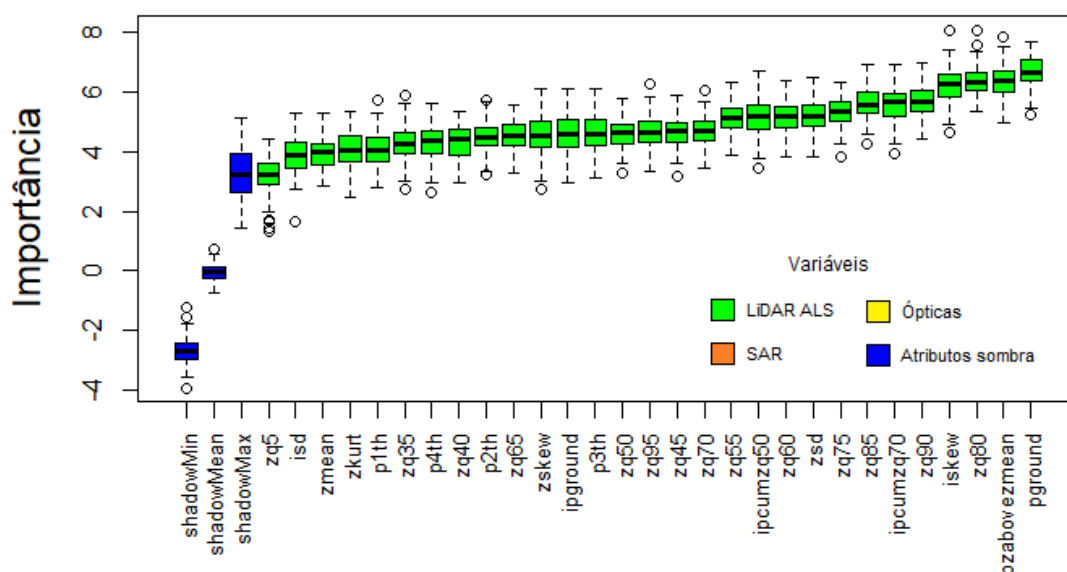
Figura 4.5 – Relevância das variáveis LiDAR ALS, SAR e ópticas com 555,55 m de resolução espacial para estimar a AGB de acordo com o algoritmo Boruta.



Fonte: Produção do autor.

Mostra-se, na Figura 4.6, o resultado da seleção das variáveis LiDAR ALS, SAR e imagens ópticas utilizando 65 amostras. Conforme mostrado na imagem, nenhuma componente SAR e óptica foi selecionada. De forma similar aos resultados supramencionados com o dado LIDAR ALS, as métricas relacionadas com o solo (pground e ipground), a porcentagem de retornos (pzabovezmean), a intensidade (iskew, isd, ipcumzq70 e ipcumzq50), a porcentagem de retorno (p2th, p3th e p4th), a altura (zsd, zskew, zkurt e zmean) e o percentil de distribuição da altura (zq35 – zq95) também foram selecionadas.

Figura 4.6 – Relevância das variáveis LiDAR ALS, SAR e ópticas com 555,55 m de resolução espacial para estimar a AGB, com 65 amostras, de acordo com o algoritmo Boruta.



Fonte: Produção do autor.

4.2 Desempenho das fontes de dado para estimar a AGB

4.2.1 Variáveis de 16,62m de resolução espacial

Os modelos ajustados com a combinação dos dados LiDAR ALS e PALSAR-2, de 16,62 m de resolução espacial, exibiram os melhores valores de RMSE, RMSE%, R^2 e MAE em comparação com aqueles sem esse conjunto (Tabela 4.1). A junção das métricas LiDAR ALS com as variáveis SAR na modelagem resultou na diminuição de $10,87 \text{ Mg ha}^{-1}$ na RMSE e no aumento de 0,14 no R^2 em comparação com o ajuste que usou apenas os dados do PALSAR-2.

A adição das variáveis ópticas reduziu a RMSE em 1,23, 3,04 e $5,89 \text{ Mg ha}^{-1}$ nas estimativas de AGB usando os dados SAR e LiDAR ALS, apenas dados LiDAR ALS e apenas dados SAR, respectivamente. Além disso, a adição dos dados ópticos aumentou o R^2 em 0,02, 0,03 e 0,07 nas estimativas de AGB com esses dados, respectivamente.

Tabela 4.1 – Desempenho médio do modelo para cada fonte de dado, com resolução espacial de 16,62 m, pelo método validação cruzada por *k-fold*.

Dados	RMSE (Mg.ha ⁻¹)	RMSE% (%)	R ²	MAE (Mg.ha ⁻¹)
LiDAR + PALSAR-2 + Sentinel-2	60,3466(±0,0675)*	23,0749(±0,3027)	0,7201(±0,0007)	43,9018(±0,0724)
LiDAR + PALSAR-2	61,5758(±0,0744)	23,0245(±0,4348)	0,7023(±0,0007)	44,0286(±0,0829)
LiDAR + Sentinel-2	82,5421(±0,0945)	28,2102(±0,2233)	0,6038(±0,0009)	65,0353(±0,0624)
PALSAR-2 + Sentinel-2	66,5602(±0,1002)	25,7080(±0,4123)	0,6398(±0,0012)	47,9120(±0,1030)
LiDAR	85,5846(±0,0553)	29,0620(±0,2737)	0,5743(±0,0005)	67,5489(±0,0767)
PALSAR-2	72,4497(±0,1094)	28,4231(±0,3614)	0,5657(±0,0016)	49,2662(±0,0826)
Sentinel-2	92,3168(±0,0795)	32,6493(±0,3326)	0,4959(±0,0009)	74,7669(±0,0708)

* Média (± Desvio Padrão).

Fonte: Produção do autor.

Com relação às estimativas com os dados isolados, o uso das métricas LiDAR ALS apresentou o maior R² entre os três dados, enquanto que o ajuste com as variáveis SAR mostrou a menor RMSE entre eles. A estimativa de AGB com somente as imagens do PALSAR-2 teve um valor de RMSE 13,09 Mg ha⁻¹ menor em comparação com a estimativa que utilizou apenas as métricas LiDAR ALS.

O desempenho do modelo com as variáveis LiDAR ALS, SAR e ópticas com 16,62 m de resolução espacial está exibido na Tabela 4.2. O ajuste apresentou uma RMSE de 60,35 Mg ha⁻¹ (RMSE% de 23,07%), R² de 0,72 e MAE de 43,90 Mg ha⁻¹ (Tabela 4.1). A AGB estimada com esse modelo, utilizando o grupo de teste da validação cruzada por *k-fold*, variou de 72,89 Mg ha⁻¹ a 460,75 Mg ha⁻¹, com uma média de 262,82 Mg ha⁻¹. Esses resultados são consistentes com outros trabalhos que estimaram a AGB na Amazônia com ou sem corte seletivo de baixa intensidade (D'OLIVEIRA et al., 2012; SILVA et al., 2016; ALMEIDA et al., 2019; REX et al., 2020).

Tabela 4.2 – Desempenho médio do modelo com variáveis LiDAR ALS, SAR e ópticas de 16,62 m de resolução espacial para cada repetição da validação cruzada por k-fold.

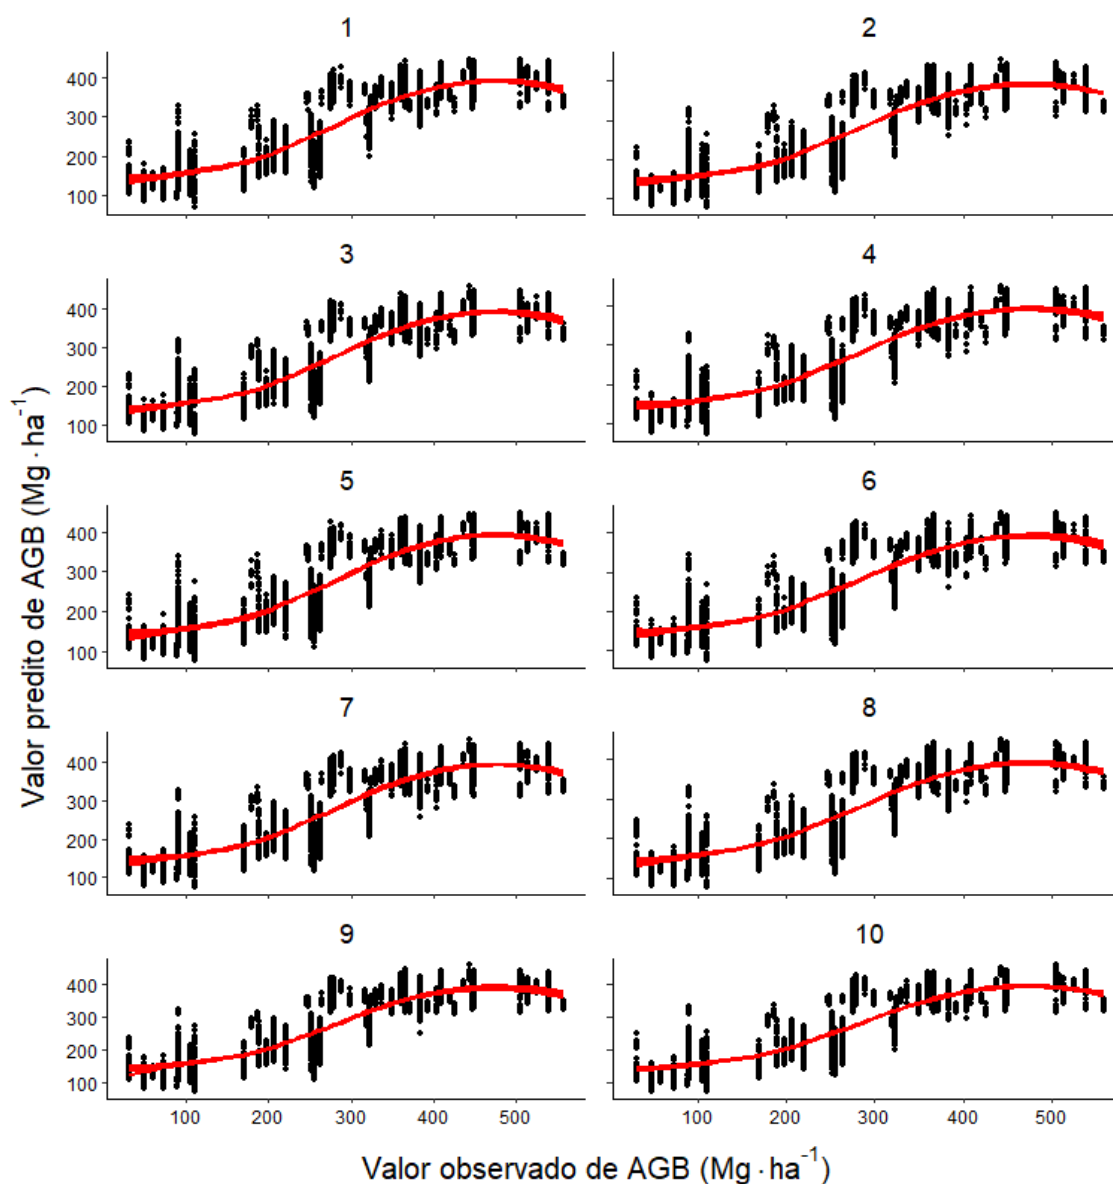
Repetição	RMSE (Mg.ha⁻¹)	RMSE% (%)	R²	MAE (Mg.ha⁻¹)
1	60,2767	23,5847	0,7211	43,9409
2	60,4099	23,3947	0,7192	43,8714
3	60,4611	22,9756	0,7192	44,0205
4	60,4026	22,9992	0,7195	43,9185
5	60,3270	23,1189	0,7202	43,9423
6	60,3763	23,0831	0,7200	43,9546
7	60,3404	22,6745	0,7200	43,9207
8	60,3248	23,2251	0,7201	43,8243
9	60,3146	22,5656	0,7204	43,7697
10	60,2321	23,1275	0,7213	43,8554
Média	60,3466	23,0749	0,7201	43,9018

Fonte: Produção do autor.

Na Figura 4.7 estão dispostos os valores de AGB observados nas parcelas de campo, no eixo horizontal, e os valores preditos de AGB com dados LiDAR ALS, SAR e imagens ópticas com 16,62m de resolução espacial, no eixo vertical. Em todas as repetições da validação cruzada por *k-fold*, é possível verificar que o modelo subestimou a AGB no intervalo entre 250 Mg ha⁻¹ e 320 Mg ha⁻¹ e a superestimou em 90 Mg ha⁻¹ e entre 270 Mg ha⁻¹ e 300 Mg ha⁻¹.

Observa-se na imagem que a variação dos dados e a linha de tendência foi similar em todas as repetições da validação cruzada. Isto posto, os modelos ajustados com os grupos de treinamento da validação cruzada predisseram AGB de forma equivalente usando cada grupo de teste.

Figura 4.7 – Valores observados de AGB pelos valores preditos de AGB com variáveis de 16,62 m de resolução. A linha vermelha representa o ajuste linear.



Fonte: Produção do autor.

4.2.2 Variáveis de 50m de resolução espacial

A AGB estimada por meio das variáveis LiDAR ALS, SAR e imagens ópticas, de 50 m de resolução, variou de $60,41 \text{ Mg ha}^{-1}$ a $468,41 \text{ Mg ha}^{-1}$, com uma média de $285,20 \text{ Mg ha}^{-1}$. A modelagem com essas fontes de dados exibiu uma RMSE de $75,88 \text{ Mg ha}^{-1}$, um R^2 de 0,66 e um MAE de $59,05 \text{ Mg ha}^{-1}$ (Tabela 4.3). Verifica-se nos resultados da tabela que os ajustes com os dados LiDAR ALS

proporcionaram os melhores resultados em comparação com aqueles sem esse dado.

Tabela 4.3 – Desempenho médio do modelo para cada fonte de dado, com resolução espacial de 50m, pelo método validação cruzada por *k-fold*.

Dados	RMSE (Mg.ha ⁻¹)	RMSE% (%)	R ²	MAE (Mg.ha ⁻¹)
LiDAR + PALSAR-2 + Sentinel-2	75,8819(±0,1230)*	26,4336(±0,6821)	0,6565(±0,0011)	59,0527(±0,1498)
LiDAR + PALSAR-2	77,4735 (±0,0927)	26,9513(±0,3907)	0,6414(±0,0009)	60,0749(±0,1088)
LiDAR + Sentinel-2	77,2924(±0,1437)	26,6452(±0,5362)	0,6405(±0,0014)	60,1753(±0,1601)
PALSAR-2 + Sentinel-2	86,6240(±0,2251)	33,1093(±0,5597)	0,4376(±0,0031)	64,9399(±0,1292)
LiDAR	77,4102(±0,1782)	27,1668(±0,5291)	0,6392(±0,0017)	60,0894(±0,1381)
PALSAR-2	92,6045(±0,2364)	35,1119(±0,5429)	0,3484(±0,0036)	70,6798(±0,1715)
Sentinel-2	101,8120(±0,1453)	36,3651(±0,7180)	0,3750(±0,0017)	80,07552(±0,1655)

* Média (± Desvio Padrão).

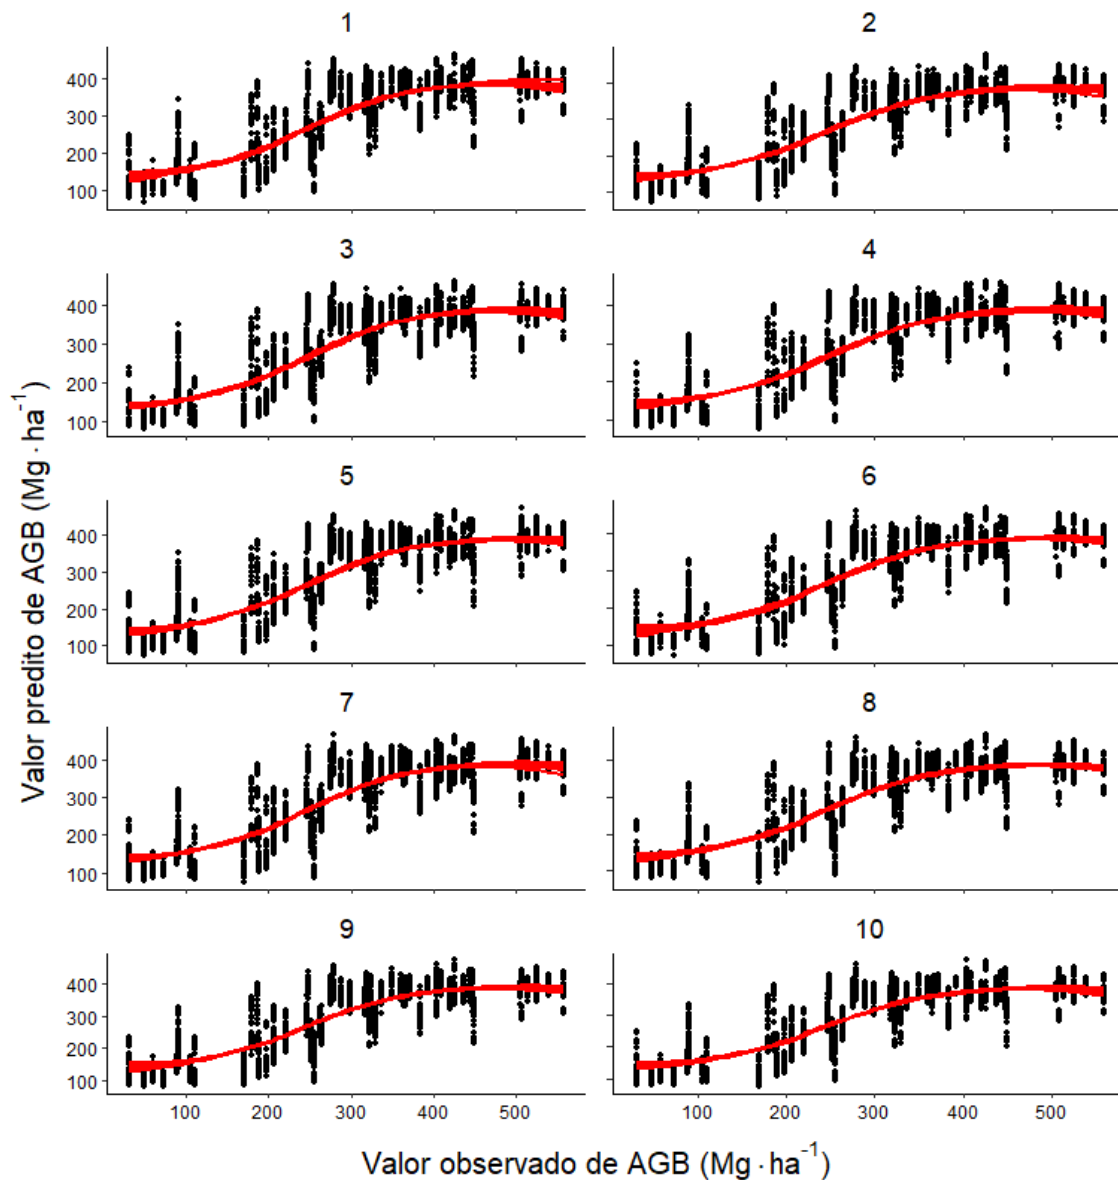
Fonte: Produção do autor.

Segundo os resultados, a inclusão dos dados ópticos e SAR na modelagem não proporcionou melhora significativa na performance do modelo. Uma das explicações para isso são os maiores valores de RMSE e MAE e o pior valor de R² dos dados SAR de 50 m de resolução em comparação com aqueles de 16,62 m de resolução. Dessa forma, a resolução espacial maior (16,62 m) dos dados SAR apresentou maior capacidade em detectar a variabilidade da AGB em regiões de floresta tropical em comparação com aqueles de resolução espacial menor (50 m).

Contrapondo as performances dos modelos que utilizaram somente os dados LiDAR ALS, referentes às Tabelas 4.1 e 4.3, foi constatado que as variáveis de 50 m de resolução tiveram melhor desempenho. Vale enfatizar que o número de amostras é distinto entre esses ajustes. A redução da resolução espacial favoreceu na diminuição da RMSE de 85,58 Mg ha⁻¹ para 77,41 Mg ha⁻¹ e no aumento do R² de 0,57 para 0,64.

Os valores de AGB observados em campo (eixo x) e os valores preditos de AGB com as variáveis LiDAR ALS, SAR e ópticas de 50m de resolução (eixo y) estão dispostos na Figura 4.8. Na imagem é possível notar maior variação dos valores preditos em comparação com aqueles mostrados na Figura 4.7. Os dez modelos ajustados na validação cruzada predisseram a AGB de forma equivalente.

Figura 4.8 – Valores observados de AGB pelos valores preditos de AGB com variáveis de 50m de resolução. A linha vermelha representa o ajuste linear.



Fonte: Produção do autor.

4.2.3 Variáveis de 555,55 m de resolução espacial

Nas estimativas de AGB com variáveis de 555,55 m de resolução, o melhor ajuste do modelo foi aquele com o conjunto de dados GEDI, LiDAR ALS, PALSAR-2 e Sentinel-2 (Tabela 4.4). Dentre as contribuições de cada dado no desempenho do modelo, as variáveis do GEDI foram as responsáveis pelo maior ganho no desempenho do modelo preditor de AGB.

Tabela 4.4 – Desempenho médio do modelo para cada fonte de dado, com resolução espacial de 555,55 m, pelo método validação cruzada por *k-fold*.

Dados	RMSE (Mg.ha ⁻¹)	RMSE% (%)	R ²	MAE (Mg.ha ⁻¹)
GEDI + LiDAR ALS + PALSAR-2 + Sentinel-2	89,8681(±0,2669)*	28,0448(±0,8595)	0,5707(±0,0024)	78,9851(±0,3776)
GEDI + LiDAR ALS + PALSAR-2	93,4305(±0,2200)	29,3672(±1,3553)	0,5511(±0,0018)	80,1400(±0,3422)
GEDI + LiDAR ALS + Sentinel-2	91,9359(±0,4206)	29,0808(±0,8604)	0,5656(±0,0036)	79,2068(±0,4169)
GEDI + PALSAR-2 + Sentinel-2	92,0250(±0,3555)	28,6793(±1,0179)	0,5650(±0,0033)	79,9092(±0,3050)
LiDAR ALS + PALSAR-2 + Sentinel-2	93,9381(±0,3873)	29,8637(±0,9575)	0,5355(±0,0035)	77,1372(±0,3327)
GEDI + LiDAR ALS	91,8035 (±0,4017)	28,6813(±0,9173)	0,5622(±0,0036)	78,0607(±0,3841)
GEDI + PALSAR-2	94,0022 (±0,3782)	29,4307(±0,6921)	0,5434(±0,0034)	81,5183(±0,4426)
LiDAR ALS + PALSAR-2	93,8446(±0,3527)	30,1943(±0,9227)	0,5357(±0,0035)	77,1559(±0,3174)
GEDI + Sentinel-2	90,7645(±0,4305)	29,1703(±0,7679)	0,5717(±0,0039)	77,5417(±0,4347)
LiDAR ALS + Sentinel-2	93,5003(±0,1997)	30,0480(±0,6023)	0,5404(±0,0021)	76,4186(±0,2490)
PALSAR-2 + Sentinel-2	92,4623(±0,4325)	29,3586(±0,4163)	0,5354(±0,0040)	77,7927(±0,3737)
GEDI	93,9401(±0,2865)	29,2517(±0,8296)	0,5427(±0,0025)	80,3415(±0,4096)
LiDAR ALS	93,6752(±0,2449)	30,1507(±0,8753)	0,5379(±0,0019)	77,0335(±0,3471)
PALSAR-2	92,7419(±0,4276)	29,2884(±0,8562)	0,5317(±0,0043)	78,1212(±0,5195)
Sentinel-2	100,9396(±0,5136)	31,3862(±1,2726)	0,4620(±0,0055)	85,1984(±0,2962)

* Média (± Desvio Padrão).

Fonte: Produção do autor.

Na inclusão dessas variáveis no ajuste, a RMSE decresceu 4,07 Mg ha⁻¹ e o R² expandiu em 0,035 em comparação com a modelagem sem esse dado. Ademais, os dados GEDI tiveram o melhor desempenho na modelagem com os dados isolados.

As imagens ópticas tiveram a segunda melhor contribuição no aprimoramento do modelo. A RMSE diminuiu em 3,56 Mg ha⁻¹ e o R² aumentou em 0,02 em comparação com o modelo sem esse dado. Essa contribuição dos dados GEDI e imagens ópticas no desempenho do modelo preditor de AGB também foi verificado por Campbell et al. (2021). A combinação dessas variáveis resultou no aumento do R² em 0,02 e na diminuição da RMSE em 0,37 Mg ha⁻¹ em comparação com o modelo ajustado com as imagens ópticas apenas.

Por outro lado, a junção das métricas do LiDAR ALS com os outros dados não proporcionou melhora significativa no modelo. A RMSE reduziu 2,16 Mg ha⁻¹ e o R² cresceu 0,006. Entretanto, o acréscimo dos dados LiDAR ALS no ajuste com somente os dados GEDI reduziu a RMSE em 2,14 Mg ha⁻¹ e expandiu o R² em 0,02.

Segundo os resultados da tabela, o desempenho de nenhum modelo foi melhorado com a adição das componentes SAR. Na modelagem dos dados separados, as imagens ópticas apresentaram o pior desempenho em comparação com as outras variáveis (RMSE igual a 100,94 Mg ha⁻¹ e R² igual a 0,46).

Os valores máximos, mínimos e médios da AGB estimada pelos melhores modelos com variáveis de 555,55m de resolução espacial estão na Tabela 4.5. Os valores da tabela apresentaram pouca variação entre eles. Em contraste, esses valores foram maiores em comparação com as estimativas de AGB usando dados de 16,62 m e 50 m de resolução espacial.

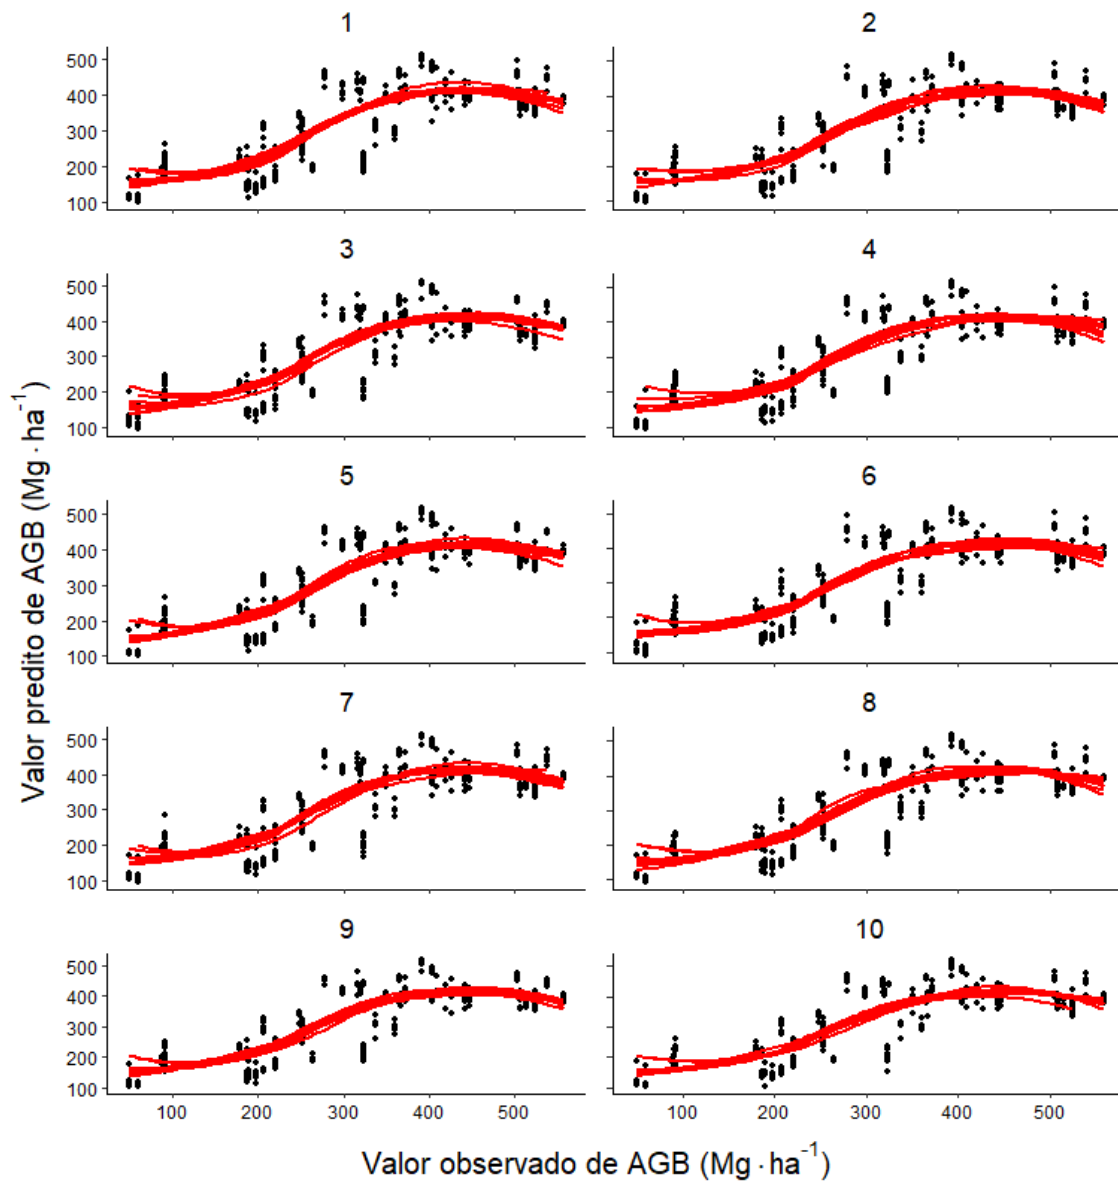
Tabela 4.5 – Valores máximos, mínimos e médios obtidos na estimativa da AGB usando os grupos de teste da validação cruzada por *k-fold*. As variáveis aplicadas possuem 555,55 m de resolução espacial.

Dados	Máximo (Mg ha⁻¹)	Mínimo (Mg ha⁻¹)	Média (Mg ha⁻¹)
GEDI + LiDAR ALS + PALSAR-2 + Sentinel-2	517,97	93,49	318,98
GEDI + PALSAR-2 + Sentinel-2	522,19	96,42	323,09
LiDAR ALS + PALSAR-2 + Sentinel-2	517,33	91,80	319,89

Fonte: Produção do autor.

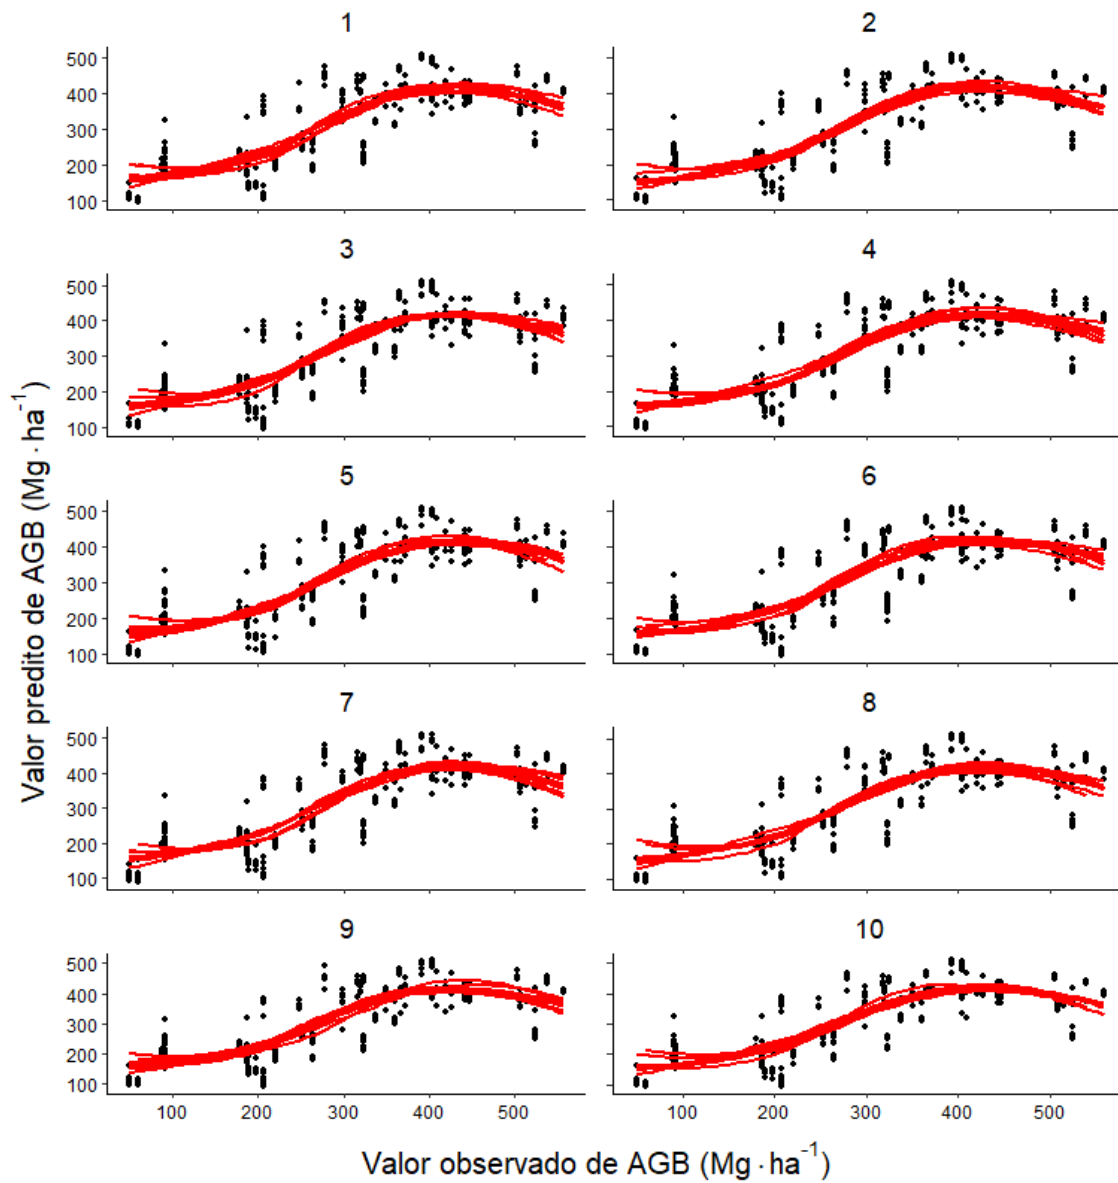
Nas Figuras 4.9, 4.10 e 4.11 estão dispostos os valores de AGB observados em campo, no eixo das abscissas, e os valores preditos de AGB com os melhores modelos de 555,55 m de resolução espacial, no eixo das ordenadas. As curvas de tendência dos gráficos apresentaram maior variância em comparação com as estimativas de AGB de 16,62 m e 50 m de resolução espacial. Uma justificativa para isso é o menor número de amostras aplicados nessas estimativas em comparação com os ajustes das Figuras 4.7 e 4.8. As três modelagens predisseram a AGB de forma semelhante. Houve subestimação dos valores de AGB entre 190 Mg ha⁻¹ e 220 Mg ha⁻¹, em 310 Mg ha⁻¹ e entre 490 Mg ha⁻¹ e 550 Mg ha⁻¹. Houve superestimação da AGB entre 280 e 410 Mg ha⁻¹.

Figura 4.9 – Valores observados de AGB pelos valores preditos de AGB com dados GEDI, LiDAR ALS, SAR e imagens ópticas de 555,55 m de resolução espacial. A linha vermelha representa o ajuste linear.



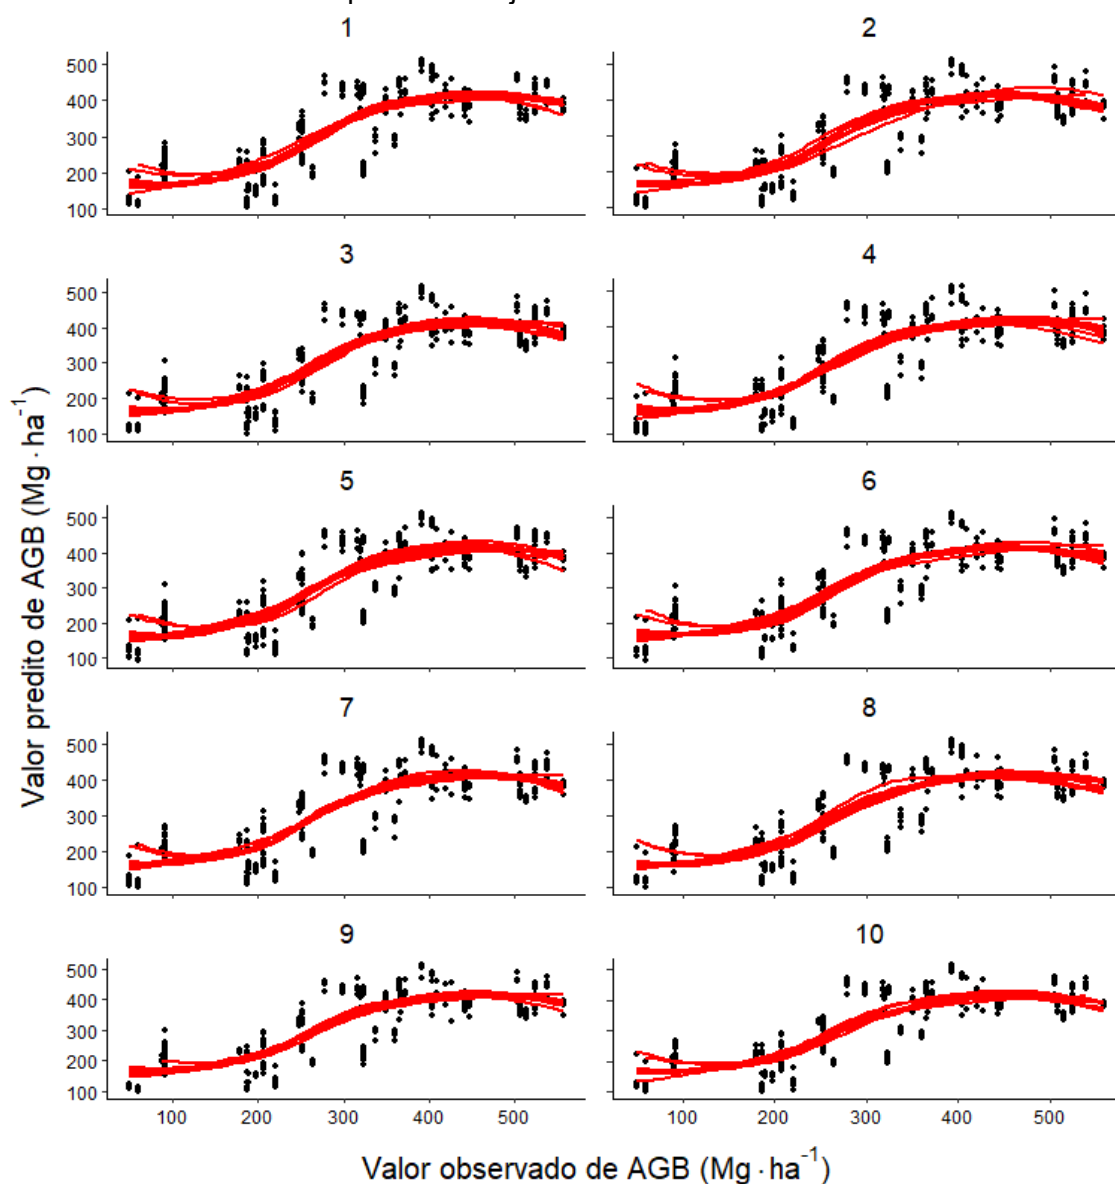
Fonte: Produção do autor.

Figura 4.10 – Valores observados de AGB pelos valores preditos de AGB com dados LiDAR ALS, SAR e imagens ópticas de 555,55 m de resolução espacial. A linha vermelha representa o ajuste linear.



Fonte: Produção do autor.

Figura 4.11 – Valores observados de AGB pelos valores preditos de AGB com dados GEDI, SAR e imagens ópticas de 555,55 m de resolução espacial. A linha vermelha representa o ajuste linear.



Fonte: Produção do autor.

A estimativa de AGB com os dados LiDAR ALS de 555,55 m de resolução espacial utilizando 65 amostras resultou na seguinte performance: RMSE de $84,1508 \text{ Mg ha}^{-1}$ ($\pm 0,3316$); RMSE% de $28,7739\%$ ($\pm 0,8246$); R^2 de $0,6038$ ($\pm 0,0029$); e MAE de $68,8092 \text{ Mg ha}^{-1}$ ($\pm 0,2235$). Devido à diferença de amostragem entre esse ajuste e as modelagens da Tabela 4.4, o resultado com 65 amostras foi superior em comparação com todos os resultados apresentados

dessa tabela. Desta forma, o aumento de amostras dentro dos transectos GEDI pode corroborar para o aprimoramento do modelo com esse dado.

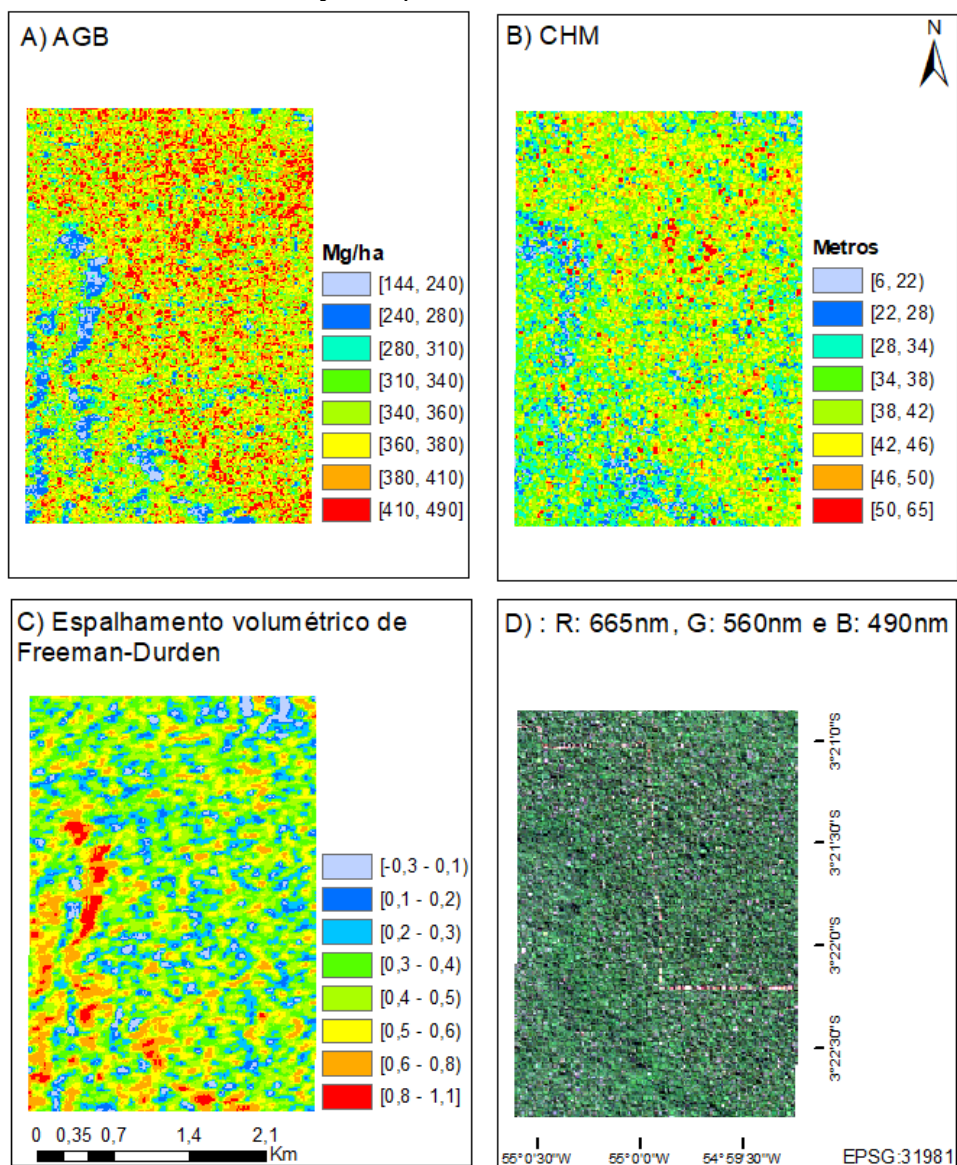
A AGB estimada com esse modelo variou de 59,84 Mg ha⁻¹ a 525,14 Mg ha⁻¹, com uma média de 291,92 Mg ha⁻¹. Nesse ajuste, nenhuma variável SAR e óptica aprimorou o modelo, bem como nenhuma componente derivada desses dados foi selecionada pelo algoritmo Boruta (Figura 4.6). Os gráficos dos valores de AGB observados em campo pelos valores preditos com esse dado estão dispostos no apêndice A, Figura A.1.

4.3 Predição da AGB

O mapeamento da AGB feito com o melhor modelo ajustado usando as variáveis de 16,62 m de resolução espacial, na região ANA, está ilustrado na Figura 4.13. O CHM, a componente de espalhamento volumétrico de Freeman-Durden e a composição das três bandas do espectro do visível do Sentinel-2 também estão dispostos na imagem. De acordo com a Figura, a maior quantidade de AGB estimada em ANA foi de 490 Mg ha⁻¹ e a menor quantidade foi de 144 Mg ha⁻¹. Almeida et al. (2019) mapearam a AGB em uma região de floresta primária na Amazônia e os valores máximo (454 Mg ha⁻¹) e mínimo (193 Mg ha⁻¹) se aproximaram dos valores estimados no presente trabalho.

Como a maior parte da área é composta por floresta primária, com indivíduos de 6 m a 65 m de altura, a maioria dos pixels apresentaram valores de AGB ≥ 280 Mg ha⁻¹. Dentre os locais com valores inferiores a 280 Mg ha⁻¹ de AGB, é possível identificar locais com distúrbios na vegetação, como estradas sob o dossel. Nesses locais, encontram-se as menores árvores e os maiores valores da componente de espalhamento volumétrico de Freeman-Durden.

Figura 4.12 – (A) Valores de AGB preditos pelo algoritmo *Random Forest*, com dados LiDAR ALS, PALSAR-2 e Sentinel-2, em uma região da Flona do Tapajós. (B) CHM do dado LiDAR ALS. (C) Componente de espalhamento volumétrico de Freeman-Durden. (D) Composição das bandas 665 nm, 560 nm e 490 nm dos dados do Sentinel-2. As Figuras A, B, C e D estão com uma resolução espacial de 16,62 m.

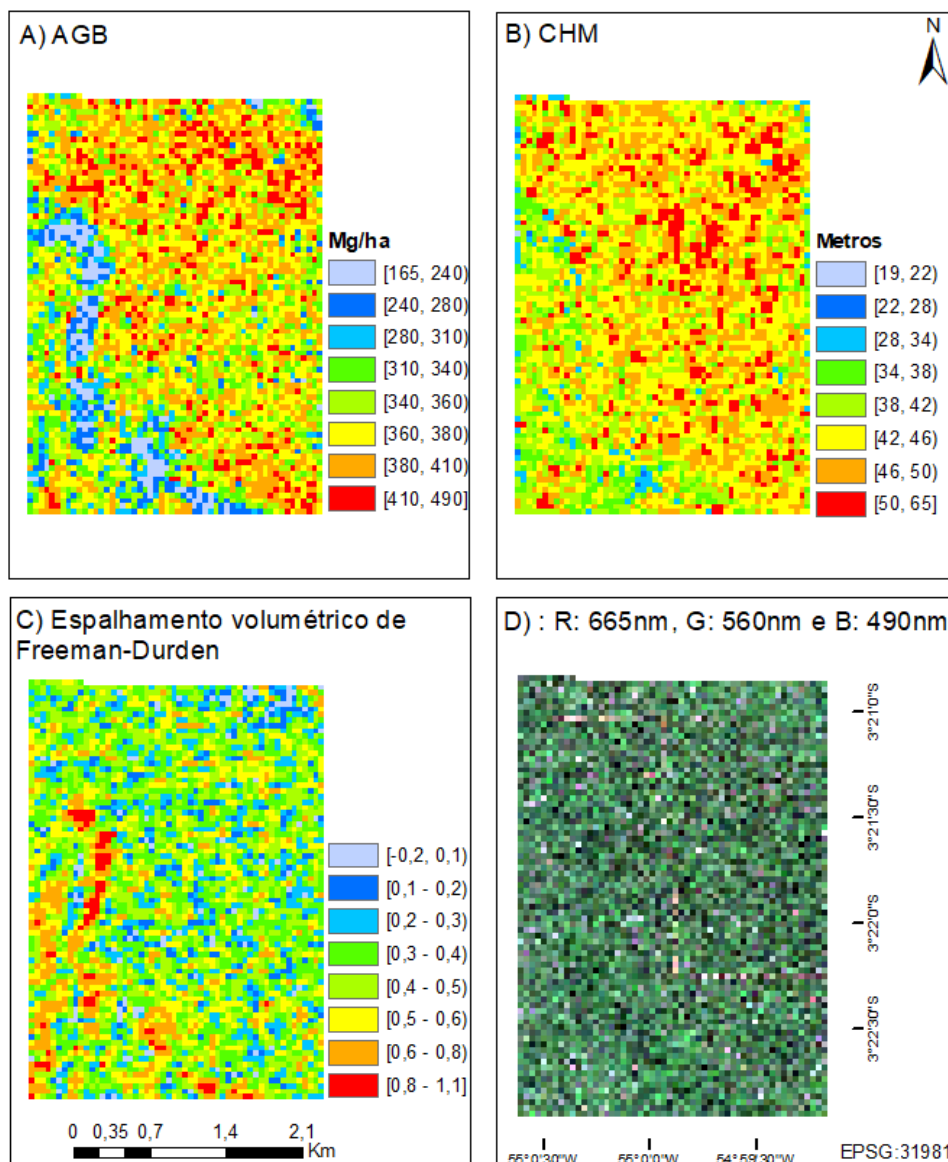


Fonte: Produção do autor.

A AGB estimada com o melhor modelo usando as variáveis de 50m de resolução espacial, para a região ANA, está representada na Figura 4.14. Ao comparar as Figuras 4.13 e 4.14, é possível observar que o menor valor de AGB observado aumentou de 144 Mg ha⁻¹ para 165 Mg ha⁻¹. Esse fato pode estar ligado à maior probabilidade de existir mais elementos inseridos no pixel de 50 m em comparação com a resolução espacial de 16,62 m (SHIMABUKURO et al.,

2019b). É possível notar esse comportamento no aumento da altura mínima de 6 m (Figura 4.6) para 19 m (Figura 4.7).

Figura 4.13 – (A) Valores de AGB preditos pelo algoritmo *Random Forest*, com dados LiDAR ALS, PALSAR-2 e Sentinel-2, em uma região da Flona do Tapajós. (B) CHM do dado LiDAR ALS. (C) Componente de espalhamento volumétrico de Freeman-Durden. (D) Composição das bandas 665 nm, 560 nm e 490 nm dos dados do Sentinel-2. As Figuras A, B, C e D estão com uma resolução espacial de 50 m.

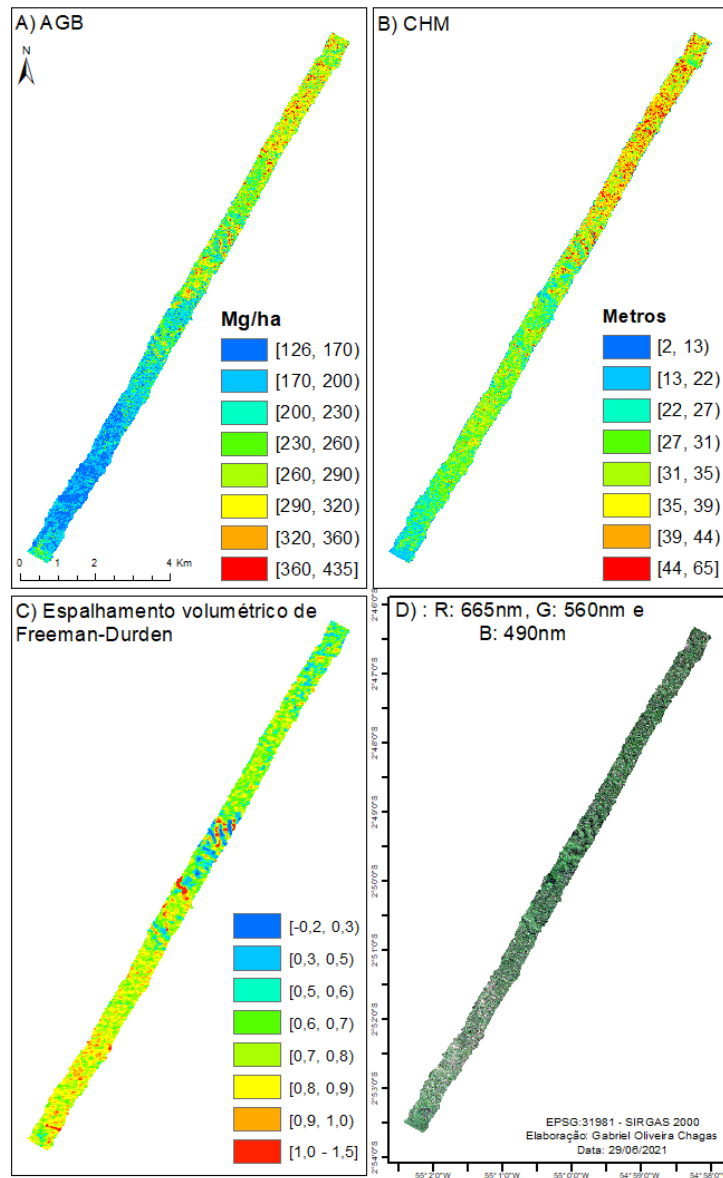


Fonte: Produção do autor.

Os resultados do mapeamento da AGB nos transectos LiDAR ALS do projeto Estimativa da Biomassa na Amazônia, utilizando o melhor modelo ajustado com variáveis de 16,62 m de resolução espacial, estão apresentados nas Figuras 4.15 e 4.16. A partir da análise visual das imagens, foi possível constatar que o

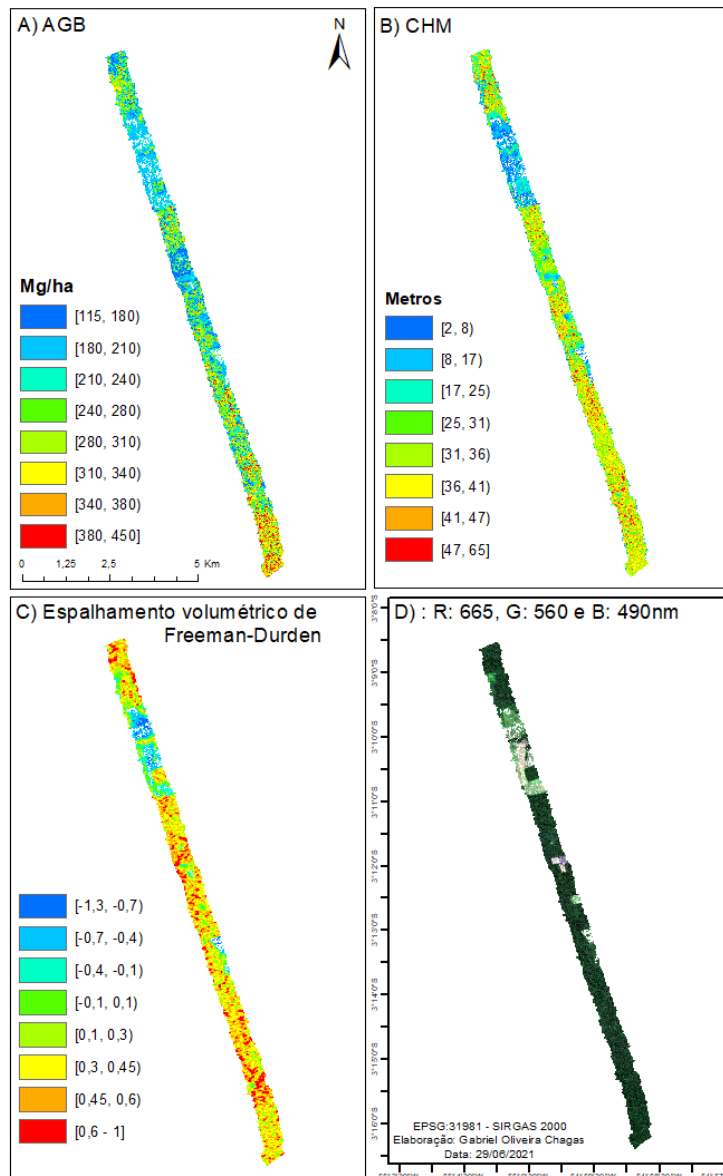
modelo é capaz de explicar a AGB nessas áreas com gradiente de degradação florestal.

Figura 4.14 – (A) Valores de AGB preditos pelo algoritmo *Random Forest*, com dados LiDAR ALS do projeto Estimativa de Biomassa da Amazônia, PALSAR-2 e Sentinel-2, em uma região da Flona do Tapajós. (B) CHM do dado LiDAR ALS. (C) Componente de espalhamento volumétrico de Freeman-Durden. (D) Composição das bandas 665 nm, 560 nm e 490 nm dos dados do Sentinel-2. As Figuras A, B, C e D estão com uma resolução espacial de 16,62 m.



Fonte: Produção do autor.

Figura 4.15 – (A) Valores de AGB preditos pelo algoritmo *Random Forest*, com dados LiDAR ALS do projeto Estimativa de Biomassa da Amazônia, PALSAR-2 e Sentinel-2, em uma região da Flona do Tapajós. (B) CHM do dado LiDAR ALS. (C) Componente de espalhamento volumétrico de Freeman-Durden. (D) Composição das bandas 665 nm, 560 nm e 490 nm dos dados do Sentinel-2. As Figuras A, B, C e D estão com uma resolução espacial de 16,62 m.

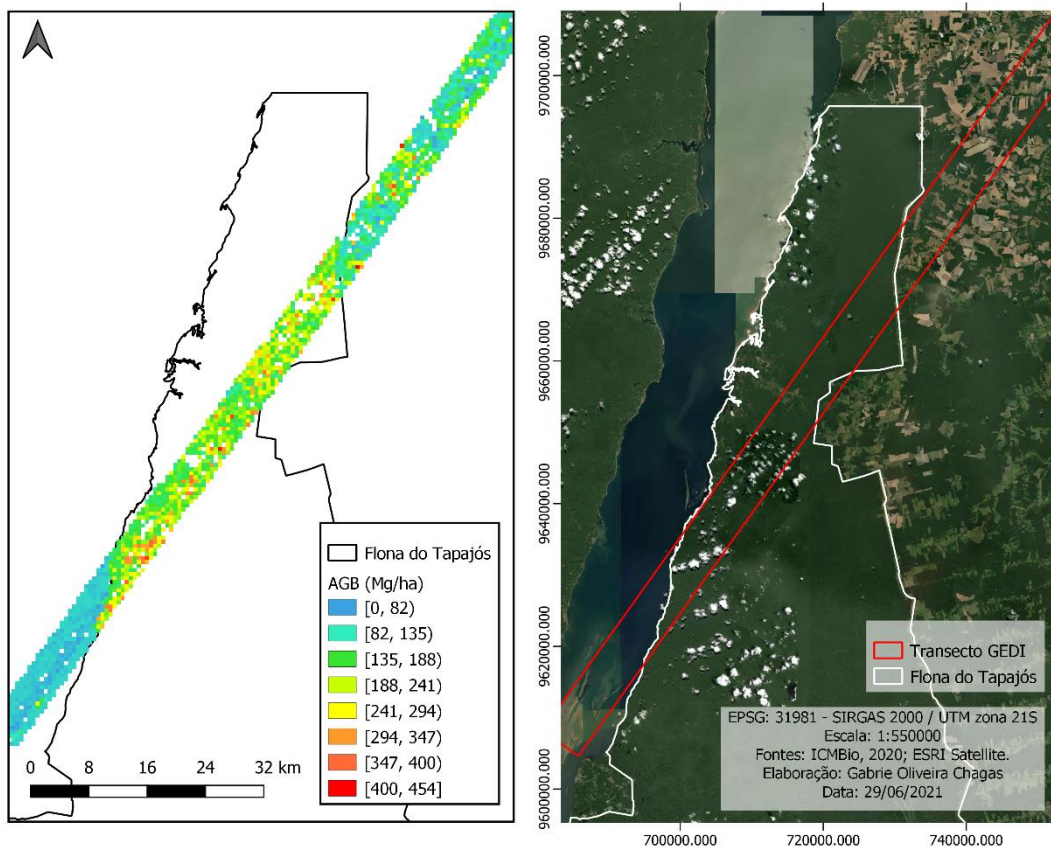


Fonte: Produção do autor.

A região da Figura 4.15 apresentou valores de AGB entre 126 Mg ha⁻¹ (área degradada) e 435 Mg ha⁻¹ (floresta intacta). A área da Figura 4.16 exibiu valores de AGB de 115 Mg ha⁻¹ (área degradada) a 450 Mg ha⁻¹ (floresta intacta). Os dados LiDAR ALS identificaram indivíduos arbóreos de 2 m a 65 m ao longo de ambos os transectos.

O mapa da AGB estimada pelo modelo ajustado com os dados GEDI está exibido na Figura 4.17. No curso hídrico e nas áreas com alta intensidade de degradação florestal a AGB variou de 0 a 82 Mg ha⁻¹. Em regiões de floresta primária, principalmente dentro da Flona do Tapajós, a AGB variou de 241 Mg ha⁻¹ a 454 Mg ha⁻¹.

Figura 4.16 – Valores de AGB preditos pelo algoritmo *Random Forest*, com o dado GEDI, em uma região da Flona do Tapajós. A AGB está com uma resolução espacial de 555,55 m.



Fonte: Produção do autor.

Nota-se que na parte interior da Flona do Tapajós a maioria dos *pixels* tem entre 135 Mg ha⁻¹ a 454 Mg ha⁻¹. Por outro lado, na fração externa da Flona, os valores dos *pixels* variaram de 0 a 188 Mg ha⁻¹. Nessa área é possível observar exceções que apresentaram valores entre 188 Mg ha⁻¹ e 454 Mg ha⁻¹ provenientes de fragmentos florestais externas à UC.

5 CONCLUSÃO

Neste trabalho foi estimada a biomassa acima do solo utilizando dados dos sensores LiDAR (GEDI e ALS), SAR (ALOS PALSAR-2) e ópticos (Sentinel-2 MSI) na região da Floresta Nacional do Tapajós e adjacências. As variáveis derivadas desses dados foram selecionadas de acordo com sua importância na estimativa de AGB. Com essa informação é possível melhorar a interpretabilidade e o desempenho do modelo e acelerar o processo de aprendizagem.

Com relação aos dados de SAR, as componentes de espalhamento volumétrico de Freeman-Durden, *generalized* Freeman-Durden, Yamaguchi e van Zyl apresentaram o maior valor de importância entre as variáveis SAR de 16,62m e 50m resolução espacial para estimar a AGB. As componentes de reflexão especular de Freeman-Durden e *generalized* Freeman-Durden e de espalhamento superficial de Freeman-Durden também compuseram o grupo das variáveis SAR de maior importância na estimativa de 16,62 m de resolução espacial. Nenhuma variável SAR foi selecionada na modelagem de 555,55 m de resolução espacial.

Com relação à seleção das variáveis LiDAR ALS, de 16,62 m e 50 m de resolução espacial, as métricas de intensidade (isd, imean, itot, iskew e ikurt), de porcentagem de retorno (p2th e p1th), de altura (zmax e zmean) e de percentil de distribuição da altura (zq35 – zq95) foram classificadas como importantes no modelo estimador de AGB. Para a estimativa de AGB de 555,55 m de resolução espacial, as métricas relacionadas com o solo (pground e ipground), de intensidade (iskew), de porcentagem de retorno (p2th) e de altura (zmax) foram aquelas com maior valor de importância entre as métricas LiDAR ALS. As componentes do dado GEDI com os maiores valores de importância foram as médias de rh100, fhd *normal*, cover e pgap *theta*, os valores máximos de fhd *normal* e pgap *theta* e os valores mínimos de cover e PAI.

Dentre as variáveis ópticas de 16,62 m e 50 m de resolução, as imagens fração solo e erro do MLME, NDWI e NDII foram classificadas como importantes para

estimar a AGB. No ajuste com variáveis de 555,55 m de resolução espacial, apenas o MTCI foi selecionado.

Além disso, foi analisado neste estudo o desempenho dos dados GEDI, LiDAR ALS, SAR e Sentinel-2, individuais e combinados, para estimar a AGB. Foi verificada, também, a influência das diferentes resoluções espaciais desses dados no desempenho do modelo.

Com base no desempenho nas estimativas de AGB de 16,62 m de resolução espacial, a adição dos dados LiDAR ALS e SAR em conjunto no modelo resultou na menor RMSE (60,35 Mg ha⁻¹ e RMSE% de 23,07%) e no maior R² (0,72) em comparação com as outras estimativas. Quanto à estimativa de AGB de 50 m de resolução espacial, os melhores ajustes foram aqueles com as métricas LiDAR ALS. A melhor estimativa com essa resolução apresentou uma RMSE de 75,88 Mg ha⁻¹ (RMSE% de 26,43) e um R² de 0,66. Com relação à estimativa com variáveis de 555,55 m de resolução espacial, as variáveis GEDI tiveram a melhor performance no ajuste da AGB. A melhor estimativa de AGB com essa resolução espacial teve uma RMSE de 89,87 Mg ha⁻¹ (RMSE% de 28,04) e um R² de 0,57.

Por fim, a AGB de áreas com diferentes graus de degradação florestal foi estimada por meio dos melhores modelos obtidos. A partir das análises visuais dos mapas de AGB produzidos neste estudo, foi constatado que os modelos ótimos deste estudo foram capazes de descrever a AGB de acordo com o grau de degradação florestal. Desta forma, este estudo provê informações sobre variáveis que podem ser obtidas dos dados GEDI, LiDAR ALS, SAR e imagens ópticas para aperfeiçoar as estimativas de AGB em regiões da Floresta Amazônica. Os resultados deste estudo demonstram o potencial dos dados GEDI, LiDAR ALS, SAR e ópticos para estimar a AGB em áreas de floresta tropical de acordo com a degradação florestal e a variabilidade da estrutura florestal.

Como pesquisa futura, recomenda-se a utilização de outros sensores SAR, da coerência interferométrica, de um maior número de parcelas de campo dentro dos transectos GEDI e a aplicação da metodologia adotada neste estudo em outras regiões da Floresta Amazônica.

REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, C. T.; GALVÃO, L. S.; ARAGÃO, L. E. O. C.; OMETTO, J. P. H. B.; JACON, A. D.; DE SOUZA PEREIRA, F. R.; SATO, L. Y.; LOPES, A. P.; DE ALENCASTRO GRAÇA, P. M. L.; DE JESUS SILVA, C. V.; FERREIRA-FERREIRA, J.; LONGO, M. Combining LiDAR and hyperspectral data for aboveground biomass modeling in the Brazilian Amazon using different regression algorithms. **Remote Sensing of Environment**, v. 232, e111323, 2019.

ALMEIDA, D. R. A.; NELSON, B. W.; SCHIETTI, J.; GORGENS, E. B.; RESENDE, A. F.; STARK, S. C.; VALBUENA, R. Contrasting fire damage and fire susceptibility between seasonally flooded forest and upland forest in the Central Amazon using portable profiling LiDAR. **Remote Sensing of Environment**, v. 184, p. 153–160, 2016.

ALVES, L. M.; MARENGO, J. A.; FU, R.; BOMBARDI, R. J. Sensitivity of Amazon regional climate to deforestation. **American Journal of Climate Change**, v. 6, n. 1, p. 75–98, 2017.

ARAGÃO, L. E. O. C.; ANDERSON, L. O.; FONSECA, M. G.; ROSAN, T. M.; VEDOVATO, L. B.; WAGNER, F. H.; SILVA, C. V. J.; SILVA JUNIOR, C. H. L.; ARAI, E.; AGUIAR, A. P.; BARLOW, J.; BERENGUER, E.; DEETER, M. N.; DOMINGUES, L. G.; GATTI, L.; GLOOR, M.; MALHI, Y.; MARENGO, J. A.; MILLER, J. B.; PHILLIPS, O. L.; SAATCHI, S. 21st Century drought-related fires counteract the decline of Amazon deforestation carbon emissions. **Nature Communications**, v. 9, n. 1, p. 536, 2018.

ARAGÃO, L. E. O. C.; MALHI, Y.; BARBIER, N.; LIMA, A.; SHIMABUKURO, Y.; ANDERSON, L.; SAATCHI, S. Interactions between rainfall, deforestation and fires during recent years in the Brazilian Amazonia. **Philosophical Transactions of the Royal Society B: Biological Sciences**, v. 363, n. 1498, p. 1779–1785, 2008.

ARAGÃO, L. E. O. C.; POULTER, B.; BARLOW, J. B.; ANDERSON, L. O.; MALHI, Y.; SAATCHI, S.; PHILLIPS, O. L.; GLOOR, E. Environmental change

and the carbon balance of Amazonian forests. **Biological Reviews**, v. 89, n. 4, p. 913–931, 2014.

ARAGÃO, L. E. O. C.; SHIMABUKURO, Y. E. The incidence of fire in Amazonian forests with implications for REDD. **Science**, v. 328, n. 5983, p. 1275 LP – 1278, 2010.

ARAI, E.; SHIMABUKURO, Y. E.; DUTRA, A. C.; DUARTE, V. Detection and analysis of forest degradation by fire using Landsat/Oli images in Google Earth Engine. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), 2019, **Proceedings...** 2019.

ARMENTERAS, D.; GONZÁLEZ, T. M.; RETANA, J. Forest fragmentation and edge influence on fire occurrence and intensity under different management types in Amazon forests. **Biological Conservation**, v. 159, p. 73–79, 2013.

AUGUSTO, A.; TABANEZ, J.; VIANA, V. M. Patch structure within Brazilian Atlantic Forest fragments and implications for conservation. **Biotropica**, v. 32, n. 4b, p. 925–933, 2000.

AVILA, A. L.; SCHWARTZ, G.; RUSCHEL, A. R.; DO CARMO LOPES, J.; SILVA, J. N. M.; CARVALHO, J. O. P.; DORMANN, C. F.; MAZZEI, L.; SOARES, M. H. M.; BAUHUS, J. Recruitment, growth and recovery of commercial tree species over 30 years following logging and thinning in a tropical rain forest. **Forest Ecology and Management**, v. 385, p. 225–235, 2017.

BANCO NACIONAL DE DESENVOLVIMENTO (BNDES). **Fundo Amazônia**. 2020. Disponível em: <<https://www.bndes.gov.br/wps/portal/site/home/financiamento/produto/fundo-amazonia>>. Acesso em: 18 fev. 2020

BANNARI, A.; MORIN, D.; BONN, F.; HUETE, A. R. A review of vegetation indices. **Remote Sensing Reviews**, v. 13, n. 1–2, p. 95–120, 1995.

BARET, F.; GUYOT, G. Potentials and limits of vegetation indices for LAI and APAR assessment. **Remote Sensing of Environment**, v. 35, n. 2, p. 161–173, 1991.

BARONA, E.; RAMANKUTTY, N.; HYMAN, G.; COOMES, O. T. The role of

pasture and soybean in deforestation of the Brazilian Amazon. **Environmental Research Letters**, v. 5, n. 2, e24002, 2010.

BERNINGER, A.; LOHBERGER, S.; STÄNGEL, M.; SIEGERT, F. SAR-based estimation of above-ground biomass and its changes in tropical forests of Kalimantan using L- and C-Band. **Remote Sensing**, v. 10, n. 6, 2018.

BIRTH, G. S.; MCVEY, G. R. Measuring the color of growing turf with a reflectance spectrophotometer. **Agronomy Journal**, v. 60, n. 6, p. 640–643, 1968.

BISPO, P. C.; SANTOS, J. R.; VALERIANO, M. M.; TOUZI, R.; SEIFERT, F. M. Integration of polarimetric PALSAR attributes and local geomorphometric variables derived from SRTM for forest biomass modeling in Central Amazonia. **Canadian Journal of Remote Sensing**, v. 40, n. 1, p. 26–42, 2014.

BLACKBURN, G. A. Spectral indices for estimating photosynthetic pigment concentrations: a test using senescent tree leaves. **International Journal of Remote Sensing**, v. 19, n. 4, p. 657–675, 1998.

BOEHMKE, B.; GREENWELL, B. M. **Hands-on machine learning with R**. [S.l.]: CRC Press, 2019. 456 p. ISBN 978-1138495685.

BRASIL. MINISTÉRIO DO MEIO AMBIENTE. Instrução normativa MMA nº 5 de 11 de dezembro de 2006: dispõe sobre procedimentos técnicos para elaboração, apresentação, execução e avaliação técnica de Planos de Manejo Florestal Sustentável - PMFSs nas florestas primitivas e suas formas de sucessão na Amazônia Legal, e dá outras providências. **Diário Oficial da União**, 2006b. Disponível em:

<<https://www.legisweb.com.br/legislacao/?id=76720>>. Acesso em: 4 jul. 2021.

BRASIL. PRESIDÊNCIA DA REPÚBLICA. **Lei nº 11.284, de 2 de março de 2006**: dispõe sobre a gestão de florestas públicas para a produção sustentável; institui, na estrutura do Ministério do Meio Ambiente, o Serviço Florestal Brasileiro - SFB; cria o Fundo Nacional de Desenvolvimento Florestal - FNDF; altera as Leis nºs 10.683, de 28 de maio de 2003, 5.868, de 12 de dezembro de 1972, 9.605, de 12 de fevereiro de 1998, 4.771, de 15 de setembro de 1965, 6.938, de 31 de agosto de 1981, e 6.015, de 31 de dezembro de 1973; e dá

outras providências. Brasília, DF: 2006a. Disponível em:
<http://www.planalto.gov.br/ccivil_03/_Ato2004-2006/2006/Lei/L11284.htm>.
Acesso em: 4 jul. 2021.

BREDE, B.; LAU, A.; BARTHOLOMEUS, H. M.; KOOISTRA, L. Comparing RIEGL RiCOPTER UAV LiDAR derived canopy height and DBH with terrestrial LiDAR. **Sensors**, v. 17, n. 10, 2017.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001.

BROWN, S. Estimating biomass and biomass change of tropical forests: a primer. **FAO Forestry Paper**, v. 134, 1997.

BULLOCK, E. L.; WOODCOCK, C. E.; OLOFSSON, P. Monitoring tropical forest degradation using spectral unmixing and Landsat time series analysis. **Remote Sensing of Environment**, v. 238, e110968, 2020.

BURIVALOVA, Z.; ŞEKERCIOĞLU, Ç. H.; KOH, L. P. Thresholds of logging intensity to maintain tropical forest biodiversity. **Current Biology**, v. 24, n. 16, p. 1893–1898, 2014.

CAMBI, M.; CERTINI, G.; NERI, F.; MARCHI, E. The impact of heavy traffic on forest soils: a review. **Forest Ecology and Management**, v. 338, p. 124–138, 2015.

CAMPBELL, M. J.; DENNISON, P. E.; KERR, K. L.; BREWER, S. C.; ANDEREGG, W. R. L. Scaled biomass estimation in woodland ecosystems: testing the individual and combined capacities of satellite multispectral and lidar data. **Remote Sensing of Environment**, v. 262, e112511, 2021.

CANNELL, M. G. R. Woody biomass of forest stands. **Forest Ecology and Management**, v. 8, n. 3, p. 299–312, 1984.

CANOVA, N. P.; HICKEY, G. M. Understanding the impacts of the 2007–08 global financial crisis on sustainable forest management in the Brazilian Amazon: a case study. **Ecological Economics**, v. 83, p. 19–31, 2012.

CARREIRAS, J. M. B.; JONES, J.; LUCAS, R. M.; GABRIEL, C. Land use and land cover change dynamics across the Brazilian Amazon: insights from extensive time-series analysis of remote sensing data. **PLOS ONE**, v. 9, n. 8, p.

1–24, 2014.

CARREIRAS, J. M. B.; MELO, J. B.; VASCONCELOS, M. J. Estimating the above-ground biomass in Miombo Savanna Woodlands (Mozambique, East Africa) using L-Band Synthetic Aperture Radar data. **Remote Sensing**, v. 5, n. 4, p. 1524–1548, 2013.

CARVALHO, A. L.; D'OLIVEIRA, M. V. N.; PUTZ, F. E.; DE OLIVEIRA, L. C. Natural regeneration of trees in selectively logged forest in western Amazonia. **Forest Ecology and Management**, v. 392, p. 36–44, 2017.

CASSOL, H. L. G.; ARAGÃO, L. E. D. O. E. C.; MORAES, E. C.; CARREIRAS, J. M. D. B.; SHIMABUKURO, Y. E. Quad-pol advanced land observing satellite/phased array L-band synthetic aperture radar-2 (ALOS/PALSAR-2) data for modelling secondary forest above-ground biomass in the central Brazilian Amazon. **International Journal of Remote Sensing**, v. 42, n. 13, p. 4985–5009, 2021.

CASSOL, H. L. G.; CARREIRAS, J. M. DE B.; MORAES, E. C.; ARAGÃO, L. E. O. E. C.; SILVA, C. V. J.; QUEGAN, S.; SHIMABUKURO, Y. E. Retrieving secondary forest aboveground biomass from polarimetric ALOS-2 PALSAR-2 data in the Brazilian Amazon. **Remote Sensing**, v. 11, n. 1, 2019.

CASTRO-ARELLANO, I.; PRESLEY, S. J.; WILLIG, M. R.; WUNDERLE, J. M.; SALDANHA, L. N. Reduced-impact logging and temporal activity of understorey bats in lowland Amazonia. **Biological Conservation**, v. 142, n. 10, p. 2131–2139, 2009.

CHAVE, J.; RÉJOU-MÉCHAIN, M.; BÚRQUEZ, A.; CHIDUMAYO, E.; COLGAN, M. S.; DELITTI, W. B. C.; DUQUE, A.; EID, T.; FEARNSIDE, P. M.; GOODMAN, R. C.; HENRY, M.; MARTÍNEZ-YRÍZAR, A.; MUGASHA, W. A.; MULLER-LANDAU, H. C.; MENCUCCINI, M.; NELSON, B. W.; NGOMANDA, A.; NOGUEIRA, E. M.; ORTIZ-MALAVASSI, E.; PÉLISSIER, R.; PLOTON, P.; RYAN, C. M.; SALDARRIAGA, J. G.; VIEILLEDENT, G. Improved allometric models to estimate the aboveground biomass of tropical trees. **Global Change Biology**, v. 20, n. 10, p. 3177–3190, 2014.

CHAVES, W. A.; SIEVING, K. E.; FLETCHER, R. J. Avian responses to

reduced-impact logging in the southwestern Brazilian Amazon. **Forest Ecology and Management**, v. 384, p. 147–156, 2017.

CLEVERS, J. G. P. W. The derivation of a simplified reflectance model for the estimation of leaf area index. **Remote Sensing of Environment**, v. 25, n. 1, p. 53–69, 1988.

CLEVERS, J. G. P. W. Application of a weighted infrared-red vegetation index for estimating leaf area index by correcting for soil moisture. **Remote Sensing of Environment**, v. 29, n. 1, p. 25–37, 1989.

CLOUDE, S. R. Target decomposition theorems in radar scattering. **Electronics Letters**, v. 21, n. 1, p. 22–24, 1985.

CLOUDE, S. R.; POTTIER, E. A review of target decomposition theorems in radar polarimetry. **IEEE Transactions on Geoscience and Remote Sensing**, v. 34, n. 2, p. 498–518, 1996.

CLOUDE, S. R.; POTTIER, E. An entropy based classification scheme for land applications of polarimetric SAR. **IEEE Transactions on Geoscience and Remote Sensing**, v. 35, n. 1, p. 68–78, 1997.

COCHRANE, M. A.; ALENCAR, A.; SCHULZE, M. D.; SOUZA, C. M.; NEPSTAD, D. C.; LEFEBVRE, P.; DAVIDSON, E. A. Positive feedbacks in the fire dynamic of closed canopy tropical forests. **Science**, v. 284, n. 5421, p. 1832 LP – 1835, 1999.

COCHRANE, M. A.; LAURANCE, W. F. Fire as a large-scale edge effect in Amazonian forests. **Journal of Tropical Ecology**, v. 18, n. 3, p. 311–325, 2002.

COCHRANE, M. A.; SCHULZE, M. D. Fire as a recurrent event in tropical forests of the eastern Amazon: effects on forest structure, biomass, and species composition. **Biotropica**, v. 31, n. 1, p. 2–16, 1999.

CORTE, A. P. D.; SOUZA, D. V.; REX, F. E.; SANQUETTA, C. R.; MOHAN, M.; SILVA, C. A.; ZAMBRANO, A. M. A.; PRATA, G.; ALVES DE ALMEIDA, D. R.; TRAUTENMÜLLER, J. W.; KLAUBERG, C.; DE MORAES, A.; SANQUETTA, M. N.; WILKINSON, B.; BROADBENT, E. N. Forest inventory with high-density UAV-Lidar: machine learning approaches for predicting individual tree

attributes. **Computers and Electronics in Agriculture**, v. 179, e105815, 2020.

CRIPPEN, R. E. Calculating the vegetation index faster. **Remote Sensing of Environment**, v. 34, n. 1, p. 71–73, 1990.

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.

DA SILVA, D. A.; PFEIFER, M.; PATTISON, Z.; VIBRANS, A. C. Drivers of leaf area index variation in Brazilian Subtropical Atlantic Forests. **Forest Ecology and Management**, v. 476, e118477, 2020.

DA SILVA, S. S.; FEARNSTIDE, P. M.; DE ALENCASTRO GRAÇA, P. M. L.; BROWN, I. F.; ALENCAR, A.; DE MELO, A. W. F. Dynamics of forest fires in the southwestern Amazon. **Forest Ecology and Management**, v. 424, p. 312–322, 2018.

DALPONTE, M.; COOMES, D. A. Tree-centric mapping of forest carbon density from airborne laser scanning and hyperspectral data. **Methods in Ecology and Evolution**, v. 7, n. 10, p. 1236–1245, 2016.

DARRIGO, M. R.; VENTICINQUE, E. M.; DOS SANTOS, F. A. M. Effects of reduced impact logging on the forest regeneration in the central Amazonia. **Forest Ecology and Management**, v. 360, p. 52–59, 2016.

DASH, J.; CURRAN, P. J. The MERIS terrestrial chlorophyll index. **International Journal of Remote Sensing**, v. 25, n. 23, p. 5403–5413, 2004.

DAUGHTRY, C. S. T.; WALTHALL, C. L.; KIM, M. S.; DE COLSTOUN, E. B.; MCMURTREY, J. E. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. **Remote Sensing of Environment**, v. 74, n. 2, p. 229–239, 2000.

DEERING, D. W. Measuring forage production of grazing units from Landsat MSS data. In: INTERNATIONAL SYMPOSIUM OF REMOTE SENSING OF THE ENVIRONMENT, 10., 1975. **Proceedings...** 1975. p. 1169–1198.

DELEGIDO, J.; VERRELST, J.; ALONSO, L.; MORENO, J. Evaluation of Sentinel-2 red-edge bands for empirical estimation of green LAI and chlorophyll content. **Sensors**, v. 11, n. 7, p. 7063–7081, 2011.

DORADO-RODA, I.; PASCUAL, A.; GODINHO, S.; SILVA, C. A.; BOTEQUIM, B.; RODRÍGUEZ-GONZÁLVEZ, P.; GONZÁLEZ-FERREIRO, E.; GUERRA-HERNÁNDEZ, J. Assessing the accuracy of GEDI data for canopy height and aboveground biomass estimates in Mediterranean Forests. **Remote Sensing**, v. 13, n. 12, 2021.

DOS-SANTOS, M. N.; KELLER, M. M.; MORTON, D. C. **LiDAR surveys over selected forest research sites, Brazilian Amazon, 2008-2018**. ORNL Distributed Active Archive Center, 2019. Disponível em: <https://daac.ornl.gov/cgi-bin/dsviewer.pl?ds_id=1644>. Acesso em: 4 jul. 2021.

DRUSCH, M.; DEL BELLO, U.; CARLIER, S.; COLIN, O.; FERNANDEZ, V.; GASCON, F.; HOERSCH, B.; ISOLA, C.; LABERINTI, P.; MARTIMORT, P.; MEYGRET, A.; SPOTO, F.; SY, O.; MARCHESE, F.; BARGELLINI, P. Sentinel-2: ESA's optical high-resolution mission for GMES operational services. **Remote Sensing of Environment**, v. 120, p. 25–36, 2012.

ELLIS, P.; GRISCOM, B.; WALKER, W.; GONÇALVES, F.; CORMIER, T. Mapping selective logging impacts in Borneo with GPS and airborne lidar. **Forest Ecology and Management**, v. 365, p. 184–196, 2016.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA). **WebGIS paisagens sustentáveis Brasil**. 2020. Disponível em: <<https://www.paisagenslidar.cnptia.embrapa.br/webgis/>>. Acesso em: 3 mar. 2020.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA). **Sistema de análise temporal da vegetação**. 2021. Disponível em: <<https://www.satveg.cnptia.embrapa.br/satveg/login.html>>. Acesso em: 5 jun. 2021.

EUROPEAN SPACE AGENCY (ESA). **Sentinel-2 MSI introduction**. 2020. Disponível em: <<https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi>>. Acesso em: 10 fev. 2020.

- FEARNSIDE, P. M. Wood density for estimating forest biomass in Brazilian Amazonia. **Forest Ecology and Management**, v. 90, n. 1, p. 59–87, 1997.
- FORMAGGIO, A. R.; SANCHES, I. D. **Sensoriamento remoto em agricultura**. [S.l.]: Oficina de Textos, 2017. 288 p.
- FRAMPTON, W. J.; DASH, J.; WATMOUGH, G.; MILTON, E. J. Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 82, p. 83–92, 2013.
- FRANÇA, F.; LOUZADA, J.; KORASAKI, V.; GRIFFITHS, H.; SILVEIRA, J. M.; BARLOW, J. Do space-for-time assessments underestimate the impacts of logging on tropical biodiversity? An Amazonian case study using dung beetles. **Journal of Applied Ecology**, v. 53, n. 4, p. 1098–1105, 2016.
- FRANCESCHETTI, G.; LANARI, R. **Synthetic aperture radar processing**. [S.l.]: CRC Press, 1999. 324 p.
- FREEMAN, A. Fitting a two-component scattering model to polarimetric SAR data from forests. **IEEE Transactions on Geoscience and Remote Sensing**, v. 45, n. 8, p. 2583–2592, 2007.
- FREEMAN, A.; DURDEN, S. L. A three-component scattering model for polarimetric SAR data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 36, n. 3, p. 963–973, 1998.
- GAO, B. NDWI: a normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v. 58, n. 3, p. 257–266, 1996.
- GEDI ECOSYSTEM LIDAR. **Global ecosystem dynamics investigation**. 2018. Disponível em: <<https://gedi.umd.edu/>>. Acesso em: 19 fev. 2020.
- GHOSH, S. M.; BEHERA, M. D. Aboveground biomass estimation using multi-sensor data synergy and machine learning algorithms in a dense tropical forest. **Applied Geography**, v. 96, p. 29–40, 2018.
- GITELSON, A. A.; GRITZ, Y.; MERZLYAK, M. N. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive

chlorophyll assessment in higher plant leaves. **Journal of Plant Physiology**, v. 160, n. 3, p. 271–282, 2003.

GITELSON, A. A.; KAUFMAN, Y. J. MODIS NDVI Optimization to fit the AVHRR data series: spectral considerations. **Remote Sensing of Environment**, v. 66, n. 3, p. 343–350, 1998.

GITELSON, A.; MERZLYAK, M. N. Quantitative estimation of chlorophyll-a using reflectance spectra: experiments with autumn chestnut and maple leaves. **Journal of Photochemistry and Photobiology B: Biology**, v. 22, n. 3, p. 247–252, 1994.

GONÇALVES, F. G.; SANTOS, J. R. Composição florística e estrutura de uma unidade de manejo florestal sustentável na Floresta Nacional do Tapajós, Pará. **Acta Amazonica**, v. 38, n. 2, p. 229–244, 2008.

GONÇALVES, F. G.; SANTOS, J. R.; TREUHAF, R. N. Stem volume of tropical forests from polarimetric radar. **International Journal of Remote Sensing**, v. 32, n. 2, p. 503–522, 2011.

GUYOT, G.; BARET, F. Utilisation de la haute resolution spectrale pour suivre l'état des couverts vegetaux. In: INTERNATIONAL COLLOQUIUM ON SPECTRAL SIGNATURES OF OBJECTS IN REMOTE SENSING, 4., 1988. **Proceedings...** 1988.

HARDISKY, M. A.; KLEMAS, V.; SMART, M. The influence of soil salinity, growth form, and leaf moisture on the spectral radiance of partina alterniflora canopies. **Photogrammetric Engineering and Remote Sensing**, v. 49, n. 1, p. 77–83, 1983.

HARRIS, N. L.; BROWN, S.; HAGEN, S. C.; SAATCHI, S. S.; PETROVA, S.; SALAS, W.; HANSEN, M. C.; POTAPOV, P. V.; LOTSCH, A. Baseline map of carbon emissions from deforestation in tropical regions. **Science**, v. 336, n. 6088, p. 1573–1576, 2012.

HAWTHORNE, W. D.; SHEIL, D.; AGYEMAN, V. K.; ABU JUAM, M.; MARSHALL, C. A. M. Logging scars in Ghanaian high forest: towards improved models for sustainable production. **Forest Ecology and Management**, v. 271, p. 27–36, 2012.

HENDERSON, F. M.; LEWIS, A. J. **Manual of remote sensing**: principles and applications of imaging radar. 3.ed. New York: John Wiley & Sons, 1998. 896 p. ISBN 978-0471294061.

HERITAGE, G.; LARGE, A. **Laser scanning for the environmental sciences**. [S.I.]: John Wiley & Sons, 2009. 288 p.

HERRERÍAS-DIEGO, Y.; QUESADA, M.; STONER, K. E.; LOBO, J. A.; HERNÁNDEZ-FLORES, Y.; SANCHEZ MONTOYA, G. Effect of forest fragmentation on fruit and seed predation of the tropical dry forest tree *Ceiba aesculifolia*. **Biological Conservation**, v. 141, n. 1, p. 241–248, 2008.

HICKEY, G. M. Evaluating sustainable forest management. **Ecological Indicators**, v. 8, n. 2, p. 109–114, 2008.

HOPKINSON, C.; CHASMER, L.; GYNAN, C.; MAHONEY, C.; SITAR, M. Multisensor and multispectral LiDAR characterization and classification of a forest environment. **Canadian Journal of Remote Sensing**, v. 42, n. 5, p. 501–520, 2016.

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

HUETE, A. R.; LIU, H. Q.; BATCHILY, K.; VAN LEEUWEN, W. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, v. 59, n. 3, p. 440–451, 1997.

HYDE, P.; NELSON, R.; KIMES, D.; LEVINE, E. Exploring LiDAR–RaDAR synergy: predicting aboveground biomass in a southwestern ponderosa pine forest using LiDAR, SAR and InSAR. **Remote Sensing of Environment**, v. 106, n. 1, p. 28–38, 2007.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Mapa esquemático de solos do Estado do Pará**. 2008. Disponível em: <<https://mapas.ibge.gov.br/tematicos/solos>>. Acesso em: 19 fev. 2020.

INSTITUTO CHICO MENDES DE CONSERVAÇÃO E BIODIVERSIDADE (ICMBIO). **Plano de manejo da Floresta Nacional do Tapajós**. 2019.

Disponível em:

<<http://www.icmbio.gov.br/portal/unidadesdeconservacao/biomas->

brasileiros/amazonia/unidades-de-conservacao-amazonia/1963-flona-do-tapajos>. Acesso em: 26 fev. 2020.

INSTITUTO NACIONAL DE METEOROLOGIA (INMET). **Chuva acumulada 24h**. Brasília: INMET, 2021. Disponível em: <<https://bdmep.inmet.gov.br/>>. Acesso em: 20 jan. 2021.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Monitoramento da cobertura florestal da Amazônia por satélites: sistemas PRODES, DETER, DEGRAD e QUEIMADAS 2007-2008**. 2008. Disponível em: <<http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/deter>>. Acesso em: 8 mar. 2020.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Melhoria dos métodos de estimativa de biomassa e de modelos de estimativa de emissões por mudança de uso da terra**. 2018. Disponível em: <<http://www.ccst.inpe.br/projetos/eba-estimativa-de-biomassa-na-amazonia/>>. Acesso em: 6 fev. 2020.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Monitoramento do desmatamento da Floresta Amazônica Brasileira por satélite**. 2019. Disponível em: <<http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/prodes>>. Acesso em: 10 mar. 2020.

JAPAN AEROSPACE EXPLORATION AGENCY (JAXA). **ALOS-2 project: PALSAR-2**. 2014. Disponível em: <<https://www.eorc.jaxa.jp/ALOS-2/en/about/palsar2.htm>>. Acesso em: 4 fev. 2020.

JOSHI, N.; MITCHARD, E. T. A.; BROLLY, M.; SCHUMACHER, J.; FERNÁNDEZ-LANDA, A.; JOHANNSEN, V. K.; MARCHAMALO, M.; FENSHOLT, R. Understanding 'saturation' of radar signals over forests. **Scientific Reports**, v. 7, n. 1, e3505, 2017.

KARLSON, M.; OSTWALD, M.; REESE, H.; SANOU, J.; TANKOANO, B.; MATTSSON, E. Mapping tree canopy cover and aboveground biomass in Sudano-Sahelian Woodlands using Landsat 8 and Random Forest. **Remote Sensing**, v. 7, n. 8, p. 10017–10041, 2015.

KAUFMAN, Y.; TANRE, D. Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. **IEEE Transactions on Geoscience and Remote Sensing**, v. 30, n. 2, p. 260–271, 1992.

KILLMANN, W.; GIBBS, H. K.; ACHARD, F.; DEFRIES, R.; FOLEY, J. A.; HOUGHTON, R. A. **Proceedings**: expert meeting on harmonizing forest-related definitions for use by various stakeholders. Rome: FAO, 2002.

KIM, Y.; VAN ZYL, J. J. A time-series approach to estimate soil moisture using polarimetric radar data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 8, p. 2519–2527, 2009.

KLEINSCHROTH, F.; HEALEY, J. R. Impacts of logging roads on tropical forests. **Biotropica**, v. 49, n. 5, p. 620–635, 2017.

KORHONEN, L.; KORPELA, I.; HEISKANEN, J.; MALTAMO, M. Airborne discrete-return LIDAR data in the estimation of vertical canopy cover, angular canopy closure and leaf area index. **Remote Sensing of Environment**, v. 115, n. 4, p. 1065–1080, 2011.

KROGAGER, E.; BOERNER, W.-M.; MADSEN, S. N. Feature-motivated Sinclair matrix (sphere/diplane/helix) decomposition and its application to target sorting for land feature classification. In: MOTT, H.; BOERNER, M. (Ed.). **Wideband interferometric sensing and imaging polarimetry**. [S.l.]: SPIE, 1997.

KUPLICH, T. M.; SHIMABUKURO, Y. E.; SERVELLO, E.; SANO, E. Polarimetric signatures and classification of tropical land covers. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2009. **Proceedings...** IEEE, 2009.

KURSA, M. B.; RUDNICKI, W. R. Feature selection with the Boruta package. **Journal of Statistical Software**, v. 36, n. 11, p. 1–13, 2010.

LAING, T.; TASCHINI, L.; PALMER, C. Understanding the demand for REDD+ credits. **Environmental Conservation**, v. 43, n. 4, p. 389–396, 2016.

LACERDA, A. E. B.; KANASHIRO, M.; SEBBENN, A. M. Effects of reduced impact logging on genetic diversity and spatial genetic structure of a *Hymenaea courbaril* population in the Brazilian Amazon Forest. **Forest Ecology and**

Management, v. 255, n. 3, p. 1034–1043, 2008.

LAURANCE, W. F.; LAURANCE, S. G.; FERREIRA, L. V; RANKIN-DE MERONA, J. M.; GASCON, C.; LOVEJOY, T. E. Biomass collapse in Amazonian Forest fragments. **Science**, v. 278, n. 5340, p. 1117 LP – 1118, 1997.

LAURANCE, W. F.; WILLIAMSON, G. B. Positive feedbacks among forest fragmentation, drought, and climate change in the Amazon. **Conservation Biology**, v. 15, n. 6, p. 1529–1535, 2001.

LAVALLE, M.; WRIGHT, T. **Absolute radiometric and polarimetric calibration of ALOS PALSAR products**. 2009. Disponível em: <<https://earth.esa.int/eogateway/documents/20142/37627/ALOS-PALSAR-calibration-products-ADEN.pdf>>. Acesso em: 28 maio 2021.

LEAN, J.; WARRILOW, D. A. Simulation of the regional climatic impact of Amazon deforestation. **Nature**, v. 342, n. 6248, p. 411–413, 1989.

LEE, J.-S.; POTTIER, E. **Polarimetric radar imaging: from basics to applications**. [S.l.]: CRC Press, 2017.

LEFSKY, M. A.; COHEN, W. B.; PARKER, G. G.; HARDING, D. J. Lidar remote sensing for ecosystem studies: Lidar, an emerging remote sensing technology that directly measures the three-dimensional distribution of plant canopies, can accurately estimate vegetation structural attributes and should be of particular inte. **BioScience**, v. 52, n. 1, p. 19–30, 2002.

LEI, Y.; LUCAS, R.; SIQUEIRA, P.; SCHMIDT, M.; TREUHAFT, R. Detection of forest disturbance with spaceborne repeat-pass SAR interferometry. **IEEE Transactions on Geoscience and Remote Sensing**, v. 56, n. 4, p. 2424–2439, 2018.

LI, X.; DU, H.; MAO, F.; ZHOU, G.; CHEN, L.; XING, L.; FAN, W.; XU, X.; LIU, Y.; CUI, L.; LI, Y.; ZHU, D.; LIU, T. Estimating bamboo forest aboveground biomass using EnKF-assimilated MODIS LAI spatiotemporal data and machine learning algorithms. **Agricultural and Forest Meteorology**, v. 256/257, p. 445–457, 2018.

LIESENBERG, V.; DE SOUZA FILHO, C. R.; GLOAGUEN, R. Evaluating

moisture and geometry effects on L-Band SAR classification performance over a tropical rain forest environment. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 9, n. 12, p. 5357–5368, 2016.

LIU, J.; PATTEY, E.; JÉGO, G. Assessment of vegetation indices for regional crop green LAI estimation from Landsat images over multiple growing seasons. **Remote Sensing of Environment**, v. 123, p. 347–358, 2012.

LOVELOCK, J. E.; MARGULIS, L. Atmospheric homeostasis by and for the biosphere: the gaia hypothesis. **Tellus**, v. 26, n. 1–2, p. 2–10, 1974.

LU, D.; CHEN, Q.; WANG, G.; LIU, L.; LI, G.; MORAN, E. A survey of remote sensing-based aboveground biomass estimation methods in forest ecosystems. **International Journal of Digital Earth**, v. 9, n. 1, p. 63–105, 2016.

MALHI, Y.; ROBERTS, J. T.; BETTS, R. A.; KILLEEN, T. J.; LI, W.; NOBRE, C. A. Climate change, deforestation, and the fate of the Amazon. **Science**, v. 319, n. 5860, p. 169 LP – 172, 2008.

MARTINS-NETO, R. P.; TOMMASELLI, A. M. G.; IMAI, N. N.; DAVID, H. C.; MILTIADOU, M.; HONKAVAARA, E. Identification of significant LiDAR metrics and comparison of machine learning approaches for estimating stand and diversity variables in heterogeneous Brazilian Atlantic Forest. **Remote Sensing**, v. 13, n. 13, 2021.

MERZLYAK, M. N.; GITELSON, A. A.; CHIVKUNOVA, O. B.; RAKITIN, V. Y. U. Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening. **Physiologia plantarum**, v. 106, n. 1, p. 135–141, 1999.

MITCHARD, E. T. A.; SAATCHI, S. S.; LEWIS, S. L.; FELDPAUSCH, T. R.; WOODHOUSE, I. H.; SONKÉ, B.; ROWLAND, C.; MEIR, P. Measuring biomass changes due to woody encroachment and deforestation/degradation in a forest–savanna boundary region of central Africa using multi-temporal L-band radar backscatter. **Remote Sensing of Environment**, v. 115, n. 11, p. 2861–2873, 2011.

MITCHARD, E. T. A.; SAATCHI, S. S.; WHITE, L. J. T.; ABERNETHY, K. A.; JEFFERY, K. J.; LEWIS, S. L.; COLLINS, M.; LEFSKY, M. A.; LEAL, M. E.;

WOODHOUSE, I. H.; MEIR, P. Mapping tropical forest biomass with radar and spaceborne LiDAR in Lopé National Park, Gabon: overcoming problems of high biomass and persistent cloud. **Biogeosciences**, v. 9, n. 1, p. 179–191, 2012.

MITCHARD, E. T. A.; SAATCHI, S. S.; WOODHOUSE, I. H.; NANGENDO, G.; RIBEIRO, N. S.; WILLIAMS, M.; RYAN, C. M.; LEWIS, S. L.; FELDPAUSCH, T. R.; MEIR, P. Using satellite radar backscatter to predict above-ground woody biomass: a consistent relationship across four different African landscapes. **Geophysical Research Letters**, v. 36, n. 23, 2009.

MORAN, E. F. Deforestation and land use in the Brazilian Amazon. **Human Ecology**, v. 21, n. 1, p. 1–21, 1993.

NARVAES, I. S.; DOS SANTOS, J. R.; DA SILVA, A. D. Q. Analysis of structural parameters of forest typologies using L-band SAR data. **Boletim de Ciências Geodésicas**, v. 16, n. 3, p. 475–489, 2010.

NEPSTAD, D. C.; VERSSIMO, A.; ALENCAR, A.; NOBRE, C.; LIMA, E.; LEFEBVRE, P.; SCHLESINGER, P.; POTTER, C.; MOUTINHO, P.; MENDOZA, E.; COCHRANE, M.; BROOKS, V. Large-scale impoverishment of Amazonian forests by logging and fire. **Nature**, v. 398, n. 6727, p. 505–508, 1999.

NUMATA, I.; SILVA, S. S.; COCHRANE, M. A.; D'OLIVEIRA, M. V. N. Fire and edge effects in a fragmented tropical forest landscape in the southwestern Amazon. **Forest Ecology and Management**, v. 401, p. 135–146, 2017.

NUMAZAWA, C. T. D.; NUMAZAWA, S.; PACCA, S.; JOHN, V. M. Logging residues and CO₂ of Brazilian Amazon timber: two case studies of forest harvesting. **Resources, Conservation and Recycling**, v. 122, p. 280–285, 2017.

PAN, Y.; BIRDSEY, R. A.; FANG, J.; HOUGHTON, R.; KAUPPI, P. E.; KURZ, W. A.; PHILLIPS, O. L.; SHVIDENKO, A.; LEWIS, S. L.; CANADELL, J. G.; CIAIS, P.; JACKSON, R. B.; PACALA, S. W.; MCGUIRE, A. D.; PIAO, S.; RAUTIAINEN, A.; SITCH, S.; HAYES, D. A Large and persistent carbon sink in the world's forests. **Science**, v. 333, n. 6045, p. 988–993, 2011.

PANDIT, S.; TSUYUKI, S.; DUBE, T. Estimating above-ground biomass in sub-

tropical Buffer Zone Community Forests, Nepal, using Sentinel 2 data. **Remote Sensing**, v. 10, n. 4, 2018.

PARK, A.; JOAQUIN JUSTINIANO, M.; FREDERICKSEN, T. S. Natural regeneration and environmental relationships of tree species in logging gaps in a Bolivian tropical forest. **Forest Ecology and Management**, v. 217, n. 2, p. 147–157, 2005.

PENMAN, J.; GYTARSKY, M.; HIRAISHI, T.; KRUG, T.; KRUGER, D.; PIPATTI, R.; BUENDIA, L.; MIWA, K.; NGARA, T.; TANABE, K.; OTHERS. **Definitions and methodological options to inventory emissions from direct human-induced degradation of forests and devegetation of other vegetation types**. [S.I.]: IPCC, 2003.

PEREIRA, L. O.; FURTADO, L. F. A.; NOVO, E. M. L. M.; SANT'ANNA, S. J. S.; LIESENBERG, V.; SILVA, T. S. F. Multifrequency and full-polarimetric SAR assessment for estimating above ground biomass and leaf area index in the Amazon várzea wetlands. **Remote Sensing**, v. 10, n. 9, 2018.

PERES, C. A. Synergistic effects of subsistence hunting and habitat fragmentation on Amazonian Forest vertebrates. **Conservation Biology**, v. 15, n. 6, p. 1490–1505, 2001

PINTY, B.; VERSTRAETE, M. M. GEMI: a non-linear index to monitor global vegetation from satellites. **Vegetatio**, v. 101, n. 1, p. 15–20, 1992.

POPE, K. O.; REY-BENAYAS, J. M.; PARIS, J. F. Radar remote sensing of forest and wetland ecosystems in the Central American tropics. **Remote Sensing of Environment**, v. 48, n. 2, p. 205–219, 1994.

PUTZ, F. E.; REDFORD, K. H. The importance of defining 'Forest': tropical forest degradation, deforestation, long-term phase shifts, and further transitions. **Biotropica**, v. 42, n. 1, p. 10–20, 2010.

PUTZ, F. E.; ZUIDEMA, P. A.; SYNNOTT, T.; PEÑA-CLAROS, M.; PINARD, M. A.; SHEIL, D.; VANCLAY, J. K.; SIST, P.; GOURLET-FLEURY, S.; GRISCOM, B.; PALMER, J.; ZAGT, R. Sustaining conservation values in selectively logged tropical forests: the attained and the attainable. **Conservation Letters**, v. 5, n. 4, p. 296–303, 2012.

- QI, J.; CHEHBOUNI, A.; HUETE, A. R.; KERR, Y. H.; SOROOSHIAN, S. A modified soil adjusted vegetation index. **Remote Sensing of Environment**, v. 48, n. 2, p. 119–126, 1994.
- QI, W.; DUBAYAH, R. O. Combining Tandem-X InSAR and simulated GEDI lidar observations for forest structure mapping. **Remote Sensing of Environment**, v. 187, p. 253–266, 2016.
- R CORE TEAM. **R: a language and environment for statistical computing**. Vienna, Austria, 2021. Disponível em: <<https://www.r-project.org/>>. Acesso em: 27 jul. 2021.
- RAMANKUTTY, N.; GIBBS, H. K.; ACHARD, F.; DEFRIES, R.; FOLEY, J. A.; HOUGHTON, R. A. Challenges to estimating carbon emissions from tropical deforestation. **Global Change Biology**, v. 13, n. 1, p. 51–66, 2007.
- RANGEL PINAGÉ, E.; KELLER, M.; DUFFY, P.; LONGO, M.; DOS-SANTOS, M. N.; MORTON, D. C. Long-term impacts of selective logging on Amazon Forest dynamics from multi-temporal airborne LiDAR. **Remote Sensing**, v. 11, n. 6, 2019.
- REX, F. E.; SILVA, C. A.; DALLA CORTE, A. P.; KLAUBERG, C.; MOHAN, M.; CARDIL, A.; SILVA, V. S.; ALMEIDA, D. R. A.; GARCIA, M.; BROADBENT, E. N.; VALBUENA, R.; STODDART, J.; MERRICK, T.; HUDAK, A. T. Comparison of statistical modelling approaches for estimating tropical forest aboveground biomass stock and reporting their changes in low-intensity logging areas using multi-temporal LiDAR data. **Remote Sensing**, v. 12, n. 9, 2020.
- RICHARDS, J. A. **Remote sensing with imaging radar**. [S.l.]: Springer, 2009. v. 1
- RICHARDSON, A. J.; WIEGAND, C. L. Distinguishing vegetation from soil background information. **Photogrammetric Engineering and Remote Sensing**, v. 43, n. 12, p. 1541–1552, 1977.
- RIGNOT, E.; WAY, J. B.; MCDONALD, K.; VIERECK, L.; WILLIAMS, C.; ADAMS, P.; PAYNE, C.; WOOD, W.; SHI, J. Monitoring of environmental conditions in Taiga forests using ERS-1 SAR. **Remote Sensing of Environment**, v. 49, n. 2, p. 145–154, 1994.

- ROMERO-SANCHEZ, M. E.; PONCE-HERNANDEZ, R. Assessing and monitoring forest degradation in a Deciduous Tropical Forest in Mexico via remote sensing indicators. **Forests**, v. 8, n. 9, 2017.
- ROS-TONEN, M. A. F.; VAN ANDEL, T.; MORSELLO, C.; OTSUKI, K.; ROSENDO, S.; SCHOLZ, I. Forest-related partnerships in Brazilian Amazonia: there is more to sustainable forest management than reduced impact logging. **Forest Ecology and Management**, v. 256, n. 7, p. 1482–1497, 2008.
- ROSENFELD, D. TRMM observed first direct evidence of smoke from forest fires inhibiting rainfall. **Geophysical Research Letters**, v. 26, n. 20, p. 3105–3108, 1999.
- ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. In: ERTS SYMPOSIUM, 3., 1973. **Proceedings...** 1973. v. 1, p. 309–317.
- ROUSSEL, J.-R.; AUTY, D.; COOPS, N. C.; TOMPALSKI, P.; GOODBODY, T. R. H.; MEADOR, A. S.; BOURDON, J.-F.; DE BOISSIEU, F.; ACHIM, A. lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. **Remote Sensing of Environment**, v. 251, e112061, 2020.
- SANTOS, E. G.; SHIMABUKURO, Y. E.; MOURA, Y. M.; GONÇALVES, F. G.; JORGE, A.; GASPARINI, K. A.; ARAI, E.; DUARTE, V.; OMETTO, J. P. 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.
- SASAKI, N.; ASNER, G. P.; PAN, Y.; KNORR, W.; DURST, P. B.; MA, H. O.; ABE, I.; LOWE, A. J.; KOH, L. P.; PUTZ, F. E. Sustainable management of tropical forests can reduce carbon emissions and stabilize timber production. **Frontiers in Environmental Science**, v. 4, p. 50, 2016.
- SAUER, S. Soy expansion into the agricultural frontiers of the Brazilian Amazon: the agribusiness economy and its social and environmental conflicts. **Land Use Policy**, v. 79, p. 326–338, 2018.
- SCHULZE, M.; GROGAN, J.; UHL, C.; LENTINI, M.; VIDAL, E. Evaluating ipê (Tabebuia, Bignoniaceae) logging in Amazonia: sustainable management or

catalyst for forest degradation? **Biological Conservation**, v. 141, n. 8, p. 2071–2085, 2008.

SHAN, J.; TOTH, C. K. **Topographic laser ranging and scanning: principles and processing**. [S.l.]: CRC Press, 2008. 654 p.

SHERIDAN, R. D.; POPESCU, S. C.; GATZIOLIS, D.; MORGAN, C. L. S.; KU, N.-W. 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, 2015.

SHIMABUKURO, Y. E.; ARAI, E.; DUARTE, V.; DUTRA, A. C. Assessment of land use land cover in Brazil, South America, using fraction images derived from Proba-V Datasets. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), 2019a. **Proceedings... IEEE**, 2019.

SHIMABUKURO, Y. E.; ARAI, E.; DUARTE, V.; JORGE, A.; DOS SANTOS, E. G.; GASPARINI, K. A. C.; DUTRA, A. C. Monitoring deforestation and forest degradation using multi-temporal fraction images derived from Landsat sensor data in the Brazilian Amazon. **International Journal of Remote Sensing**, v. 40, n. 14, p. 5475–5496, 2019b.

SHIMABUKURO, Y. E.; BEUCHLE, R.; GRECCHI, R. C.; ACHARD, F. Assessment of forest degradation in Brazilian Amazon due to selective logging and fires using time series of fraction images derived from Landsat ETM+ images. **Remote Sensing Letters**, v. 5, n. 9, p. 773–782, 2014.

SHIMABUKURO, Y. E.; DUTRA, A. C.; ARAI, E.; DUARTE, V.; CASSOL, H. L. G.; PEREIRA, G.; CARDOZO, F. DA S. Mapping burned areas of Mato Grosso State Brazilian Amazon using Multisensor datasets. **Remote Sensing**, v. 12, n. 22, 2020.

SHIMABUKURO, Y. E.; PONZONI, F. J. **Spectral mixture for remote sensing: linear model and applications**. [S.l.]: Springer, 2018. 80 p.

SHIMABUKURO, Y. E.; SMITH, J. A. The least-squares mixing models to generate fraction images derived from remote sensing multispectral data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 29, n. 1, p. 16–20,

1991.

SILVA, C. A.; HAMAMURA, C.; VALBUENA, R.; HANCOCK, S.; CARDIL, A.; BROADBENT EBEN, N.; ALMEIDA DANILO, R. A.; SILVA JUNIOR, C. H. L.; KLAUBERG, C. **rGEDI**: an R package for NASA's Global Ecosystem Dynamics Investigation (GEDI) data visualizing and processing. 2020. Disponível em: <<https://github.com/carlos-alberto-silva/rGEDI/blob/master/README.md>>. Acesso em: 16 mar. 2020.

SILVA, C. V. J.; SANTOS, J. R.; GALVAO, L. S.; SILVA, R. D.; MOURA, Y. M. Floristic and structure of an Amazonian primary forest and a chronosequence of secondary succession. **Acta Amazonica**, v. 46, n. 2, p. 133–150, 2016.

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

SILVÉRIO, D. V.; BRANDO, P. M.; BUSTAMANTE, M. M. C.; PUTZ, F. E.; MARRA, D. M.; LEVICK, S. R.; TRUMBORE, S. E. Fire, fragmentation, and windstorms: a recipe for tropical forest degradation. **Journal of Ecology**, v. 107, n. 2, p. 656–667, 2019.

SINHA, S.; JEGANATHAN, C.; SHARMA, L. K.; NATHAWAT, M. S. A review of radar remote sensing for biomass estimation. **International Journal of Environmental Science and Technology**, v. 12, n. 5, p. 1779–1792, 2015.

SIST, P. Reduced-impact logging in the tropics: objectives, principles and impacts. **The International Forestry Review**, p. 3–10, 2000.

SKOLE, D.; TUCKER, C. Tropical deforestation and habitat fragmentation in the Amazon: satellite data from 1978 to 1988. **Science**, v. 260, n. 5116, p. 1905 LP – 1910, 1993.

STOFFELS, A.; SOEST, J. V. The main problems in sample plots. **Ned Bosbouwtijschr**, v. 25, p. 190–199, 1953.

SULLIVAN, F. B.; DUCEY, M. J.; ORWIG, D. A.; COOK, B.; PALACE, M. W.

Comparison of lidar- and allometry-derived canopy height models in an eastern deciduous forest. **Forest Ecology and Management**, v. 406, p. 83–94, 2017.

SULLIVAN, M. J. P.; LEWIS, S. L.; HUBAU, W.; QIE, L.; BAKER, T. R.; BANIN, L. F.; CHAVE, J.; CUNI-SANCHEZ, A.; FELDPAUSCH, T. R.; LOPEZ-GONZALEZ, G.; ARETS, E.; ASHTON, P.; BASTIN, J.-F.; BERRY, N. J.; BOGAERT, J.; BOOT, R.; BREARLEY, F. Q.; BRIENEN, R.; BURSLEM, D. F. R. P.; DE CANNIERE, C.; CHUDOMELOVÁ, M.; DANČÁK, M.; EWANGO, C.; HÉDL, R.; LLOYD, J.; MAKANA, J.-R.; MALHI, Y.; MARIMON, B. S.; JUNIOR, B. H. M.; METALI, F.; MOORE, S.; NAGY, L.; VARGAS, P. N.; PENDRY, C. A.; RAMÍREZ-ANGULO, H.; REITSMA, J.; RUTISHAUSER, E.; SALIM, K. A.; SONKÉ, B.; SUKRI, R. S.; SUNDERLAND, T.; SVÁTEK, M.; UMUNAY, P. M.; MARTINEZ, R. V.; VERNIMMEN, R. R. E.; TORRE, E. V.; VLEMINCKX, J.; VOS, V.; PHILLIPS, O. L. Field methods for sampling tree height for tropical forest biomass estimation. **Methods in Ecology and Evolution**, v. 9, n. 5, p. 1179–1189, 2018.

TANG, H.; DUBAYAH, R.; SWATANTRAN, A.; HOFTON, M.; SHELDON, S.; CLARK, D. B.; BLAIR, B. Retrieval of vertical LAI profiles over tropical rain forests using waveform lidar at La Selva, Costa Rica. **Remote Sensing of Environment**, v. 124, p. 242–250, 2012.

TAPIA-ARMIJOS, M. F.; HOMEIER, J.; ESPINOSA, C. I.; LEUSCHNER, C.; DE LA CRUZ, M. Deforestation and forest fragmentation in South Ecuador since the 1970s: losing a hotspot of biodiversity. **PLOS ONE**, v. 10, n. 9, p. 1–18, 2015.

TIAN, H.; LU, C.; CIAIS, P.; MICHALAK, A. M.; CANADELL, J. G.; SAIKAWA, E.; HUNTZINGER, D. N.; GURNEY, K. R.; SITCH, S.; ZHANG, B.; YANG, J.; BOUSQUET, P.; BRUHWILER, L.; CHEN, G.; DLUGOKENCKY, E.; FRIEDLINGSTEIN, P.; MELILLO, J.; PAN, S.; POULTER, B.; PRINN, R.; SAUNOIS, M.; SCHWALM, C. R.; WOFESY, S. C. The terrestrial biosphere as a net source of greenhouse gases to the atmosphere. **Nature**, v. 531, n. 7593, p. 225–228, 2016.

TOUZI, R. Target scattering decomposition in terms of roll-invariant target parameters. **IEEE Transactions on Geoscience and Remote Sensing**, v. 45,

n. 1, p. 73–84, 2007.

TREUHAFT, R.; LEI, Y.; GONÇALVES, F.; KELLER, M.; SANTOS, J. R.; NEUMANN, M.; ALMEIDA, A. Tropical-forest structure and biomass dynamics from TanDEM-X radar interferometry. **Forests**, v. 8, n. 8, 2017.

TSUI, O. W.; COOPS, N. C.; WULDER, M. A.; MARSHALL, P. L. Integrating airborne LiDAR and space-borne radar via multivariate kriging to estimate above-ground biomass. **Remote Sensing of Environment**, v. 139, p. 340–352, 2013.

TSUI, O. W.; COOPS, N. C.; WULDER, M. A.; MARSHALL, P. L.; MCCARDLE, A. Using multi-frequency radar and discrete-return LiDAR measurements to estimate above-ground biomass and biomass components in a coastal temperate forest. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 69, p. 121–133, 2012.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127–150, 1979.

VAN ZYL, J. J.; ARII, M.; KIM, Y. Model-based decomposition of polarimetric SAR covariance matrices constrained for nonnegative eigenvalues. **IEEE Transactions on Geoscience and Remote Sensing**, v. 49, n. 9, p. 3452–3459, 2011.

VÉGA, C.; RENAUD, J.-P.; DURRIEU, S.; BOUVIER, M. On the interest of penetration depth, canopy area and volume metrics to improve Lidar-based models of forest parameters. **Remote Sensing of Environment**, v. 175, p. 32–42, 2016.

VELOSO, H. P.; RANGEL-FILHO, A. L. R.; LIMA, J. C. A. **Classificação da vegetação brasileira, adaptada a um sistema universal**. Rio de Janeiro: IBGE, 1991. 124 p. ISBN 85-240-0384-7.

VIDAL, E.; WEST, T. A. P.; PUTZ, F. E. Recovery of biomass and merchantable timber volumes twenty years after conventional and reduced-impact logging in Amazonian Brazil. **Forest Ecology and Management**, v. 376, p. 1–8, 2016.

VIEIRA, S.; DE CAMARGO, P. B.; SELHORST, D.; DA SILVA, R.; HUTYRA, L.; CHAMBERS, J. Q.; BROWN, I. F.; HIGUCHI, N.; DOS SANTOS, J.; WOFSY, S. C.; TRUMBORE, S. E.; MARTINELLI, L. A. Forest structure and carbon dynamics in Amazonian tropical rain forests. **Oecologia**, v. 140, n. 3, p. 468–479, 2004.

VILLARD, L.; LE TOAN, T.; HO TONG MINH, D.; MERMOZ, S.; BOUVET, A. Forest biomass from radar remote sensing. In: BAGHDADI, N.; ZRIBI, M. (Ed.). **Land surface remote sensing in agriculture and forest**. [S.l.]: Elsevier, 2016. p. 363–425.

WANG, S.; WILSON, B. Pluralism in the economics of sustainable forest management. **Forest Policy and Economics**, v. 9, n. 7, p. 743–750, 2007.

WANG, Y.; KASISCHKE, E. S.; MELACK, J. M.; DAVIS, F. W.; CHRISTENSEN, N. L. The effects of changes in loblolly pine biomass and soil moisture on ERS-1 SAR backscatter. **Remote Sensing of Environment**, v. 49, n. 1, p. 25–31, 1994.

WEST, T. A. P.; VIDAL, E.; PUTZ, F. E. Forest biomass recovery after conventional and reduced-impact logging in Amazonian Brazil. **Forest Ecology and Management**, v. 314, p. 59–63, 2014.

WIEDERKEHR, N. C.; GAMA, F. F.; MURA, J. C.; SANTOS, J. R.; BISPO, P. DA C.; SANO, E. E. Analysis of the target decomposition technique attributes and polarimetric ratios to discriminate land use and land cover classes of the Tapajós region. **Boletim de Ciências Geodésicas**, v. 25, 2019.

WOODHOUSE, I. H. **Introduction to microwave remote sensing**. Boca Raton: CRC Press, 2006. 400 p. ISBN 9781315272573.

WOODS, M.; LIM, K.; TREITZ, P. Predicting forest stand variables from LiDAR data in the Great Lakes – St. Lawrence forest of Ontario. **The Forestry Chronicle**, v. 84, n. 6, p. 827–839, 2008.

YAMAGUCHI, Y.; MORIYAMA, T.; ISHIDO, M.; YAMADA, H. Four-component scattering model for polarimetric SAR image decomposition. **IEEE Transactions on Geoscience and Remote Sensing**, v. 43, n. 8, p. 1699–1706, 2005.

YU, Y.; SAATCHI, S. Sensitivity of L-Band SAR backscatter to aboveground biomass of global forests. **Remote Sensing**, v. 8, n. 6, 2016.

ZANNE, A. E.; LOPEZ-GONZALEZ, G.; COOMES, D. A.; ILIC, J.; JANSEN, STEVEN, R.; LEWIS, S. L.; MILLER, R. B.; SWENSON, N. G.; WIEMANN, M. C.; CHAVE, J. **Data from:** towards a worldwide wood economics spectrum. [S.I.]: Dryad, 2009.

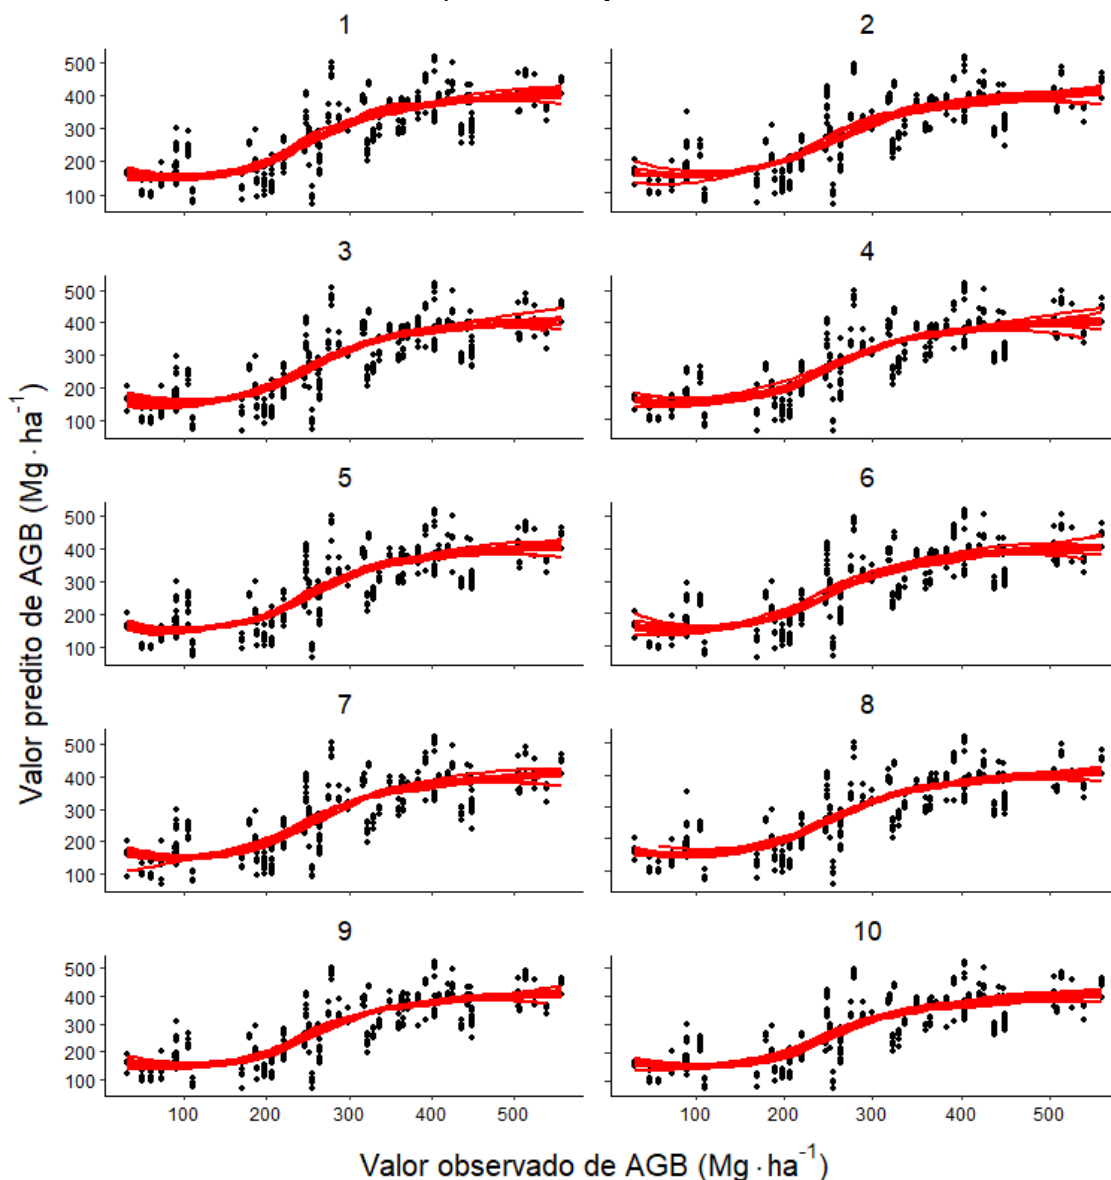
ZEMP, D. C.; SCHLEUSSNER, C.-F.; BARBOSA, H. M. J.; HIROTA, M.; MONTADE, V.; SAMPAIO, G.; STAAL, A.; WANG-ERLANDSSON, L.; RAMMIG, A. Self-amplified Amazon forest loss due to vegetation-atmosphere feedbacks. **Nature Communications**, v. 8, n. 1, p. 14681, 2017.

ZHAO, P.; LU, D.; WANG, G.; LIU, L.; LI, D.; ZHU, J.; YU, S. Forest aboveground biomass estimation in Zhejiang Province using the integration of Landsat TM and ALOS PALSAR data. **International Journal of Applied Earth Observation and Geoinformation**, v. 53, p. 1–15, 2016.

APÊNDICE A – VALORES PREDITOS DE AGB

Abaixo estão os gráficos dos valores de AGB observados nas parcelas de campo pelos valores preditos de AGB com os grupos de teste da validação cruzada por *k-fold*. O modelo foi ajustado com as métricas do LiDAR ALS de 555,55m de resolução espacial e com 65 pontos amostrados (Figura A.1).

Figura A.1 – Valores observados de AGB pelos valores preditos de AGB com as métricas LiDAR ALS de 555,55m de resolução e 65 pontos amostrados. A linha vermelha representa o ajuste linear.



Fonte: Produção do autor.

ANEXO A – INFORMAÇÕES SOBRE A AQUISIÇÃO DOS DADOS LIDAR

Nas Tabelas A.1, A.2, A.3, A.4, A.5 e A.6 são apresentadas as informações sobre a aquisição dos dados LiDAR ALS do projeto Paisagens Sustentáveis. Na Tabela A.7 estão expostas as características da aquisição dos dados LiDAR ALS do projeto Estimativa de Biomassa da Amazônia.

Tabela A.1 – Informações sobre a aquisição dos dados LiDAR do projeto Paisagens Sustentáveis da região ANA.

Variável	Especificações
<i>Scanner</i>	OPTECH / ALTM 3100 / 04SEN157
Data de aquisição	14/10/2018
Datum	Sirgas 2000
Zona UTM	21S
Número de <i>tiles</i>	12
Área total	989 ha
Altitude média do voo	750m
Campo de visada	10°
Densidade média dos retornos	28,12 ppm ²
Frequência do escaneamento	40 Hz
Instrumento IMU	APLANNIX / Av510 IMU8 / 2119
Frequência do IMU	200 kHz
Sobreposição das linhas de voo	70%

Fonte: Adaptada de Embrapa (2020).

Tabela A.2 – Informações sobre a aquisição dos dados LiDAR do projeto Paisagens Sustentáveis da região SAN1.

Variável	Especificações
<i>Scanner</i>	OPTECH / ORION / 09SEN243
Datas de aquisição	22/04/2015, 30/04/2015 e 01/05/2015
Datum	Sirgas 2000
Zona UTM	21S
Número de <i>tiles</i>	13
Área total	413 ha
Altitude média do voo	850m
Campo de visada	12°
Densidade média dos retornos	49,53 ppm ²
Frequência do escaneamento	83 Hz
Instrumento IMU	LITTON / 413996
Frequência do IMU	100 kHz
Sobreposição das linhas de voo	65%

Fonte: Adaptada de Embrapa (2020).

Tabela A.3 – Informações sobre a aquisição dos dados LiDAR do projeto Paisagens Sustentáveis da região SAN2.

Variável	Especificações
<i>Scanner</i>	OPTECH / ORION / 09SEN243
Datas de aquisição	23/04/2015, 30/04/2015 e 01/05/2015
Datum	Sirgas 2000
Zona UTM	21S
Número de <i>tiles</i>	18
Área total	591 ha
Altitude média do voo	850m
Campo de visada	12°
Densidade média dos retornos	58,67 ppm ²
Frequência do escaneamento	83 Hz
Instrumento IMU	LITTON / 413996
Frequência do IMU	100 kHz
Sobreposição das linhas de voo	65%

Fonte: Adaptada de Embrapa (2020).

Tabela A.4 – Informações sobre a aquisição dos dados LiDAR do projeto Paisagens Sustentáveis da região TAP1.

Variável	Especificações
<i>Scanner</i>	OPTECH / ALTM 3100 / 05SEN171
Data de aquisição	06/03/2017
Datum	Sirgas 2000
Zona UTM	21S
Número de <i>tiles</i>	17
Área total	1048 ha
Altitude média do voo	850m
Campo de visada	15°
Densidade média dos retornos	19,28 ppm ²
Frequência do escaneamento	40 Hz
Instrumento IMU	APLANNIX / Av510 IMU8 / 2119
Frequência do IMU	200 kHz
Sobreposição das linhas de voo	70%

Fonte: Adaptada de Embrapa (2020).

Tabela A.5 – Informações sobre a aquisição dos dados LiDAR do projeto Paisagens Sustentáveis da região TAP4.

Variável	Especificações
<i>Scanner</i>	OPTECH / ALTM 3100 / 04SEN157
Data de aquisição	15/10/2018
Datum	Sirgas 2000
Zona UTM	21S
Número de <i>tiles</i>	13
Área total	580 ha
Altitude média do voo	750m
Campo de visada	10°
Densidade média dos retornos	31,89 ppm ²
Frequência do escaneamento	40 Hz
Instrumento IMU	APLANNIX / Av510 IMU8 / 2119
Frequência do IMU	200 kHz
Sobreposição das linhas de voo	70%

Fonte: Adaptada de Embrapa (2020).

Tabela A.6 – Informações sobre a aquisição dos dados LiDAR do projeto Paisagens Sustentáveis da região TAP5.

Variável	Especificações
<i>Scanner</i>	OPTECH / ALTM 3100 / 04SEN157
Datas de aquisição	14/10/2018 e 15/10/2018
Datum	Sirgas 2000
Zona UTM	21S
Número de <i>tiles</i>	3
Área total	53 ha
Altitude média do voo	750m
Campo de visada	10°
Densidade média dos retornos	33,81 ppm ²
Frequência do escaneamento	40 Hz
Instrumento IMU	APLANNIX / Av510 IMU8 / 2119
Frequência do IMU	200 kHz
Sobreposição das linhas de voo	70%

Fonte: Adaptada de Embrapa (2020).

Tabela A.7 – Características da aquisição dos dados LiDAR do projeto Estimativa de Biomassa da Amazônia.


Sensor	LiDAR HARRIER 68i
Frequência de escaneamento	5 Hz a 200 Hz
Tipo de dado	Discreto e completo (FWF)
Ângulo da varredura completa	45°
Densidade de pulsos	4 ppm ²
<i>Footprint</i>	30 cm
Altura do voo	600 m

Fonte: INPE (2018).

ANEXO B – PRECIPITAÇÃO TOTAL DIÁRIA


Nas Figuras B.1 e B.2 são mostrados os valores de precipitação pluviométrico diário acumulado nos dez dias anteriores as aquisições das imagens do ALOS PALSAR-2.

Figura B.1 – Precipitação total diária entre os dias 08 e 17/04/2016 da estação Belterra/PA.



Fonte: INMET (2021).

Figura B.2 – Precipitação total diária entre os dias 22/04 e 01/05/2016 da estação Belterra/PA.



Fonte: INMET (2021).