

UNIVERSIDADE DO ESTADO DE SANTA CATARINA – UDESC
CENTRO DE CIÊNCIAS AGROVETERINARIAS – CAV
CURSO DE ENGENHARIA FLORESTAL

RAIANY DE OLIVEIRA SILVA

ESTIMATIVAS DE BIOMASSA AÉREA A PARTIR DE DADOS SAR E LiDAR EM
ÁREA DE FLORESTA TROPICAL ÚMIDA

LAGES

2025

RAIANY DE OLIVEIRA SILVA

**ESTIMATIVAS DE BIOMASSA AÉREA A PARTIR DE DADOS SAR E LiDAR EM
ÁREA DE FLORESTA TROPICAL ÚMIDA**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Florestal, da Universidade do Estado de Santa Catarina, como requisito parcial para a obtenção do título de Mestre em Engenharia Florestal, área de concentração em Engenharia Florestal.

Orientador: Prof. Dr. Veraldo Liesenberg

LAGES

2025

RAIANY DE OLIVEIRA SILVA

**ESTIMATIVAS DE BIOMASSA A PARTIR DE DADOS SAR E LiDAR EM ÁREA DE
FLORESTAS TROPICAL ÚMIDA**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Florestal, da Universidade do Estado de Santa Catarina, como requisito parcial para a obtenção do título de Mestre em Engenharia Florestal, área de concentração em Engenharia Florestal.

BANCA EXAMINADORA

Prof. Dr. Veraldo Lisenberg

Universidade do Estado de Santa Catarina – UDESC

Prof. Dr. Emanuel Araújo Silva

Universidade Federal de Santa Maria - UFSM

Dra. Juliana Marchesan

Secretaria da Agricultura, Pecuária, Produção Sustentável e Irrigação – SEAPI/RS

Dra. Carla Luciane Lima

Universidade do Estado de Santa Catarina – UDESC

Lages, 27 de Agosto de 2025.

Em memória de Otília Maria da Silva.

AGRADECIMENTOS

Agradeço, primeiramente, a Deus, por ter me guiado e sustentado até este momento.

Ao meu orientador, Professor Veraldo Liesenberg, pela orientação, pela paciência, pelo suporte e pelos valiosos ensinamentos compartilhados ao longo desta jornada.

À minha família, pelo amor, pelo incentivo e pelo apoio incondicionais. Em especial, à minha avó e primeira professora, Maria de Lourdes Barbosa de Oliveira, e à minha mãe, Maria das Dores Barbosa de Oliveira, por sempre acreditarem em mim e me inspirarem com sua força e dedicação.

Aos meus irmãos, Raysa de Oliveira Silva e Antônio Carlos Barbosa Sobrinho, pela parceria e por estarem sempre presentes.

Aos meus amigos de longa data, Izabelle Maria Barboza de Azevedo, Cássia Ribeiro Macedo, Daniele Galvão Alencar e Quemuel Alves Feitosa, pela amizade sincera e pelo apoio constante.

Aos novos amigos que fiz ao longo desta trajetória, pela companhia, pelo incentivo e pelo aprendizado compartilhado.

Ao corpo docente do Programa de Pós-Graduação em Engenharia Florestal, pelos ensinamentos e contribuições para minha formação acadêmica e profissional.

Por fim, agradeço à CAPES pelo apoio financeiro que viabilizou o desenvolvimento desta pesquisa.

*“Há outra curva na estrada depois desta.
Ninguém sabe o que vai acontecer.”*

L. M. Montgomery

RESUMO

As florestas tropicais exercem um papel fundamental na regulação do clima global pelos serviços ecossistêmicos que oferecem, como troca de energia com a atmosfera, manutenção do ciclo hidrológico, sequestro de Carbono, entre outros. Porém, a determinação da biomassa dessas florestas é um grande desafio devido sua extensão, tornando sua mensuração onerosa. Diante disso, esta pesquisa teve como finalidade verificar o impacto da resolução espacial em dados LiDAR aerotransportado para detecção de alteração na paisagem, assim como a utilização de dados LiDAR e SAR na estimativa da biomassa aérea de uma área de Floresta Tropical Amazônica. O estudo ocorreu na Fazenda Nova Neonita, localizada no município de Paragominas (Pará), com clima classificado como Aw - clima tropical com inverno seco, segundo Köppen, e com vegetação predominante do bioma amazônico. Foram utilizados LiDAR aerotransportados (2014 e 2017) e SAR do satélite ALOS-2/PALSAR-2. O processamento dos dados LiDAR foi realizado no *Toolbox for LiDAR Data Filtering and Forest Studies* (TIFFS), em que foram gerados os modelos digitais de superfície (DSM) e de elevação (DEM) e modelos de altura do dossel (CHM), com resoluções espaciais de 1, 3, 5, 10 e 20 metros. Já os dados SAR foram processados no PolSARpro, utilizando polarizações HH, HV e VV, além do cálculo do *Radar Vegetation Index* (RVI), razões de polarização e parâmetros polarimétricos como entropia e anisotropia. A biomassa foi estimada pelo método de regressão de *Stepwise*, com variáveis pré-definidas com Análise de Componentes Principais (PCA), comparada à biomassa observada obtida pela equação de Chambers *et al.* (2001). A acurácia dos modelos foi avaliada pelo R^2 ajustado, pelo erro quadrático médio (RMSE) e pelo CV (%). A análise dos CHMs mostrou que resoluções mais finas (1, 3 e 5 m) fornecem maior detalhamento da altura do dossel. Além disso, para a análise multitemporal, as resoluções de 1 a 5 metros registraram melhor o padrão de alteração local, enquanto os pixels de 20 metros induziram a superestimação de característica de vegetação. Com o inventário florestal, foram identificadas 119 espécies florestais em 39 famílias, destacando a Fabaceae (110 indivíduos e 36 espécies). A AGB calculada a partir do inventário, foi de 70,93 Mg/ha e 76,07 Mg/ha. A partir dos dados dos sensores e utilizando um modelo linear, foi possível prever a biomassa da área com um R^2 de 44,7% e RMSE de 46,24 Mg/ha. Os resultados demonstram o potencial do uso de sensores ativos em áreas de floresta tropical úmidas, como a Amazônia, permitindo o monitoramento florestal, gestão e quantificação do estoque de biomassa, além de subsidiar estratégias de mitigação das mudanças climáticas.

Palavras-chave: florestas secundárias; modelagem; mudança da vegetação; sensores ativos.

ABSTRACT

Tropical forests play a fundamental role in regulating the global climate through the ecosystem services they provide, such as energy exchange with the atmosphere, maintenance of the hydrological cycle, and carbon sequestration, among others. However, the determination of biomass in these forests remains a major challenge due to their vast extent, making measurement costly and time-consuming. In this context, the aim of this research is to assess the impact of spatial resolution in airborne LiDAR data for detecting landscape changes, as well as the use of LiDAR and SAR data for estimating aboveground biomass (AGB) in a Tropical Amazon Forest area. The study was conducted at Fazenda Nova Neonita, located in the municipality of Paragominas, Pará State, Brazil, with climate classified as Aw – tropical climate with dry winter, according to Köppen, and predominantly Amazonian biome vegetation. Airborne LiDAR data (2014 and 2017) and ALOS-2/PALSAR-2 SAR data were used. LiDAR data processing was performed in TIFFS to generate digital surface models (DSM), digital elevation models (DEM), and canopy height models (CHM), with spatial resolutions of 1, 3, 5, 10, and 20 meters. SAR data were processed in PolSARpro, using HH, HV, and VV polarizations, and the Radar Vegetation Index (RVI), polarization ratios, and polarimetric parameters such as entropy and anisotropy. Biomass was estimated using Stepwise regression with predefined variables obtained from Principal Component Analysis (PCA), and the results were compared with the observed biomass calculated using the equation of Chambers et al. (2001). Model accuracy was evaluated using adjusted R^2 , root mean square error (RMSE), and coefficient of variation (CV%). Analysis of CHMs showed that finer resolutions (1, 3, and 5 m) provide greater detail of canopy height. Furthermore, in multitemporal analysis, resolutions of 1 to 5 meters better captured patterns of local changes, while 20-meter pixels tended to overestimate vegetation characteristics. The forest inventory identified 119 plant species in 39 families, with Fabaceae standing out (110 individuals and 36 species). The AGB calculated from the inventory was 70.93 Mg/ha and 76.07 Mg/ha. Based on sensor data, it was possible to predict biomass in the study area with a model achieving an R^2 of 44.7% and RMSE of 46.24 Mg/ha. The results demonstrate the potential of using active sensors in tropical humid forests such as the Amazon, for forest monitoring, management, and biomass stock quantification, as well as supporting strategies for climate change mitigation.

Keywords: secondary forests; modeling; vegetation change; active sensors.

2 EFEITO DA RESOLUÇÃO ESPACIAL EM DADOS LiDAR PARA O MONITORAMENTO DE MUDANÇAS EM FLORESTAS TROPICAIS ÚMIDAS

RESUMO

O uso de dados LiDAR no monitoramento ambiental tem se tornado mais eficiente, devido à melhoria contínua da qualidade das informações espectrais, temporais e espaciais. Diante disso, o objetivo desse capítulo foi avaliar o impacto da resolução espacial em dados LiDAR na detecção de alterações florestais em uma área de Floresta Tropical Úmida. O estudo foi realizado na Fazenda Nova Neonita, no município de Paragominas – PA, inserida no bioma amazônico, com vegetação densa. Foram utilizados dados LiDAR coletados nos anos de 2014 e 2017, disponibilizados pelo projeto Paisagens Sustentáveis, resultando em nuvens de pontos obtidas por perfilamento a laser aerotransportado. O processamento dos dados foi realizado no *software Toolbox for LiDAR Data Filtering and Forest Studies* (TIFF), para gerar os Modelos Digitais de Superfície (DSM), de Terreno (DEM) e de Altura do Dossel (CHM) em resoluções espaciais de 1, 3, 5, 10 e 20 metros. A partir disso, foi calculada a diferença entre os CHMs dos dois anos e reclassificaram-se os pixels em três classes de alteração: supressão (valores $< -0,5$ m), sem alteração (entre $-0,5$ e $0,5$ m) e regeneração ($> 0,5$ m e $< 1,5$ m). Foram também extraídas métricas de percentis de altura em parcelas circulares de 100 m de raio, analisadas estatisticamente por meio de ANOVA e teste de Tukey a 5% de significância. Com as alturas extraídas dos CHMs, foi encontrada diferença estatística, indicando a influência significativa do tamanho do pixel na altura média da vegetação. As resoluções mais altas (1 a 5 m) apresentaram valores de altura menores e mais próximos da realidade, enquanto as resoluções mais baixas (10 e 20 m) superestimaram as alturas, reduzindo o detalhamento das características florestais. As análises percentílicas e espaciais confirmaram que as resoluções mais finas permitem identificar com maior precisão as variações verticais da floresta, sendo mais eficazes para detectar áreas de supressão e regeneração. Em contrapartida, as resoluções mais grosseiras promoveram generalizações, dificultando a distinção entre classes de mudança e provocando superestimativas. Conclui-se que a resolução espacial é essencial para determinar a precisão das análises em estudos florestais baseados em LiDAR, fundamentais para o monitoramento da vegetação, estimativas de biomassa e compreensão das dinâmicas espaciais e temporais das florestas tropicais.

Palavras-chaves: monitoramento ambiental; conservação; floresta amazônica; sensoriamento.

3 ESTIMATIVA DA BIOMASSA ACIMA DO SOLO UTILIZANDO LiDAR E SAR EM FLORESTA TROPICAL ÚMIDA

RESUMO

A quantificação da biomassa acima do solo (AGB) é fundamental para compreender a dinâmica florestal, possibilitando estudos ambientais e contribuindo com a avaliação do sequestro de CO₂, auxiliando no planejamento de ações voltadas às mitigações das mudanças climáticas. Com isso, o uso de dados de sensores ativos, como LiDAR e SAR, tem se destacado como uma alternativa eficiente na quantificação da biomassa florestal. Dessa forma, o objetivo deste trabalho foi estimar a biomassa acima do solo utilizando dados de LiDAR e SAR, na Floresta Amazônica. A área de estudo está localizada na Fazenda Nova Neonita, no município de Paragominas, Pará. Foram utilizados dados de inventário florestal conduzido pelo Instituto Floresta Tropical (IFT) em 2018, em parcelas de 20x500 m e subparcelas de 20x50m. Além disso, foram utilizados dados LiDAR, coletados em 2014 e 2017, que foram processados no *software* TIFFS para geração dos modelos digitais de superfície, terreno e altura do dossel, além da extração de métricas estruturais, e dados SAR, obtidos pelo ALOS-2/PALSAR-2 em 2016, que foram processados no *software* PolSARpro v6.0. A modelagem da biomassa foi realizada com análise de componentes principais (PCA) e regressão *stepwise*, combinando as variáveis LiDAR e SAR. A partir do inventário florestal foram mensurados 595 indivíduos, sendo identificadas 119 espécies distribuídas em 39 famílias, destacando-se Fabaceae, Urticaceae, Sapotaceae, Bignoniaceae e Lecythydaceae. O diâmetro médio à altura do peito (DAP) foi de 39,97 cm e a altura média das árvores foi de 18,47 m. A AGB média foi de 76,07 Mg/ha. A estimativa de biomassa com o sensor LiDAR apresentou desempenho moderado, com R² ajustado de 44,7% e RMSE de 46,74, respectivamente. A combinação dos sensores LiDAR com SAR não apresentou melhorias no modelo, obtendo um R² ajustado de 44,7%. Entretanto, os resultados do sensor LiDAR demonstraram maior correlação com biomassa, devido à sua capacidade de captar a estrutura tridimensional da floresta, enquanto o radar é limitado em áreas de alta biomassa, mas útil por operar sob cobertura de nuvens.

Palavras-chave: biomassa florestal, sensoriamento remoto, Amazônia, sequestro de carbono.

REFERÊNCIAS

- ADENIYI, O. D.; MAERKER, M. Explorative analysis of varying spatial resolutions on a soil type classification model and its transferability in an agricultural lowland area of Lombardy, Italy. **Geoderma Regional**, v. 37, p. e00785, 2024. Doi: <https://doi.org/10.1016/j.geodrs.2024.e00785>.
- ALMEIDA, C. A.; COUTINHO, A. C.; ESQUERDO, J. C. D. M.; ADAMI, M.; VENTURIERI, A.; DINIZ, C. G.; DESSAY, N.; DURIEUX, L.; GOMES, A. R. High spatial resolution land use and land cover mapping of the Brazilian Legal Amazon in 2008 using Landsat-5/TM and Modis data. **Acta Amazonica**, v. 40, n. 3, p. 291-302, 2016. DOI: <https://doi.org/10.1590/1809-4392201505504>.
- ALVES, L. W. R.; CARVALHO, E. J. M.; SILVA, L. G. T. Diagnóstico Agrícola do Município de Paragominas, PA. **Boletim de Pesquisa e Desenvolvimento**. EMBRAPA Amazônia Central. Belém – PA. 2014.
- BELLOLI, T. F.; GUASSELLI, L. A.; KUPLICH, T.; RUIZ, L. F. C. SIMIONI, J. P. D. Classificação baseada em objeto de tipologias de cobertura vegetal em área úmida integrando imagens ópticas e SAR. **Revista Brasileira Cartografia**, v. 74, n. 1, 2022.
- 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.
- BRANDON, K. Ecosystem Services from Tropical Forests: Review of Current Science. **Center for Global Development Working Paper**, n. 308, 2014. Disponível em: <https://ssrn.com/abstract=2622749>. Acesso em: 22 de ago 2023.
- BRASIL. **Ministério do Meio Ambiente e Mudança do Clima**. Brasília, DF: Ministério do Meio Ambiente e Mudança do Clima - Serviço Florestal Brasileiro, 2024.
- BROWN, I. F.; MARTINELLI, L. A.; THOMAS, W. W.; MOREIRA, M. Z.; FERREIRA, C. A. Cid; VICTORIA, R. A. Uncertainty in the biomass of Amazonian forests: an example from Rondônia, Brazil. **Forest Ecology and Management**, Amsterdam, v. 75, p. 175–189, 1995.
- CHAVES, J.; RÉJOU-MÉCHAIN, M.; BÚRGUEZ, A.; CHIDUMAYO, E.; COLGAN, M. S.; DELITTI, W., B. C.; DUQUE, A.; EID, T.; FEARNISIDE, P. M.; GOODMAN, R., C.; HENRY, M.; YRÍZAR, A. M.; MUNGASHA, W., A.; LANDAU, H., C., M.; MENCUCCINI, M.; NELSON, B. W.; NGOMANDA, A.; NOGUEIRA, E., M.; MALAVASSI, E., O.; PELISSIER, 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. 20, p. 3177-3190, 2014. DOI: <https://doi.org/10.1111/gcb.12629>.
- CHEN, Q.; MCROBERTS, R. E.; WANG, C.; RADTKE, P. J. Forest aboveground biomass mapping and estimation across multiple spatial scales using model-based inference. **Remote Sensing of Environment**, v. 184, p. 350-360, 2016.

COUTINHO, A. C.; ALMEIDA, C.; VENTURIERI, A.; ESQUERDO, J. C. D. M.; SILVA, M. **Uso e cobertura da terra nas áreas desflorestadas da Amazônia Legal**: TerraClass 2008. Brasília. DF Embrapa; INPE: Belém, Brasil, 2013.

DEBASTIANI, A. B.; SAQUETTA, C. R.; CORTE, A. P. D.; REX, F. E.; PINTO, N. S. Evaluating SAR-optical sensor fusion for aboveground biomass estimation in a Brazilian tropical forest. **Annals of Forest Research**, v. 62, n. 1, p. 109–122, 2019.

DIAS-FILHO, M. B. A fotossíntese e o aquecimento global. Belém, PA: **Embrapa Amazônia Oriental**, 2006. 24 p. ISSN 1517-2201.

FAO, UNEP. **The state of the world's forests 2020**. Roma: Forests, biodiversidade and people, 2020. DOI: doi.org/10.4060/ca8642en.

FERREIRA, L.; MAIA, A. P. M.; PINHEIRO, M. S.; OLIVEIRA, M. C.; PAIZÃO JUNIOR, L. E.; AMORIN, J. T. A.; BAIA, L. L. F.; TRINDADE, J. H.; JARDIM, M. M. A. G. Diversidade florística em fitofisionomias de duas Unidades de Conservação na Amazônia Oriental, Pará, Brasil. **Revista Brasileira de Geografia Física**, v. 16, n. 6, p. 3283-3297, 2023.

FRIZZLE, C.; FOURNIER, R. A.; TRUDEL, M.; LUTHER, J. E. Towards sustainable forestry: Using a spatial Bayesian belief network to qualify trade-offs among forest-related ecosystem services. **Journal of Environmental Management**, v. 301, p. 113817, 2022. Doi: 10.1016/j.jenvman.2021.113817.

GOMES, L.F.; BRITES, R. S.; LOCKS, C. J.; ANJOS, R. R. dos. Estimativa das alterações na biomassa florestal utilizando LiDAR em áreas de manejo florestal sustentável na Amazônia sul-ocidental. **Anuário do Instituto de Geociências**, v. 43, n.3, p. 260-268, 2020. Doi: 10.11137/2020_3_260_268.

HAGENSIEKER, R.; ROSCHER, R.; ROSENRETER, J.; JAKIMOW, B.; WASKER, B. Tropical Land Use Land Cover Mapping in Para (Brazil) using discriminative Markov Random Fields and multi-temporal TerraSAR-X data. **International Journal of Applied Earth Observation and Geoinformation**, v. 63, p. 244-256, 2017.

IPCC - Intergovernmental Panel on Climate Change. **Climate Change 2022: Mitigation of Climate Change**. 2022. ISBN 978-92-9169-160-9.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente**: Uma perspectiva em recursos terrestres (tradução da segunda edição). São Paulo: Parêntese Editora, 2011.

JOSHI, N.; MITCHARD, E.T. A.; BROLLY, M.; SCHUMACHER, J.; LANDA, A. F.; JOHANNSEN, V. K.; MARCHAMALO, M.; FENSHOLT, R. Understanding ‘saturation’ of radar signals over forests. **Scientific Reports**, v. 7, p. 1–11, 2017.

KUMAR, L.; MUSTANGA, O. Remote sensing of above-ground biomass. **Remote Sensing**, v. 9, p. 935, 2017. Doi:10.3390/rs9090935.

LAL, Rattan. **Carbon sequestration**. Philosophical Transactions of the Royal Society B: Biological Sciences, v. 363, n. 1492, p. 815–830, 2008.

LEE, J. S.; GRUNES, M. R.; GRANDI, G. 1999. Polarimetric SAR speckle filtering and its implication for Classification. **IEEE Transactions on Geoscience and Remote Sensing**, Vol. 37, No 5, pp.2363-2373. Doi: 10.1109/36.789635.

LEMOS, A. L.F.; VITAL, M. H. F.; PINTO, M. A. C. As florestas e o painel de mudanças climáticas da ONU. **BNDES Setorial**, Rio de Janeiro, n. 32, p. 153–192, set. 2010.

LIMA, S. S. N. BARBOSA, A. M. O. **Diagnóstico da Realidade Municipal Revisão do Plano Diretor Paragominas – Pará**. 2020.

MACHADO, G. O.; BRANCALION, P. H. S.; FERNANDES, A. A. Estimativa de biomassa e estoque de Carbono da floresta amazônica do Estado do Pará. **Revista de Gestão e Secretariado**, v. 15, n., 7, p. 02-10, 2024. DOI: <http://doi.org/10.7769/gesec.v15i8.3971>.

MENDONÇA, R.; MARÇAL, C. L. D.; PAZ, A. R. da. Efeito da resolução espacial e da fonte de dados de elevação sobre a caracterização da rede de drenagem. In: **Simpósio Brasileiro De Sensoriamento Remoto**, 19., 2019, Santos. **Anais...** São José dos Campos: INPE, 2019. p. 123–135. Disponível em: <http://marte2.sid.inpe.br/col/sid.inpe.br/marte2/2019/09.16.16.49/doc/97555.pdf>. Acesso em: 28 dez. 2024.

MILLER, A.; PANNEERSELVAM, J.; LIU, L. A review of regression and classification techniques for analysis of common and rare variants and gene-environmental factors. **Neurocomputing**, v. 489, n.7, p.466-485, 2022. Doi: <https://doi.org/10.1016/j.neucom.2021.08.150>.

MOUTINHO, P.; GUIMARÃES, A. L.; ARRUDA, V. L. S.; PINTO, E.; FEARNSIDE, P. M. Beyond deforestation: carbon emissions from land grabbing and forest degradation in the Brazilian Amazon. **Frontiers in Forests and Global Change**, v. 4, p. 645282, 2021. DOI: <https://doi.org/10.3389/ffgc.2021.645282>.

NASCIMENTO, A. C. V.; BARROS, P. L. C.; FERREIRA, G. C.; SANTOS, J. C.; CARNEIRO, F. S. Avaliação da estrutura fitossociológica de um fragmento florestal no Município de Paragominas-PA, Brasil. **Research, Society and Development**, v. 10, n. 9, e 41510917325, 2021. Doi: <http://dx.doi.org/10.33448/rsd-v10i9.17325>.

NEUENSCHWANDER, A.; DUNCANSON, L.; MONTESANO, P.; MINOR, D.; GUENTHER, E.; HANCOCK, S.; WULDER, M. A.; WHITE, J. C.; PURSLOW, M.; THOMAS, N.; MANDEL, A.; FENG, T.; ARMSTON, J.; KELLNER, J. R.; ANDERSEN, H. E.; BOSCHETTI, L.; FEKETY, P.; HUDAK, A.; PISEK, J.; SANCHEZ-LÓPEZ, N.; STERENCZAK. Towards global spaceborne lidar biomass: Developing and applying boreal forest biomass models for ICESat-2 laser altimetry data. **Science of Remote Sensing**, v. 10, p. 100150, 2024. Doi: <https://doi.org/10.1016/j.srs.2024.100150>.

NISHIWAKI, A. A. M.; MOURA, M. S. B.; GALVÍNCIO, J. D.; OLIVEIRA, C. P.; SILVA, E. A.; LIMA, J. R. S.; ANTONIMO, A. C. S.; SOUZAM E. S.; MENEZES, R. S. C.; MONTENEGRO, S. M. G. L.; DOMINGUES, T. F. Uso do LiDAR na estimativa de atributos florestais: uma revisão. **Revista Brasileira de Geografia Física**, v. 16, n. 1, 2023. Doi: <https://doi.org/10.26848/rbgf.v16.1.p505-527>.

ODUM, E. P. **Ecologia**. Rio de Janeiro: Guanabara Koogan, 2010. 434 p.

OLIVEIRA, A. S. de; TRINDADE, A. L. C.; CLEMENTE, C. C.; CHO, D. F.; MORELLI, F.; ZACHARIAS, G. C.; FERREIRA, G. P.; MORITA, J. P.; CAITANO, L. L.; MUCHAGATA, M.; OLIVEIRA, M. S. de; MATTOS, P. P. de; FERRAZ, P. C.; LEÃO, R. A.; OLIVEIRA, Y. M. M. de. Florestas. *In: IBAMA. Relatório de qualidade do meio ambiente: RQMA: Brasil 2020*. Brasília, p. 302-365, cap. 5, 2022.

PACKALEN, P.; STRUNK, J.; PACKALEN, T.; MALTAMO, M.; MEHTATALO, L. Resolution dependence in an area-based approach to forest inventory with airborne laser scanning. **Remote Sensing of Environmental**, v. 224, p. 192-201, 2019. Doi: <https://doi.org/10.1016/j.rse.2019.01.022>.

PEZZUTI, J. C. B.; SILVA, D. F. Síntese analítica do mapeamento das condições ambientais da macrorregião de Paragominas (Paper 236). **Papers do NAEA**, v. 1, n.1, 2009.

POORAZIMY, N.; KUPLIK, M.; ANDERSEN, H.-E.; MEYER, V. J.; SCHWANTES, A. M.; HOSSEINZADEH, S. R.; FRIEDL, M. A. Combining airborne LiDAR and optical remote sensing data to estimate forest aboveground biomass and carbon stocks: a review. **Remote Sensing of Environment**, v. 240, p. 111–678, 2020.

REX, F. E.; CORTE, A. P. D.; SILVA, C. A.; MACHADO, S. A.; SANQUETTA, C. R. Dynamics of above-ground biomass in the Brazilian Amazon using lidar data. **Anuário do Instituto de Geociências**, v. 43, n. 1, p. 228–238, 2020.

ROMERO, F. M. B.; JACOBINE, L. A. G.; TORRES, C. M. M. E.; RIBEIRO, S. C.; ROCHA, S. J. S. S.; NOVAIS, T. N. O.; GASPAR, R. O.; SILVA, L. F.; VIDAL, E.; LEITE, H. G.; STAUDHAMMER, C. L.; FEARNside, P. M. Aboveground biomass allometric models for large trees in southwestern Amazonia. **Tree, Forests and People**, v. 9, 2022. DOI: <https://doi.org/10.1016/j.tfp.2022.100317>.

SILVA, C. A.; SANTILLI, G. SANO, E. E.; RODRIGUES, S. W. P. Análise qualitativa do desmatamento na floresta amazônica a partir de sensores SAR, Óptico e Termal. **Anuário do Instituto de Geociências**, v. 42, n. 4, p. 18-29, 2019.

SONG, G.; WANG, J.; ZHAO, Y.; YANG, D.; LEE, C. K. F.; GUO, Z.; DETTO, M.; ALBERTON, B.; MORELLATO, P.; NELSON, B.; WU, J. Scale matters: Spatial resolution impacts tropical leaf phenology characterized by multi-source satellite remote sensing with an ecological-constrained deep learning model. **Remote Sensing of Environment**, v. 304, p. 1114027, 2024. Doi: <https://doi.org/10.1016/j.rse.2024.114027>.

SUVANATO, S.; PELTONIEMI, M.; TUOMINEN, S.; STRANDSTROM, M.; LEHTONEN, A. High-resolution mapping of forest vulnerability to wind for disturbance-aware forestry. **Forest Ecology and Management**, v. 453, 2019. Doi: <https://doi.org/10.1016/j.foreco.2019.117619>.

TEIXEIRA, L. M. **Influência da intensidade de exploração seletiva de madeira no crescimento e respiração do tecido lenhoso das árvores em uma floresta de terra-firme na região de Manaus**. Dissertação (Mestrado em Ciência Agrária) – Universidade Federal do Amazonas, Manaus, 2003.

WATZLAWICK, L. F. **Estimativa de biomassa e Carbono em Floresta Ombrófila Mista e plantações florestais a partir de dados de imagens do satélite IKONOS II**. 120 f. Tese

(Doutorado em Ciência Florestais) – Setor de Ciências Agrárias, Universidade Federal do Paraná. Curitiba, 2003.

WONG, C. J.; CHAI, L. T.; JAMES, D.; BESAR, N. A.; KAMLUN, K. U.; PHUA, M. Assessment of anthropogenic disturbances on mangrove aboveground biomass in Malaysian Borneo using airborne LIDAR data. **The Egyptian Journal of Remote Sensing and Space Sciences**, v. 27, n. 3, p. 547-554, 2024. Doi: <https://doi.org/10.1016/j.ejrs.2024.06.004>.

YAN, W. Y.; EWIJK, K. V.; TREITZ, P.; SHAKER, A. Effects of radiometric correction on cover type and spatial resolution for modeling plot level forest attributes using multispectral airborne LiDAR data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 169, p. 152-165, 2020. Doi: <https://doi.org/10.1016/j.isprsjprs.2020.09.001>.

ZHOU, T.; HOU, Y.; YANG, Z.; LAFFITTE, B.; LOU, K.; LOU, X.; LIAO, D.; TANG, X. Reducing spatial resolution increased net primary productivity prediction of terrestrial ecosystems: a random forest approach. **Science of The Total Environment**, v. 897, 2023. Doi: <https://doi.org/10.1016/j.scitotenv.2023.165134>.

WICHERT, M. C. P.; WATT, P.; WATT, M. S. Aplicações de imagem de satélite de alta resolução no planejamento florestal. **Série Técnica IPEF**, v. 17, n. 38, agosto de 2013.

REX, F. E.; DALLA CORTE, A. P.; DEBASTIANI, A. B.; KAZAMA, V. S.; SANQUETTA, C. R. Uso de dados LiDAR na estimativa de variáveis biofísicas na Amazônia, sob diferentes resoluções espaciais. **Nativa**, v. 6, n. 5, p. 487-493, 2018.

ANEXOS

ANEXO A – ESPÉCIES COM NÚMEROS DE INDIVÍDUOS (NI), UNIDADES AMOSTRAIS (UI), VALORES ABSOLUTOS E RELATIVOS DE DENSIDADE, DOMINÂNCIA, FREQUÊNCIA, VALOR DE IMPORTÂNCIA ABOLUTA (IVI) E RELATIVA (IVI%) E VALOR DE COBERTURA (IVC).

Espécies	NI	Ui	DA	DR	DoA	DoR	FA	FR	IVC	IVI	IVI%
<i>Abarema jupunba</i>	1	1	10	0.17	0.01	0.19	1	0.17	0.36	0.53	0.18
<i>Ambelania acida</i>	1	1	10	0.17	0.00	0.03	1	0.17	0.19	0.36	0.12
<i>Anacardium spruceanum</i>	2	2	20	0.34	0.05	0.90	2	0.34	1.24	1.58	0.53
<i>Annona ambotay</i>	4	4	40	0.67	0.02	0.27	4	0.67	0.94	1.61	0.54
<i>Apeiba echinata</i>	4	4	40	0.67	0.01	0.25	4	0.67	0.92	1.60	0.53
<i>Bagassa guianensis</i>	1	1	10	0.17	0.00	0.03	1	0.17	0.19	0.36	0.12
<i>Bocageopsis pleiosperma</i>	14	14	140	2.35	0.04	0.78	14	2.35	3.13	5.48	1.83
<i>Bowdichia nitida</i>	1	1	10	0.17	0.01	0.25	1	0.17	0.41	0.58	0.19
<i>Brosimum rubescens</i>	3	3	30	0.50	0.02	0.30	3	0.50	0.81	1.31	0.44
<i>Byrsonima chrysophylla</i>	1	1	10	0.17	0.00	0.03	1	0.17	0.19	0.36	0.12
<i>Caraipa grandifolia</i>	2	2	20	0.34	0.00	0.08	2	0.34	0.42	0.75	0.25
<i>Carapa guianensis</i>	2	2	20	0.34	0.02	0.38	2	0.34	0.71	1.05	0.35
<i>Caryocar villosum</i>	2	2	20	0.34	0.03	0.53	2	0.34	0.87	1.21	0.40
<i>Casearia grandiflora</i>	11	11	110	1.85	0.02	0.40	11	1.85	2.25	4.10	1.37
<i>Cassia fastuosa</i>	1	1	10	0.17	0.02	0.31	1	0.17	0.48	0.65	0.22
<i>Cecropia ficifolia</i>	76	76	760	12.77	0.16	2.86	76	12.77	15.63	28.4	9.47
<i>Cecropia palmata</i>	12	12	120	2.02	0.02	0.39	12	2.02	2.41	4.43	1.48
<i>Chimarrhis turbinata</i>	5	5	50	0.84	0.11	2.00	5	0.84	2.84	3.68	1.23
<i>Copaifera reticulata</i>	1	1	10	0.17	0.03	0.45	1	0.17	0.62	0.79	0.26
<i>Cordia goeldiana</i>	1	1	10	0.17	0.01	0.19	1	0.17	0.36	0.52	0.17
<i>Cordia scabrifolia</i>	10	10	100	1.68	0.02	0.35	10	1.68	2.03	3.71	1.24
<i>Couepia robusta</i>	1	1	10	0.17	0.02	0.30	1	0.17	0.47	0.64	0.21
<i>Couratari stellata</i>	2	2	20	0.34	0.04	0.77	2	0.34	1.11	1.44	0.48
<i>Croton matourensis</i>	6	6	60	1.01	0.05	0.96	6	1.01	1.96	2.97	0.99
<i>Dialium guianense</i>	8	8	80	1.34	0.08	1.33	8	1.34	2.67	4.01	1.34
<i>Dimorphandra macrostachya</i>	9	9	90	1.51	0.15	2.65	9	1.51	4.16	5.67	1.89
<i>Diospyros guianensis</i>	1	1	10	0.17	0.00	0.05	1	0.17	0.22	0.38	0.13
<i>Diploptropis sp.</i>	1	1	10	0.17	0.03	0.48	1	0.17	0.65	0.82	0.27
<i>Dipteryx odorata</i>	3	3	30	0.50	0.04	0.78	3	0.50	1.28	1.78	0.59
<i>Duguetia stelechantha</i>	1	1	10	0.17	0.00	0.03	1	0.17	0.20	0.37	0.12
<i>Enterolobium schomburgkii</i>	1	1	10	0.17	0.02	0.39	1	0.17	0.55	0.72	0.24
<i>Eperua bijuga</i>	9	9	90	1.51	0.11	1.90	9	1.51	3.41	4.92	1.64
<i>Eschweilera amazonica</i>	1	1	10	0.17	0.01	0.10	1	0.17	0.26	0.43	0.14
<i>Eschweilera coriacea</i>	7	7	70	1.18	0.13	2.32	7	1.18	3.49	4.67	1.56
<i>Eschweilera grandifolia</i>	1	1	10	0.17	0.02	0.34	1	0.17	0.50	0.67	0.22

Espécies	NI	Ui	DA	DR	DoA	DoR	FA	FR	IVC	IVI	IVI%
<i>Eschweilera ovata</i>	9	9	90	1.51	0.20	3.57	9	1.51	5.08	6.59	2.20
<i>Eschweilera parviflora</i>	18	18	180	3.03	0.31	5.44	18	3.03	8.47	11.49	3.83
<i>Euterpe oleracea</i>	1	1	10	0.17	0.00	0.02	1	0.17	0.19	0.35	0.12
<i>Goupia glabra</i>	6	6	60	1.01	0.14	2.38	6	1.01	3.39	4.40	1.47
<i>Heisteria densifrons</i>	1	1	10	0.17	0.00	0.02	1	0.17	0.18	0.35	0.12
<i>Helicostylis sp.</i>	8	8	80	1.34	0.11	1.85	8	1.34	3.19	4.54	1.51
<i>Hevea sp.</i>	2	2	20	0.34	0.05	0.86	2	0.34	1.20	1.53	0.51
<i>Himatanthus sucuuba</i>	1	1	10	0.17	0.01	0.25	1	0.17	0.42	0.58	0.19
<i>Hymenaea parviflora</i>	2	2	20	0.34	0.03	0.51	2	0.34	0.85	1.18	0.39
<i>Hymenolobium sp.</i>	1	1	10	0.17	0.02	0.42	1	0.17	0.58	0.75	0.25
<i>Inga alba</i>	4	4	40	0.67	0.05	0.86	4	0.67	1.53	2.21	0.74
<i>Inga grandis</i>	1	1	10	0.17	0.01	0.12	1	0.17	0.28	0.45	0.15
<i>Inga heterophylla</i>	4	4	40	0.67	0.01	0.12	4	0.67	0.80	1.47	0.49
<i>Inga marginata</i>	31	31	310	5.21	0.14	2.45	31	5.21	7.66	12.87	4.29
<i>Inga sp.</i>	3	3	30	0.50	0.01	0.19	3	0.50	0.69	1.20	0.40
<i>Jacaranda copaia</i>	7	7	70	1.18	0.09	1.53	7	1.18	2.71	3.89	1.30
<i>Jacaratia spinosa</i>	5	5	50	0.84	0.09	1.57	5	0.84	2.41	3.25	1.08
<i>Lecythis idatimon</i>	27	27	270	4.54	0.27	4.71	27	4.54	9.25	13.79	4.60
<i>Lecythis lurida</i>	3	3	30	0.50	0.11	2.00	3	0.50	2.51	3.01	1.00
<i>Licania canescens</i>	7	7	70	1.18	0.10	1.73	7	1.18	2.90	4.08	1.36
<i>Licania heteromorpha</i>	4	4	40	0.67	0.02	0.38	4	0.67	1.05	1.73	0.58
<i>Luehea sp.</i>	1	1	10	0.17	0.03	0.56	1	0.17	0.73	0.90	0.30
<i>Manilkara amazonica</i>	1	1	10	0.17	0.02	0.39	1	0.17	0.56	0.73	0.24
<i>Manilkara huberi</i>	5	5	50	0.84	0.09	1.55	5	0.84	2.39	3.23	1.08
<i>Minquartia guianensis</i>	2	2	20	0.34	0.00	0.06	2	0.34	0.39	0.73	0.24
<i>Mouriri collocarpa</i>	1	1	10	0.17	0.00	0.05	1	0.17	0.22	0.39	0.13
<i>Nectandra cuspidata</i>	2	2	20	0.34	0.00	0.03	2	0.34	0.37	0.71	0.24
<i>Neea oppositifolia</i>	6	6	60	1.01	0.04	0.77	6	1.01	1.78	2.79	0.93
NI	43	43	430	7.23	0.35	6.10	43	7.23	13.33	20.55	6.85
<i>Ocotea canaliculata</i>	1	1	10	0.17	0.00	0.04	1	0.17	0.21	0.37	0.12
<i>Ocotea glomerata</i>	1	1	10	0.17	0.02	0.27	1	0.17	0.43	0.60	0.20
<i>Parkia gigantocarpa</i>	3	3	30	0.50	0.07	1.19	3	0.50	1.69	2.20	0.73
<i>Parkia multijuga</i>	8	8	80	1.34	0.18	3.07	8	1.34	4.41	5.76	1.92
<i>Parkia paraensis</i>	1	1	10	0.17	0.02	0.43	1	0.17	0.60	0.76	0.25
<i>Parkia pendula</i>	1	1	10	0.17	0.01	0.19	1	0.17	0.35	0.52	0.17
<i>Parkia sp.</i>	8	8	80	1.34	0.05	0.88	8	1.34	2.22	3.56	1.19
<i>Peltogyne leicointei</i>	2	2	20	0.34	0.05	0.95	2	0.34	1.28	1.62	0.54
<i>Piptadenia cobi</i>	1	1	10	0.17	0.04	0.63	1	0.17	0.80	0.97	0.32
<i>Platymiscium filipes</i>	1	1	10	0.17	0.01	0.24	1	0.17	0.40	0.57	0.19
<i>Poecilanthe effusa</i>	3	3	30	0.50	0.00	0.05	3	0.50	0.55	1.06	0.35
<i>Poeppigia sp.</i>	1	1	10	0.17	0.01	0.14	1	0.17	0.31	0.48	0.16
<i>Pourouma minor</i>	4	4	40	0.67	0.05	0.80	4	0.67	1.47	2.15	0.72
<i>Pouteria anibifolia</i>	4	4	40	0.67	0.05	0.87	4	0.67	1.54	2.21	0.74
<i>Pouteria cladantha</i>	2	2	20	0.34	0.02	0.42	2	0.34	0.76	1.09	0.36
<i>Pouteria gongrijpii</i>	13	13	130	2.18	0.12	2.13	13	2.18	4.32	6.50	2.17

Espécies	NI	Ui	DA	DR	DoA	DoR	FA	FR	IVC	IVI	IVI%
<i>Pouteria guianensis</i>	1	1	10	0.17	0.00	0.05	1	0.17	0.22	0.39	0.13
<i>Pouteria hispida</i>	5	5	50	0.84	0.07	1.15	5	0.84	1.99	2.83	0.94
<i>Pouteria macrophylla</i>	1	1	10	0.17	0.01	0.18	1	0.17	0.35	0.52	0.17
<i>Pouteria retinervis</i>	2	2	20	0.34	0.00	0.07	2	0.34	0.41	0.74	0.25
<i>Pouteria sp.</i>	6	6	60	1.01	0.08	1.37	6	1.01	2.38	3.39	1.13
<i>Pradosia praealta</i>	1	1	10	0.17	0.03	0.51	1	0.17	0.68	0.85	0.28
<i>Protium paniculatum</i>	2	2	20	0.34	0.01	0.10	2	0.34	0.43	0.77	0.26
<i>Pseudopiptadenia suaveolens</i>	5	5	50	0.84	0.07	1.15	5	0.84	1.99	2.83	0.94
<i>Pterocarpus sp.</i>	1	1	10	0.17	0.02	0.38	1	0.17	0.54	0.71	0.24
<i>Qualea paraensis</i>	2	2	20	0.34	0.07	1.30	2	0.34	1.64	1.97	0.66
<i>Rinorea guianensis</i>	4	4	40	0.67	0.01	0.17	4	0.67	0.84	1.51	0.50
<i>Sacoglottis guianensis</i>	6	6	60	1.01	0.05	0.90	6	1.01	1.91	2.92	0.97
<i>Sagotia racemosa</i>	7	7	70	1.18	0.02	0.31	7	1.18	1.49	2.66	0.89
<i>Sapium marmieri</i>	11	11	110	1.85	0.02	0.38	11	1.85	2.23	4.07	1.36
<i>Schefflera morototoni</i>	1	1	10	0.17	0.01	0.22	1	0.17	0.39	0.55	0.18
<i>Simaba cedron</i>	1	1	10	0.17	0.00	0.02	1	0.17	0.19	0.35	0.12
<i>Sloanea guianensis</i>	2	2	20	0.34	0.03	0.47	2	0.34	0.80	1.14	0.38
<i>Sterculia pruriens</i>	1	1	10	0.17	0.00	0.02	1	0.17	0.19	0.36	0.12
<i>Strychnos subcordata</i>	6	6	60	1.01	0.02	0.30	6	1.01	1.30	2.31	0.77
<i>Stryphnodendron paniculatum</i>	5	5	50	0.84	0.05	0.81	5	0.84	1.65	2.49	0.83
<i>Stryphnodendron pulcherrimum</i>	2	2	20	0.34	0.02	0.40	2	0.34	0.74	1.08	0.36
<i>Swartzia corrugata</i>	1	1	10	0.17	0.01	0.19	1	0.17	0.36	0.52	0.17
<i>Symphonia globulifera</i>	1	1	10	0.17	0.00	0.03	1	0.17	0.20	0.37	0.12
<i>Tabebuia serratifolia</i>	1	1	10	0.17	0.00	0.02	1	0.17	0.19	0.36	0.12
<i>Tachigali myrmecophila</i>	8	8	80	1.34	0.15	2.63	8	1.34	3.98	5.32	1.77
<i>Tachigali paniculata</i>	4	4	40	0.67	0.12	2.01	4	0.67	2.69	3.36	1.12
<i>Tapirira guianensis</i>	9	9	90	1.51	0.11	1.92	9	1.51	3.43	4.95	1.65
<i>Terminalia amazonia</i>	1	1	10	0.17	0.05	0.79	1	0.17	0.96	1.13	0.38
<i>Tetragastris altissima</i>	8	8	80	1.34	0.13	2.23	8	1.34	3.58	4.92	1.64
<i>Theobroma glaucum</i>	1	1	10	0.17	0.00	0.04	1	0.17	0.21	0.37	0.12
<i>Thyrsodium paraense</i>	1	1	10	0.17	0.00	0.02	1	0.17	0.18	0.35	0.12
<i>Trattinnickia burseraefolia</i>	3	3	30	0.50	0.05	0.90	3	0.50	1.40	1.91	0.64
<i>Virola melinoni</i>	3	3	30	0.50	0.06	1.13	3	0.50	1.63	2.14	0.71
<i>Vismia guianensis</i>	5	5	50	0.84	0.01	0.14	5	0.84	0.98	1.82	0.61
<i>Vochysia guianensis</i>	1	1	10	0.17	0.00	0.02	1	0.17	0.19	0.35	0.12
<i>Xylopia nitida</i>	2	2	20	0.34	0.05	0.83	2	0.34	1.16	1.50	0.50
<i>Zanthoxylum rhoifolium</i>	3	3	30	0.50	0.01	0.16	3	0.50	0.66	1.17	0.39
<i>Zollernia paraensis</i>	2	2	20	0.34	0.02	0.31	2	0.34	0.65	0.99	0.33
<i>Zygia racemosa</i>	3	3	30	0.50	0.02	0.27	3	0.50	0.77	1.28	0.43
Total	595	595	5950	100	5.72	100	595	100	200	300	100

Fonte: Elaborado pela autora (2025).

ANEXO B – Script utilizado para calcular a Biomassa Acima do Solo (AGB) do inventário florestal.

```

## Estimativa da Biomassa
# Biomassa inventário Chaves et al (2014)
inv$AGB_2018 <- with(inv, exp(
  -1.803 - 0.97 * (-0.103815) + 0.976 *
    log(inv$WSD_2018) + 2.673 * log(inv$DBH_2018) -
    0.0299 * (log(inv$DBH_2018)^2)))

### Biomassa inventário Chamber et al (2014)
dados$AGB <- with(dados,
  densidade * exp(-1.499 + 2.148 * log(DAP) +
    0.207 * (log(DAP))^2 -
    0.0281 * (log(DAP))^3))

### Biomassa por parcela
area_parcela <- 1000 # Por exemplo, 500 m²

# Fator de conversão para hectare
fator_conversao <- 10000 / area_parcela

# Calcular a biomassa total por parcela e escalonar para hectare
biomassa_por_parcela <- aggregate(inv$AGB_2013 ~ inv$parcelas, data = inv, sum)

biomassa_parcela$AGB_ha <- biomassa_por_parcela$AGB_2013 * fator_conversao

# Soma por parcela
biomassa_parcela <- aggregate(AGB_2018 ~ parcelas, data = inv, sum)
print(biomassa_por_parcela)

# Verificar se as colunas necessárias existem
if (!all(c("parcelas", "AGB_2018") %in% names(inv))) {
  stop("As colunas 'parcelas' e 'AGB_2013' precisam estar presentes no data frame.")
}

# Remover NAs da coluna AGB
dados <- na.omit(inv)

# Definir área da parcela em m²
area_parcela_m2 <- 1000 # Substitua pelo valor correto

# Fator de conversão para hectare

```

```

fator_conversao <- 10000 / area_parcela_m2

# Calcular a biomassa total por parcela
biomassa_parcela <- aggregate(AGB_2018 ~ parcelas, data = inv, sum)

# Adicionar a biomassa por hectare
if (nrow(biomassa_par) > 0) {
  biomassa_parcela$AGB_ha <- biomassa_par$AGB_2018 * fator_conversao
  print(biomassa_parcela) # Exibe o resultado final
} else {
  stop("Nenhuma biomassa foi calculada. Verifique os dados de entrada.") }

# Calcular média
media_AGB <- mean(biomassa_parcela$AGB_ha, na.rm = TRUE)

# Calcular desvio padrão
desvio_AGB <- sd(biomassa_parcela$AGB_ha, na.rm = TRUE)

# Gráfico de barras
ggplot(dados, aes(x = parcelas, y = AGB_Mg)) +
  geom_bar(stat = "identity", fill = "forestgreen") +
  labs( title = "", x = "Parcela",
        y = "AGB (Mg/ha)" ) +
  theme_minimal(base_family = "Times") +
  theme(axis.text.x = element_text(angle = 0, hjust = 1))

# Gráfico de Box-plot
library(ggplot2)

ggplot(dados, aes(y = AGB_Mg)) +
  geom_boxplot(fill = "lightgreen", color = "darkgreen") +
  labs(
    title = "",
    y = "AGB (Mg/ha)" ) +
  theme_minimal() +
  theme(
    axis.text.x = element_blank(), # remove os valores (textos) do eixo x
    axis.ticks.x = element_blank(), # remove os traços (ticks) do eixo x
    text = element_text(family = "Times")
  )

```

ANEXO C – SCRIPT PARA A REALIZAÇÃO DA ANÁLISE DE COMPONENTES PRINCIPAIS (PCA), ANÁLISE DE VARIÂNCIA E TESTE DE MÉDIA DE TUKEY.

```

# Carregar pacotes necessários
if (!require("ggplot2")) install.packages("ggplot2", dependencies = TRUE)
if (!require("factoextra")) install.packages("factoextra", dependencies = TRUE)

library(ggplot2)
library(factoextra)

# Padronizar os dados (opcional, mas recomendado)
dados_lidar <- scale(lidar)

# Calcular a PCA
pca <- prcomp(dados_lidar, center = TRUE, scale. = TRUE)

# Resumo da PCA
print("Resumo da PCA:")
print(summary(pca))

# Calcular os autovalores
autovalores <- (pca$sdev)^2
print("Autovalores (eigenvalues):")
print(autovalores)

# Percentual de variância explicada por cada componente
variância_explicada <- autovalores / sum(autovalores) * 100
print("Percentual de variância explicada:")
print(variância_explicada)

# Visualização da variância explicada
fviz_eig(pca,
  addlabels = TRUE, barfill = "lightgrey", barcolor = "black") +
  ggtitle("") +
  xlab("Componentes") +
  ylab("Porcentagem de variância explicada") +
  theme(text = element_text(family = "Times"))

# Biplot para visualizar os resultados da PCA
fviz_pca_biplot(pca,
  repel = TRUE, # Evita sobreposição de textos
  col.var = "red", # Cor das variáveis
  col.ind = "blue" # Cor dos indivíduos

```

```

) + ggtitle("Biplot da PCA")

## Selecionar fonte "Times New Roma"
windowsFonts("Times" = windowsFont("Times New Roman"))
windowsFonts(Times = windowsFont("Times New Roman"))

# Salvar os resultados da PCA (opcional)
pca_resultados <- data.frame(pca$x)
write.csv(pca_resultados, "resultados_pcaALOS.csv", row.names = TRUE)

#Ajuste com Regressão de Stepwise (Forward)

# LiDAR+ALOS
AGB <-lm(dados$Mg_ha~., data=dados)

modelo_AGB <- ols_step_forward_p(AGB_alos, penter = 0.05, prem = 0.1, details = TRUE)

Lidar_Alos <- lm(AGB_Mg ~ mean + pct55 + pct25 + skewness + pct20 + RVI_2 + kurtosis ,
data = Alos)
Alos_estimados <- predict(modelo_Alos)

Alos$AGB_estimados<- predict(modelo_Alos)

# Pacote ggplot2
library(ggplot2)

# Plot parcelas estimadas vs observadas
ggplot(Alos, aes(x = AGB_Mg, y = AGB_estimados)) +
  geom_point(shape = 21, fill = "white",color = "black", size = 3) +
  geom_abline(slope = 1, intercept = 0, color = "lightgrey", linetype = "dashed") +
  labs(
    x = "AGB referência (Mg/ha)",
    y = "AGB Estimado (Mg/ha)",
    title = " " ) +
  theme_minimal() +
  theme_minimal(base_family = "Times") + geom_smooth(method = "lm", color = "black", se
= FALSE)

# Análise de Variância (ANOVA)
ANOVA<-aov(AGB~Tratamento,data=dados)
summary(ANOVA)

#Teste e média
TukeyHSD (ANOVA)

```