

UNIVERSIDADE FEDERAL DO PARANÁ

CARLA TALITA PERTILLE

MODELAGEM DA BIOMASSA E DO CARBONO AÉREO DE *Eucalyptus* spp.
COM UAV-LIDAR: ABORDAGENS POR ÁREA E POR ÁRVORE INDIVIDUAL

CURITIBA

2026

CARLA TALITA PERTILLE

MODELAGEM DA BIOMASSA E DO CARBONO AÉREO DE *Eucalyptus* spp. COM
UAV-LIDAR: ABORDAGENS POR ÁREA E POR ÁRVORE INDIVIDUAL

Tese apresentada ao curso de Pós-Graduação em Engenharia Florestal, Área de Concentração em Manejo Florestal, Setor de Ciências Agrárias, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Doutor em Engenharia Florestal.

Orientadora: Profa. Dra. Ana Paula Dalla Corte

Coorientador: Prof. Dr. Alexandre Behling

Coorientador: Prof. Dr. Carlos Roberto Sanquetta

CURITIBA

2026

DADOS INTERNACIONAIS DE CATALOGAÇÃO NA PUBLICAÇÃO (CIP)
UNIVERSIDADE FEDERAL DO PARANÁ / SISTEMA DE BIBLIOTECAS
BIBLIOTECA DE CIÊNCIAS FLORESTAIS E DA MADEIRA

Pertille, Carla Talita

Modelagem da biomassa e do carbono aéreo de *Eucalyptus* spp.
com UAV-LiDAR: abordagens por área e por árvore individual / Carla
Talita Pertille. - Curitiba, 2026.

1 recurso on-line : PDF.

Orientadora: Profa. Dra. Ana Paula Dalla Corte

Coorientadores: Prof. Dr. Alexandre Behling

Prof. Dr. Carlos Roberto Sanquetta

Tese (Doutorado) - Universidade Federal do Paraná, Setor de
Ciências Agrárias, Programa de Pós-Graduação em Engenharia Florestal.
Defesa: Curitiba, 16/12/2025.

1. Fotogrametria aérea . 2. Sensoriamento remoto. 3. Biomassa.
4. Modelos matemáticos. 5. Carbono. 6. Eucalipto. 7. Aprendizado
do computador. I. Dalla Corte, Ana Paula. II. Behling, Alexandre.
III. Sanquetta, Carlos Roberto. IV. Universidade Federal do Paraná,
Setor de Ciências Agrárias. V. Título.

CDD – 634.9

CDU – 634.0.58



MINISTÉRIO DA EDUCAÇÃO
SETOR DE CIÊNCIAS AGRÁRIAS
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA
FLORESTAL - 40001016015P0

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação ENGENHARIA FLORESTAL da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de **CARLA TALITA PERTILLE**, intitulada: **Modelagem da biomassa e do carbono aéreo de *Eucalyptus* spp. com UAV-LiDAR: abordagens por área e por árvore individual**, sob orientação da Profa. Dra. ANA PAULA DALLA CORTE, que após terem inquirido a aluna e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de doutora está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 16 de Dezembro de 2025.

Assinatura Eletrônica
18/12/2025 08:22:32.0
ANA PAULA DALLA CORTE
Presidente da Banca Examinadora

Assinatura Eletrônica
18/12/2025 14:16:51.0
VAGNER ALEX PESCK
Avaliador Externo (UNIVERSIDADE ESTADUAL DO CENTRO-OESTE)

Assinatura Eletrônica
17/12/2025 19:49:29.0
ALLAN LIBANIO PELISSARI
Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica
17/12/2025 23:30:05.0
HUDSON FRANKLIN PESSOA VERAS
Avaliador Externo (INSTITUTO FEDERAL DO ACRE)

Assinatura Eletrônica
18/12/2025 09:04:28.0
DEIVISON VENICIO SOUZA
Avaliador Externo (UNIVERSIDADE FEDERAL DO PARÁ)

Avenida Lothário Meissner, 632 - CURITIBA - Paraná - Brasil CEP 80210-170 - Tel: (41) 3360-4212 - E-mail: pgfloresta@gmail.com

Documento assinado eletronicamente de acordo com o disposto na legislação federal Decreto 8539 de 08 de outubro de 2015.
Gerado e autenticado pelo SIGA-UFPR, com a seguinte identificação única: 504537

Para autenticar este documento/assinatura, acesse <https://siga.ufpr.br/siga/visitante/autenticacaoassinaturas.jsp> e insira o código 504537

Dedico esse trabalho ao
meu pai Carlos, a minha mãe Lenir e a minha irmã Fabiane.

AGRADECIMENTOS

Agradeço a Deus pela vida, pela proteção, pelas bênçãos e pelas oportunidades concedidas, bem como por todas as escolhas e conquistas que me permitiram chegar até este momento.

Agradeço imensamente a minha família, em especial ao meu pai Carlos, à minha mãe Lenir e à minha irmã Fabiane. Vocês são o meu alicerce e meu maior exemplo de amor e coragem. Obrigada pelo apoio incondicional, pelo carinho e pelo incentivo em todos os momentos.

Agradeço à minha orientadora, professora Ana Paula Dalla Corte, pela orientação, pela orientação, pelos ensinamentos, pela confiança e pelo suporte durante todas as etapas deste trabalho. Agradeço aos meus coorientadores, professores Carlos Roberto Sanquetta e Alexandre Behling, pela colaboração e pelas contribuições que foram importantes para a realização desta pesquisa. Também agradeço aos membros da banca examinadora pela avaliação e pelas contribuições para o aprimoramento deste trabalho.

Agradeço aos pesquisadores do Instituto de Pesquisas e Estudos Florestais (IPEF) e do *Le Centre de Coopération Internationale en Recherche Agronomique pour le Développement* (CIRAD) vinculados ao EUCFLUX, Otávio Camargo Campoe, Gueric le Maire e a Joannés Guillemot. Também agradeço a empresa Bracell, especialmente a Geovanni Malatesta Barros e Emerson Roberto Schoenninger além da empresa Floragro, pelo apoio na obtenção dos dados de campo. A todos os envolvidos no projeto EUCFLUX, agradeço pelo suporte na aquisição dos dados e pelas valiosas contribuições que enriqueceram esta pesquisa.

Agradeço aos meus amigos de longa data, especialmente a Fabiola, Graziela, Felipe, Bruno e Luana; aos amigos que pude conhecer ao longo dessa trajetória (especialmente a Karla Mayara Almada Gomes, Girlene Cruz e Vitoria Ferreira), a todos os integrantes e amigos do laboratório BIOFIX e aos amigos do laboratório de Manejo Florestal.

Agradeço ao Programa de Pós Graduação em Engenharia Florestal (PPGEF) da Universidade Federal do Paraná (UFPR) e a CAPES pela concessão da bolsa de estudos. Por fim, agradeço a todos que contribuíram direta ou indiretamente para a realização dessa pesquisa. Muito obrigada!

*“No que diz respeito ao empenho, ao compromisso,
ao esforço, à dedicação, não existe meio termo.
Ou você faz uma coisa bem-feita
ou não faz.” Ayrton Senna*

RESUMO

A estimativa da biomassa e do carbono acima do solo em plantios de *Eucalyptus* spp. é um tema central para o manejo sustentável e para a compreensão do ciclo do carbono. Diante desse contexto, abordagens que integram inventário florestal e Sensoriamento Remoto têm se destacado como ferramentas eficientes para a estimativa desses atributos. Essa pesquisa teve como objetivo quantificar o estoque de biomassa e de carbono acima do solo por compartimento, em genótipos de *Eucalyptus* spp., utilizando dados UAV-LiDAR a partir da abordagem a nível de área e por árvore individual. A área de estudo está localizada em São Paulo e integra o projeto EUCFLUX sendo formada por cinco blocos experimentais implantados em 2018 com 25 genótipos de *Eucalyptus* spp. O censo florestal ocorreu em maio de 2023 nas parcelas de cada genótipo. Em seguida, foi realizada a amostragem destrutiva em 150 árvores para a determinação da biomassa acima do solo. O voo UAV-LiDAR ocorreu na sequência, com um sensor *Zenmuse L1* embarcado em uma aeronave *DJI Matrice 300*. O processamento dos dados UAV-LiDAR envolveu a classificação dos retornos, geração dos modelos digitais e a extração das métricas. A biomassa por compartimento foi estimada a partir de uma adaptação do modelo de Schumacher-Hall, com inclusão do genótipo como variável *dummy*. Essa variável foi multiplicada por um teor de carbono de 46% para a obtenção do carbono acima do solo por compartimento. Para a construção dos modelos preditivos de biomassa e carbono, as métricas UAV-LiDAR foram selecionadas por Análise de Componentes Principais. Todos os modelos foram avaliados pelo coeficiente de determinação ajustado ($R^2_{ajustado}$) e a Raiz do Erro Quadrático Médio ou *Root Mean Square Error* (RMSE) e por medidas de concordância juntamente com o gráfico de Bland-Altman. Na abordagem a nível de área, o *Random Forest* (RF) se destacou nos compartimentos total e fuste, com $R^2_{ajustado}$ de 0,952 e 0,959 e RMSE abaixo de 5,5% para a biomassa. Para o carbono, o $R^2_{ajustado}$ foi de 0,952 e 0,961, com erro abaixo de 5,6%. Na copa, o *Extreme Gradient Boosting* (XGBoost) teve performance superior aos demais, com $R^2_{ajustado}$ de 0,765 e 0,707 e RMSE abaixo de 15,1% para a biomassa e o carbono acima do solo. Na abordagem individual, foram avaliados os métodos *Local Maxima Filter* (LMF), *Segment Anything Model* (SAM) e o *Detectron2* para a detecção de copas. O *Detectron2* apresentou a maior taxa de detecção, com 94%, seguido pelo SAM com 90% e pelo LMF com 54%. Na modelagem individual de biomassa e carbono acima do solo, o XGBoost apresentou o melhor desempenho, com $R^2_{ajustado}$ de até 0,961 e erro abaixo de 5,7% nos compartimentos total e fuste. Já na copa, o $R^2_{ajustado}$ foi de 0,84 e o RMSE foi inferior a 16,7%. A comparação entre as abordagens em nível de área e individual indicou diferenças médias de aproximadamente 25% para biomassa e carbono, evidenciando o desempenho consistente dos algoritmos e o potencial do UAV-LiDAR em análises multiescala para a quantificação de biomassa e carbono acima do solo.

Palavras-chave: métricas UAV-LiDAR; análise multiescala; detecção de copas; aprendizado de máquina; aprendizado profundo.

ABSTRACT

The estimation of aboveground biomass and carbon in *Eucalyptus* spp. plantations is a central topic for sustainable forest management and for understanding the carbon cycle. In this context, approaches that integrate forest inventory data and remote sensing have emerged as efficient tools for estimating these attributes. This study aimed to quantify aboveground biomass and carbon stocks by compartment in *Eucalyptus* spp. genotypes using UAV-LiDAR data at both area-based and individual-tree levels. The study area is located in the state of São Paulo, Brazil, and is part of the EUCFLUX project, comprising five experimental blocks established in 2018 with 25 *Eucalyptus* spp. genotypes. Forest inventory data were collected in May 2023 in the plots of each genotype. Subsequently, destructive sampling was carried out on 150 trees to determine aboveground biomass. The UAV-LiDAR survey was conducted thereafter using a Zenmuse L1 sensor mounted on a DJI Matrice 300 platform. UAV-LiDAR data processing included return classification, digital model generation, and metric extraction. Biomass by compartment was estimated using an adaptation of the Schumacher–Hall model, with genotype included as a dummy variable. This variable was multiplied by a fixed carbon content of 46% to obtain aboveground carbon by compartment. For the development of predictive biomass and carbon models, UAV-LiDAR metrics were selected using Principal Component Analysis. All models were evaluated using the adjusted coefficient of determination (adjusted R^2), Root Mean Square Error (RMSE), and concordance measures, together with Bland–Altman plots. At the area-based level, Random Forest (RF) showed the best performance for the total and stem compartments, with adjusted R^2 values of 0.952 and 0.959 and RMSE below 5.5% for biomass. For carbon, adjusted R^2 values were 0.952 and 0.961, with errors below 5.6%. For the crown compartment, Extreme Gradient Boosting (XGBoost) outperformed the other methods, with adjusted R^2 values of 0.765 and 0.707 and RMSE below 15.1% for aboveground biomass and carbon. At the individual-tree level, the Local Maxima Filter (LMF), Segment Anything Model (SAM), and Detectron2 were evaluated for tree crown detection. Detectron2 achieved the highest detection rate (94%), followed by SAM (90%) and LMF (54%). In individual-tree modeling of aboveground biomass and carbon, XGBoost achieved the best performance, with adjusted R^2 values up to 0.961 and RMSE below 5.7% for the total and stem compartments. For the crown compartment, the adjusted R^2 was 0.84 and RMSE was below 16.7%. The comparison between area-based and individual-tree approaches revealed average differences of approximately 25% for both biomass and carbon, highlighting the consistent performance of the algorithms and the strong potential of UAV-LiDAR data for multiscale estimation of aboveground biomass and carbon.

Keywords: UAV-LiDAR; Multiscale analysis; Tree crown detection; Machine Learning; Deep Learning.

LISTA DE FIGURAS

FIGURA 1 – DISTRIBUIÇÃO DAS FLORESTAS MUNDIAIS EM 2020	22
FIGURA 2 – EMISSÕES TOTAIS DE GEE NO BRASIL ENTRE 1990 E 2023	34
FIGURA 3 – PLATAFORMAS PARA AQUISIÇÃO DE DADOS LiDAR.....	37
FIGURA 4 – ÁREA EXPERIMENTAL COM <i>Eucalyptus</i> spp. EM ITATINGA, SÃO PAULO, BRASIL	44
FIGURA 5 – AMOSTRAGEM DESTRUTIVA DE <i>Eucalyptus</i> spp. EM ITATINGA, SÃO PAULO, BRASIL.....	48
FIGURA 6 – MODELAGEM DA BIOMASSA E DO CARBONO ACIMA DO SOLO DE <i>Eucalyptus</i> spp. A NÍVEL DE ÁREA	55
FIGURA 7 – VARIÁVEIS DENDROMÉTRICAS DE <i>Eucalyptus</i> spp. EM ITATINGA, SÃO PAULO, BRASIL.....	57
FIGURA 8 – BIOMASSA ACIMA DO SOLO MÉDIA ($\text{kg} \cdot \text{árv}^{-1}$) E CARBONO ACIMA DO SOLO MÉDIO ($\text{kg} \cdot \text{árv}^{-1}$) PELA AMOSTRAGEM DESTRUTIVA DE 150 ÁRVORES DE GENÓTIPOS DE <i>Eucalyptus</i> spp. EM ITATINGA, SÃO PAULO, BRASIL.....	58
FIGURA 9 – BIOMASSA ACIMA DO SOLO ($\text{kg} \cdot \text{árv}^{-1}$) POR COMPARTIMENTO EM GENÓTIPOS DE <i>Eucalyptus</i> spp.....	59
FIGURA 10 – ANÁLISE DE COMPONENTES PRINCIPAIS EM MÉTRICAS UAV-LIDAR EM GENÓTIPOS DE <i>Eucalyptus</i> spp.....	61
FIGURA 11 – MODELOS PREDITIVOS DE A) BIOMASSA ACIMA DO SOLO E B) CARBONO ACIMA DO SOLO POR COMPARTIMENTO EM <i>Eucalyptus</i> spp. COM ML E STEPWISE.....	64
FIGURA 12 – GRÁFICO DE BLAND-ALTMAN PARA OS MODELOS DE BIOMASSA ($\text{t} \cdot \text{ha}^{-1}$) TOTAL (A), DE FUSTE (B) E DE COPA (C) E DE CARBONO ($\text{t} \cdot \text{ha}^{-1}$) TOTAL (D), FUSTE (E) E COPA (F) EM <i>Eucalyptus</i> spp.	68
FIGURA 13 – GENÓTIPOS DE <i>Eucalyptus</i> spp. EM ITATINGA, SÃO PAULO, BRASIL	85
FIGURA 14 – COPAS DOS GENÓTIPOS DE <i>Eucalyptus</i> spp. EM ITATINGA, SÃO PAULO, BRASIL	88
FIGURA 15 – IMPLEMENTAÇÃO DO ALGORITMO SEGMENT ANYTHING MODEL PARA A DETECÇÃO DE COPAS DOS GENÓTIPOS DE <i>Eucalyptus</i> spp.	91

FIGURA 16 – IMPLEMENTAÇÃO DO DETECTRON2 PARA A DETECÇÃO DE COPAS DOS GENÓTIPOS DE <i>Eucalyptus</i> spp.	92
FIGURA 17 – DETECÇÃO E MODELAGEM INDIVIDUAL DE BIOMASSA E CARBONO ACIMA DO SOLO DE <i>Eucalyptus</i> spp.	95
FIGURA 18 – REPRESENTATIVIDADE DOS GENÓTIPOS DE <i>Eucalyptus</i> spp. NA DETECÇÃO MANUAL DAS COPAS	97
FIGURA 19 – DELIMITAÇÃO MANUAL DE COPAS DOS GENÓTIPOS 8 (A), 14 (B) E 25 (C) DE <i>Eucalyptus</i> spp. EM ITATINGA, SÃO PAULO, BRASIL	97
FIGURA 20 – DETECÇÃO DE COPAS COM LMF NOS GENÓTIPOS 16 (A) E 25 (B) DE <i>Eucalyptus</i> spp. NO BLOCO 2	99
FIGURA 21 – COPAS DE GENÓTIPOS DE <i>Eucalyptus</i> spp. IDENTIFICADAS COM SAM: A) GENÓTIPO 16; B) GENÓTIPO 25 NOS BLOCOS EXPERIMENTAIS	102
FIGURA 22 – DETECÇÃO DE COPAS DOS GENÓTIPOS 16 (A) E 25 (B) DE <i>Eucalyptus</i> spp. COM DETECTRON2	104
FIGURA 23 – MODELOS PREDITIVOS DE BIOMASSA INDIVIDUAL A) ACIMA DO SOLO, B) FUSTE e C) COPA E CARBONO INDIVIDUAL D) ACIMA DO SOLO, E) FUSTE E F) COPA (kg.árv ⁻¹) DE <i>Eucalyptus</i> spp.....	109
FIGURA 24 – GRÁFICO DE BLAND-ALTMAN PARA A BIOMASSA ACIMA DO SOLO INDIVIDUAL POR COMPARTIMENTO: TOTAL (A), FUSTE (B) E COPA (C) E DO CARBONO ACIMA DO SOLO TOTAL (D), FUSTE (E) E COPA (F) EM <i>Eucalyptus</i> spp.....	113

LISTA DE TABELAS

TABELA 1 – ÁREA FLORESTAL MUNDIAL EM 2020.....	22
TABELA 2 – CATEGORIA DE MÉTRICAS LiDAR.....	39
TABELA 3 – MODELOS HIPSOMÉTRICOS E VOLUMÉTRICOS TESTADOS EM <i>Eucalyptus</i> spp. EM ITATINGA.....	46
TABELA 4 – MÉTRICAS UAV-LiDAR OBTIDAS PARA OS GENÓTIPOS DE <i>Eucalyptus</i> spp. EM ITATINGA, SÃO PAULO, BRASIL.....	51
TABELA 5 – VALIDAÇÃO DOS MODELOS PREDITIVOS DE BIOMASSA E CARBONO ACIMA DO SOLO EM GENÓTIPOS DE <i>Eucalyptus</i> spp. COM REGRESSÃO LINEAR MÚLTIPLA.....	52
TABELA 6 – ALGORITMOS DE <i>MACHINE LEARNING</i> TESTADOS PARA A PREDIÇÃO DA BIOMASSA E DO CARBONO ACIMA DO SOLO DE GENÓTIPOS DE <i>Eucalyptus</i> spp. EM SÃO PAULO, BRASIL.	54
TABELA 7 – MEDIDAS DE CONCORDÂNCIA PARA A VALIDAÇÃO DA MODELAGEM DE BIOMASSA E CARBONO EM DIFERENTES COMPARTIMENTOS DE <i>Eucalyptus</i> spp.....	54
TABELA 8 – MODELOS HIPSOMÉTRICOS E VOLUMÉTRICOS TESTADOS EM <i>Eucalyptus</i> spp.....	56
TABELA 9 – AJUSTE HIPSOMÉTRICO TOTAL E ESTRATIFICADO DE TROREY EM <i>Eucalyptus</i> spp.	56
TABELA 10 – ESTIMATIVA DA BIOMASSA ACIMA DO SOLO EM DIFERENTES COMPARTIMENTOS EM <i>Eucalyptus</i> spp. PELO MODELO ADAPTADO DE SCHUMACHER-HALL.....	60
TABELA 11 – BIOMASSA ACIMA DO SOLO MÉDIA ($t \cdot ha^{-1}$) E CARBONO ACIMA DO SOLO MÉDIO ($t \cdot ha^{-1}$) POR COMPARTIMENTO DE GENÓTIPOS DE <i>Eucalyptus</i> spp. SÃO PAULO, BRASIL	60
TABELA 12 – MODELOS PREDITIVOS BASEADOS EM DADOS UAV-LiDAR PARA ESTIMATIVA DA BIOMASSA ACIMA DO SOLO ($t \cdot ha^{-1}$) E CARBONO ACIMA DO SOLO ($t \cdot ha^{-1}$) POR COMPARTIMENTO EM <i>Eucalyptus</i> spp.	63
TABELA 13 – MEDIDAS DE CONCORDÂNCIA DOS MODELOS PREDITIVOS DE BIOMASSA ACIMA DO SOLO ($t \cdot ha^{-1}$) E CARBONO ACIMA DO SOLO ($t \cdot ha^{-1}$) POR COMPARTIMENTO EM <i>Eucalyptus</i> spp.....	67

TABELA 14 – ESTIMATIVA DA BIOMASSA ACIMA DO SOLO ($t \cdot ha^{-1}$) E CARBONO ACIMA DO SOLO ($t \cdot ha^{-1}$) POR COMPARTIMENTO EM <i>Eucalyptus</i> spp. COM <i>STEPWISE</i> E ML	71
TABELA 15 – MEDIDAS DE ACURÁCIA PARA A VALIDAÇÃO DA DETECÇÃO DE COPAS DE <i>Eucalyptus</i> spp.	93
TABELA 16 – GRADE DE HIPER PARÂMETROS TESTADOS NOS ALGORITMOS DE <i>MACHINE LEARNING</i> PARA A PREDIÇÃO DA BIOMASSA E DO CARBONO ACIMA DO SOLO INDIVIDUAL DE GENÓTIPOS DE <i>Eucalyptus</i> spp. EM SÃO PAULO, BRASIL.	94
TABELA 17 – DETECÇÃO MANUAL DE COPAS DE <i>Eucalyptus</i> spp. EM SÃO PAULO, BRASIL	96
TABELA 18 – ACURÁCIA DA DETECÇÃO INDIVIDUAL DE <i>Eucalyptus</i> spp. COM LMF NOS CONJUNTOS DE TREINAMENTO E VALIDAÇÃO	98
TABELA 19 – TAXA DE DETECÇÃO DE COPAS DE GENÓTIPOS DE <i>Eucalyptus</i> spp. COM LMF	100
TABELA 20 – MEDIDAS DE ACURÁCIA DA DETECÇÃO DE COPAS DE GENÓTIPOS DE <i>Eucalyptus</i> spp. COM SAM.....	101
TABELA 21 – DETECÇÃO DE COPAS DE GENÓTIPOS DE <i>Eucalyptus</i> spp. COM SAM	103
TABELA 22 – MEDIDAS DE ACURÁCIA DA DETECÇÃO DE COPAS DE GENÓTIPOS DE <i>Eucalyptus</i> spp. COM DETECTRON2	104
TABELA 23 – DETECÇÃO DE COPAS DE <i>Eucalyptus</i> spp. COM <i>DETECTRON2</i> NA ÁREA EXPERIMENTAL EM ITATINGA, SÃO PAULO, BRASIL.....	105
TABELA 24 – IDENTIFICAÇÃO DE COPAS DE <i>Eucalyptus</i> spp. COM DIFERENTES MÉTODOS DE DETECÇÃO	106
TABELA 25 – BIOMASSA ACIMA DO SOLO INDIVIDUAL ($kg \cdot árv^{-1}$) E CARBONO ACIMA DO SOLO INDIVIDUAL ($kg \cdot árv^{-1}$) POR COMPARTIMENTO DE <i>Eucalyptus</i> spp. ESTIMADOS COM ML E UAV-LiDAR	107
TABELA 26 – MEDIDAS DE CONCORDÂNCIA DOS MODELOS PREDITIVOS DE BIOMASSA ACIMA DO SOLO ($kg \cdot árv^{-1}$) E DO CARBONO ACIMA DO SOLO ($kg \cdot árv^{-1}$) POR COMPARTIMENTO EM <i>Eucalyptus</i> spp. A NÍVEL INDIVIDUAL.....	112

TABELA 27 – COMPARATIVO DA BIOMASSA (t.ha ⁻¹) E DO CARBONO ACIMA DO SOLO INDIVIDUAL (t.ha ⁻¹) POR COMPARTIMENTO EM <i>Eucalyptus</i> spp. PELOS MÉTODOS DE DETECÇÃO	116
TABELA 28 – ESTIMATIVA DA BIOMASSA ACIMA DO SOLO (t.ha ⁻¹) E CARBONO ACIMA DO SOLO (t.ha ⁻¹) INDIVIDUAL POR COMPARTIMENTO EM <i>Eucalyptus</i> spp. COM DETECTRON2	117
TABELA 29 – COMPARATIVO DA BIOMASSA ACIMA DO SOLO (t.ha ⁻¹) E DO CARBONO ACIMA DO SOLO (t.ha ⁻¹) POR COMPARTIMENTO EM <i>Eucalyptus</i> spp. COM DIFERENTES ABORDAGENS: ÁREA X ÁRVORE INDIVIDUAL	126
TABELA 30 – TESTES ESTATÍSTICOS APLICADOS ÀS ESTIMATIVAS DE BIOMASSA (t.ha ⁻¹) E CARBONO ACIMA DO SOLO (t.ha ⁻¹) POR COMPARTIMENTO EM <i>Eucalyptus</i> spp. E POR ABORDAGEM: ÁREA X INDIVÍDUO	127

LISTA DE ABREVIATURAS OU SIGLAS

ALS	<i>Airborne Laser Scanning</i>
ANN	<i>Artificial Neural Network</i>
CH ₄	Metano
CHM	<i>Canopy Height Model</i>
CO ₂	Dióxido de carbono
CO _{2eq}	Carbono equivalente
DL	<i>Deep Learning</i>
DSM	<i>Digital Surface Model</i>
DTM	<i>Digital Terrain Model</i>
EUCFLUX	Programa Cooperativo sobre Produtividade e Fluxos de Carbono e Água em Eucalyptus (fase 2)
FAO	<i>Food and Agriculture Organization</i>
GEE	Gases de Efeito Estufa
IPEF	Instituto de Pesquisas Florestais
IPCC	<i>Intergovernmental Panel of Climate Change</i>
IPPU	<i>Industrial Processes and Use of Products</i>
kNN	<i>k-Nearest Neighbor</i>
LIDAR	<i>Light Detection and Ranging</i>
LASER	<i>Light Amplification by Stimulated Emission of Radiation</i>
LMF	<i>Local Maxima Filter</i>
ML	<i>Machine Learning</i>
N ₂ O	Óxido Nitroso
NOAA	<i>National Oceanic and Atmospheric Administration</i>
RF	<i>Random Forest</i>
SAM	<i>Segment Anything Model</i>
SEEG	Sistema de Estimativas de Emissões e Remoções de Gases de Efeito Estufa
SVR	<i>Support Vector Regression</i>
UAV	<i>Unmanned Aerial Vehicle</i>
UNFCCC	<i>United Nations Framework Convention on Climate Change</i>
XGB	<i>Extreme Gradient Boosting</i>

SUMÁRIO

1 INTRODUÇÃO	19
1.1 HIPÓTESE	20
1.2 OBJETIVOS	20
1.2.1 Objetivo geral	21
1.2.2 Objetivos específicos.....	21
2 REVISÃO DE LITERATURA	22
2.1 SETOR FLORESTAL	22
2.2 DINÂMICA DO CARBONO EM FLORESTAS.....	25
2.2.1 Estimativa de biomassa e carbono.....	26
2.3 MUDANÇAS CLIMÁTICAS	30
2.3.1 Efeito estufa e aquecimento global	30
2.3.2 Emissões de GEE	33
2.4 <i>LIGHT DETECTION AND RANGING</i> (LIDAR).....	34
3 ESTIMATIVA DA BIOMASSA E DO CARBONO DE GENÓTIPOS DE <i>Eucalyptus</i> spp. COM UAV-LIDAR COM ABORDAGEM A NÍVEL DE ÁREA E APRENDIZADO DE MÁQUINA	40
3.1 INTRODUÇÃO	41
3.2 MATERIAL E MÉTODOS	43
3.2.1 Descrição da área	43
3.2.2 Censo florestal	46
3.2.3 Quantificação da biomassa e do carbono acima do solo	47
3.2.4 Varredura UAV-LiDAR.....	49
3.2.5 Abordagem a nível de área	51
3.3 RESULTADOS.....	56
3.3.1 Censo florestal e amostragem destrutiva da biomassa acima do solo	56
3.3.2 Modelagem da biomassa e carbono acima do solo	61
3.4 DISCUSSÃO	72
3.5 CONCLUSÃO	80
4 DETECÇÃO E MODELAGEM INDIVIDUAL DE BIOMASSA E CARBONO ACIMA DO SOLO DE GENÓTIPOS DE <i>Eucalyptus</i> spp. COM UAV-LIDAR	82
4.1 INTRODUÇÃO	83
4.2 MATERIAL E MÉTODOS	85

4.2.1 Descrição da área	85
4.2.2 Estoque de biomassa e carbono acima do solo	86
4.2.3 UAV-LiDAR	87
4.2.4 Detecção manual	88
4.2.5 Detecção automática.....	89
4.2.5.1 <i>Local Maximum Filter</i> (LMF)	89
4.2.5.2 <i>Segment Anything Model</i> (SAM)	90
4.2.5.3 <i>Detectron2</i>	91
4.2.5.4 Acurácia de detecção	93
4.2.6 Modelagem individual de biomassa e carbono acima do solo.....	93
4.3 RESULTADOS	96
4.3.1 Detecção manual	96
4.3.2 Detecção automática.....	98
4.3.2.1 <i>Local Maximum Filter</i> (LMF)	98
4.3.2.2 <i>Segment Anything Model</i> (SAM)	101
4.3.2.3 <i>Detectron2</i>	103
4.3.2.4 Comparação dos métodos de detecção automática.....	106
4.3.3 Modelagem individual de biomassa e carbono acima do solo.....	106
4.4 DISCUSSÃO	118
4.5 CONCLUSÃO	123
5 ANÁLISE COMPARATIVA DAS ABORDAGENS A NÍVEL DE ÁREA E POR	
ÁRVORE INDIVIDUAL NA ESTIMATIVA DE BIOMASSA E CARBONO ACIMA DO	
SOLO EM <i>Eucalyptus</i> spp	124
5.1 INTRODUÇÃO	124
5.2 MATERIAL E MÉTODOS	124
5.3 RESULTADOS	125
5.4 DISCUSSÃO	127
5.5 CONCLUSÃO	128
6 CONSIDERAÇÕES FINAIS	129
6.1 RECOMENDAÇÕES PARA TRABALHOS FUTUROS	130
REFERÊNCIAS	132
ANEXO 1	146

1 INTRODUÇÃO

A preocupação global com as alterações climáticas está cada vez mais proeminente, especialmente pelos impactos negativos capazes de comprometer a saúde do planeta de forma irreversível, além da interferência no sistema econômico mundial (FU; LU; PIRABI, 2024). Nesse contexto, as emissões excessivas de Gases de Efeito Estufa (GEE) corroboram para o agravamento do aquecimento global e para o aumento da temperatura terrestre, fato já destacado nas projeções climáticas divulgadas pelo relatório anual do *Intergovernmental Panel on Climate Change* – IPCC (IPCC, 2023).

Diante do enfrentamento da emergência climática, as florestas possuem relevante notoriedade frente à mitigação das mudanças climáticas e à redução das emissões de GEE. Esse potencial foi reconhecido e apontado em pesquisas científicas como o maior e mais econômico sumidouro de carbono, atraindo atenção nas negociações climáticas globais (SHI *et al.*, 2022).

Considerando o expressivo potencial florestal do Brasil, com cerca de 10,5 milhões de hectares de florestas plantadas e aproximadamente 7 milhões de hectares de florestas conservadas (IBÁ, 2025), as florestas se destacam pela absorção de carbono atmosférico. Dessa forma, a determinação do estoque de carbono e da biomassa florestal é imprescindível para a gestão dos recursos florestais no que tange aos acordos e tratados climáticos adotados pelo país.

A quantificação da biomassa e do carbono em florestas exige estimativas fidedignas (SANQUETTA, 2002). Para isso, podem ser utilizados métodos diretos, como a derrubada e a pesagem das árvores e métodos indiretos, que estimam a biomassa e o carbono a partir de equações (SANQUETTA, 2002). Dentre eles, os métodos diretos utilizam amostragem destrutiva, ou seja, a separação e a pesagem dos compartimentos em campo e posterior secagem das mesmas, necessitando de maior tempo de execução, além do alto custo, especialmente em áreas com maiores extensões (FU *et al.*, 2015, SANQUETTA, 2004).

Já os métodos indiretos possuem maior aplicabilidade (RUIZ-VILLANUEVA *et al.*, 2016), devido à sua maior eficiência operacional e ao menor custo, pela geração de estimativas em larga escala, ao monitoramento contínuo e à integração com outras técnicas e abordagens. Considerando os métodos indiretos, evidencia-se a crescente utilização de dados de Sensoriamento Remoto, como a tecnologia *Light*

Detection and Ranging (LiDAR), possibilitando a obtenção de informações da estrutura da floresta com alto nível de precisão (CORTE *et al.*, 2022; GIONGO *et al.*, 2010; LI; JIANG, 2024; XU *et al.*, 2025).

O potencial da tecnologia LiDAR vinculado a sensores com varredura aérea (*Airborne Laser Scanning* - ALS) vêm sendo investigado para a determinação do estoque de carbono em plantios florestais (BAI; PANG; KONG, 2024; FAN *et al.*, 2024; JIANG *et al.*, 2023; LIU *et al.*, 2024; ZHANG *et al.*, 2024). Para isso, métricas derivadas de dados LiDAR e estimativas baseadas em variáveis dendrométricas têm sido relacionadas, em diferentes escalas de análise desde abordagens em nível de área, na qual atributos estatísticos são extraídos para a área de interesse (parcela ou povoamento) (WHITE *et al.*, 2017) até abordagens a nível de árvore individual, com a detecção dos indivíduos e posterior estimativa individual da biomassa e do carbono acima do solo (CAMPBELL *et al.*, 2023; DUBROVIN *et al.*, 2024; LIN *et al.*, 2024).

Diante disso, esse estudo foi baseado na seguinte questão: A utilização da tecnologia UAV-LiDAR com diferentes abordagens tem potencial para a quantificação da biomassa e do carbono acima do solo em genótipos de *Eucalyptus* spp.? Esta pergunta será respondida ao longo dos capítulos dessa tese, que avaliam o potencial da tecnologia UAV-LiDAR na estimativa da biomassa e do carbono acima do solo em *Eucalyptus* spp. considerando diferentes escalas de análise, por meio da abordagem a nível de área e por árvore individual.

1.1 HIPÓTESE

Para isso, a seguinte hipótese foi formulada:

H₀: as estimativas realizadas com as abordagens em nível de área e em nível de árvore individual obtidas com dados UAV-LiDAR não apresentam diferenças estatisticamente significativas em relação às estimativas de biomassa e carbono acima do solo obtidas pelo censo florestal tradicional, bem como, não apresentam diferenças significativas entre si.

1.2 OBJETIVOS

Este trabalho propõe-se a desenvolver os seguintes objetivos:

1.2.1 Objetivo geral

Avaliar o desempenho de duas abordagens baseadas em dados UAV-LiDAR (unidade de área e árvore individual) para a estimativa da biomassa e do estoque de carbono acima do solo em diferentes genótipos de *Eucalyptus* spp. em comparação ao censo florestal.

1.2.2 Objetivos específicos


- i) Estimar a biomassa e o carbono acima do solo em diferentes compartimentos, por abordagem a nível de área, em genótipos de *Eucalyptus* spp., integrando dados UAV-LiDAR de alta densidade e técnicas de modelagem;
- ii) Detectar, de forma automática, os indivíduos de *Eucalyptus* spp. e estimar, a biomassa acima do solo e o carbono acima do solo por compartimento sob a abordagem de árvore individual com distintas técnicas de modelagem;
- iii) Avaliar estatisticamente o desempenho das estimativas por unidade de área e por árvore individual em relação ao censo florestal.

2 REVISÃO DE LITERATURA

2.1 SETOR FLORESTAL

Segundo o último relatório divulgado pela *Food and Agriculture Organization* (FAO) em 2020, o *Global Forest Resources Assessment* (FRA), as florestas ocupavam, em 2020, cerca de 4,06 bilhões de hectares representando 31% da área total mundial (FAO, 2020). As florestas tropicais possuem a maior extensão (45%), seguidas pelas florestas boreais (27%), temperadas (16%) e subtropicais (11%) (FIGURA 1) (FAO, 2020):

FIGURA 1 – DISTRIBUIÇÃO DAS FLORESTAS MUNDIAIS EM 2020



FONTE: FAO (2020).

O relatório também apontou que, mais da metade da área florestal localiza-se em cinco países (Rússia, Brasil, Canadá, Estados Unidos e China), enquanto os dez países com as maiores coberturas florestais (TABELA 1) representavam aproximadamente 66% da área total mundial (FAO, 2020a).

TABELA 1 – ÁREA FLORESTAL MUNDIAL EM 2020

País	Área (ha)	Área (%)
Rússia	815.312	20%
Brasil	496.620	12%
Canadá	346.928	9%
Estados Unidos	309.795	8%
China	219.978	6%
Austrália	134.005	3%
República do Congo	126.155	3%

País	Área (ha)	Área (%)
Indonésia	92.133	2%
Peru	72.330	2%
Índia	72.160	2%
Total	2.685.416	66%

FONTE: FAO (2020).

A grande extensão florestal no Brasil está relacionada com a implantação dos plantios florestais no país. Em 1904, Edmundo Navarro de Andrade introduziu algumas espécies de *Eucalyptus* spp. para a geração de produtos para a Companhia Paulista de Estradas de Ferro (MARTINI, 2009) cuja adaptação em terras brasileiras favoreceu a expansão das florestas plantadas, sendo um dos principais marcos dessa atividade.

Essa expansão também foi influenciada pela instituição de marcos legais, como algumas políticas públicas oriundas da promulgação do Código Florestal Brasileiro de 1934 (Decreto nº 23.793/1934) (BRASIL, 1934), pela Lei dos Incentivos Fiscais (Lei nº 5.106/1966) (BRASIL, 1966), pela substituição do Código Florestal em 1965 (Lei nº 4.771/1965) (BRASIL, 1965) e posterior atualização em 2012 (Lei nº 12.651/2012) (BRASIL, 2012).

A primeira legislação citada estabeleceu regras de exploração florestal e defendeu a proteção às florestas (BRASIL, 1934), enquanto a Lei instituída em 1966 favoreceu a utilização de descontos nas declarações de rendimentos de pessoas físicas ou jurídicas dos recursos empregados em áreas com florestas (CASTILHO *et al.*, 2016). Tais fatores aliados a promulgação do Código Florestal de 1965 possibilitaram o estabelecimento de plantios em grandes escalas para o abastecimento de fábricas, cuja principal matéria prima era a madeira.

Porém, ao longo do tempo, tais regulamentos tornaram-se restritivos quanto ao uso e exploração de florestas nativas. Tal fato também contribuiu para a maior visibilidade das florestas plantadas, pois essas espécies tornaram-se primordiais no fornecimento de matéria prima para a confecção de inúmeros produtos de madeira e como ferramentas de proteção ambiental contra o desmatamento das florestas nativas.

A representatividade das florestas plantadas brasileiras pode ser visualizada no relatório da Indústria Brasileira de Árvores (IBÁ). Nesse relatório, em 2024, os plantios de *Eucalyptus* spp. e *Pinus* spp. ocupavam 10,5 milhões de hectares, sendo 8,1 milhões de hectares de *Eucalyptus* spp. (em torno de 76%) com produtividade

média de $34,4 \text{ m}^3.\text{ha}^{-1}.\text{ano}^{-1}$ (IBÁ, 2025). O gênero *Pinus* spp. totalizou 1,9 milhões de hectares (aproximadamente 19%) com produtividade média de $31,1 \text{ m}^3.\text{ha}^{-1}.\text{ano}^{-1}$ (IBÁ, 2025). Ainda constam 500 mil hectares (5%) plantados com outras espécies, como a seringueira, acácia e teca (IBÁ, 2025). O referido relatório também revelou que o Brasil possui aproximadamente 7 milhões de hectares de florestas conservadas, responsáveis pelo armazenamento de 5 bilhões de toneladas de $\text{CO}_{2\text{eq}}$ (IBÁ, 2025).

No Brasil, além da responsabilidade ambiental o setor florestal possui ampla relevância comercial e social, pela extensa cobertura de florestas e pela geração de emprego e renda. Tais fatores são consequências da expansão florestal ocorrida desde 1900, a qual foi favorecida pelo desenvolvimento tecnológico no plantio, a condução, o manejo, a colheita de florestas e a sua posterior industrialização (RODRIGUES *et al.*, 2021). A aplicação de novas tecnologias e os avanços no melhoramento genético e desenvolvimento de clones contribuem para o aumento da produtividade florestal (IBÁ, 2023).

A demanda crescente por produtos de origem florestal está diretamente relacionada com o crescimento populacional e a maior acessibilidade e popularização dos produtos oriundos da madeira, caracterizando a floresta como um bem precioso e estratégico (IBÁ, 2025). Dessa forma, o setor é responsável pela geração de produtos destinados para o mercado de produtos madeireiros, celulose e papel, painéis de madeira, laminação, carvão vegetal, construção civil e outros fins (IBÁ, 2025). Essa produção gerou um valor bruto de produção foi estimado em R\$ 240 bilhões e geração de 2,8 milhões de empregos diretos e indiretos (IBÁ, 2025).

Além da participação econômica citada anteriormente, o setor florestal destaca-se pela manutenção do clima regional e global (ESPERON-RODRIGUEZ *et al.*, 2022) especialmente para a mitigação do impacto das emissões do dióxido de carbono (CO_2) pela conversão do carbono atmosférico em biomassa florestal (PSISTAKI; TSANTOPOULOS; PASCHALIDOU, 2024). Diante disso, a atuação das florestas como fontes e e/ou sumidouros de carbono atmosférico será explorado no próximo item.

2.2 DINÂMICA DO CARBONO EM FLORESTAS

As florestas são reservatórios abundantes de carbono orgânico, água e energia na natureza. Portanto, sendo o principal mecanismo dos ecossistemas terrestres, as florestas, possuem ampla biodiversidade, estrutura e processos ecológicos complexos, sendo determinantes para a sobrevivência e desenvolvimento das condições de vida terrestre (ZHAO *et al.*, 2022).

Com cobertura de aproximadamente 4 bilhões de hectares ou 31% da superfície terrestre (FAO, 2020a), os ecossistemas florestais são componentes importantes dos ciclos de carbono terrestre, podendo absorver aproximadamente 7,6 bilhões de toneladas de $\text{CO}_2\cdot\text{ano}^{-1}$ com potencial de remoção de 25 a 30% das emissões antrópicas anualmente (HARRIS *et al.*, 2021). Além disso, as florestas podem emitir, em média, 8 bilhões de toneladas de $\text{CO}_2\cdot\text{ano}^{-1}$ decorrentes de desmatamento e degradação (HARRIS *et al.*, 2021). Dados recentes indicam que entre 2001 e 2023, os ecossistemas florestais globais foram responsáveis pela emissão de $9,0 \pm 2,7 \text{ Gt CO}_{2\text{eq}}\cdot\text{ano}^{-1}$ de emissões de GEE e pela remoção de $-14,5 \pm 7,7 \text{ Gt CO}_{2\text{eq}}\cdot\text{ano}^{-1}$, resultando em um balanço de $-5,5 \pm 8,1 \text{ Gt CO}_{2\text{eq}}\cdot\text{ano}^{-1}$ (GIBBS *et al.*, 2024).

As relações entre o clima e as florestas são amplamente discutidas e conhecidas, especialmente a remoção de carbono da atmosfera. Esse processo é oriundo da interação entre as florestas com o ambiente, por meio da fotossíntese, respiração, decomposição e outras emissões relacionadas com perturbações como fogo, desmatamento ou exploração florestal. Tais fenômenos podem alterar os estoques líquidos de carbono definindo a função do ecossistema florestal: fonte de emissão ou um sumidouro (PSISTAKI; TSANTOPOULOS; PASCHALIDOU, 2024).

O armazenamento de carbono pelas árvores varia com o tempo de estoque, permanecendo no indivíduo arbóreo sob as formas de sacarose, amido ou celulose. No primeiro, o carbono é transportado e utilizado na respiração rapidamente, caracterizando um armazenamento de curto prazo. Sendo como amido, o tempo de armazenamento poderá ser maior, como alguns dias ou meses. No caso da celulose, o carbono removido da atmosfera estará presente na celulose ou lignina, perdurando por todo o ciclo de vida na planta (BUCKERIDGE; CAVALARI; SILVA, 2008).

Diversos fatores podem afetar a capacidade de remover e armazenar carbono em uma floresta. Segundo Yao, Piao e Wang (2018), 45% do carbono pode ser estocado nas árvores, ao passo que o IPCC (2006) revela um potencial de aproximadamente 50%.

Florestas jovens, por exemplo, estocam menores quantidades de carbono, contudo, a absorção de carbono é maior. Nas florestas adultas, ocorre o processo inverso: é maior a quantidade de carbono armazenado e menor o potencial de captura de carbono da atmosfera, ao ser comparado com áreas que apresentam regeneração natural (SEDJO, 2001).

Arevalo, Alegre e Vilcahuaman (2002) corroboram sugerindo que a espécie, a taxa de crescimento, o tipo de sítio, o clima e o período de rotação também podem interferir na capacidade de absorção de carbono.

Como o crescimento possui ligação direta com o acúmulo de biomassa, o espaçamento também deve ser considerado, por influenciar o desenvolvimento das plantas, delimitando a quantidade de recursos (principalmente luz, água e nutrientes) que cada árvore irá receber (STAPE *et al.*, 2010).

As práticas de manejo florestal também são pontuadas por Pussinen *et al.* (2002) como fatores de influência. Estratégias de manejo como intensidades de desbastes, número de anos do ciclo e tratamentos silviculturais, podem determinar a função das florestas como dreno ou sumidouros de carbono. De acordo com o horizonte de planejamento, os fluxos de carbono podem ser otimizados em períodos menores, como 30 a 40 anos, ou períodos ainda maiores (SCHMID *et al.*, 2006).

Zhao *et al.* (2022) sugerem que as alterações existentes no ciclo do carbono em florestas abrangem diferentes estações, períodos interanuais com variações de acordo com as condições ambientais, climáticas e com os tipos de vegetação.

Sabendo que o estoque de carbono é dependente da produção total de biomassa da floresta, os principais métodos de obtenção de biomassa e carbono em plantios comerciais serão descritos a seguir.

2.2.1 Estimativa de biomassa e carbono

Segundo Silveira *et al.* (2008) a biomassa pode ser definida como a massa viva ou morta, animal ou vegetal de origem biológica. Seu acúmulo está relacionado com fatores ambientais e inerentes à própria árvore, principalmente os que afetam a

fotossíntese e a respiração, como luz, temperatura, umidade, fertilidade do solo, acúmulo de CO₂ no ar, além de questões indiretas como pragas e doenças (LEMOS *et al.*, 2010).

Complementando as definições citadas, as concentrações da biomassa vegetal, constituída por carbono e minerais, variam de acordo com a espécie, fase de desenvolvimento, estado nutricional e condições edafoclimáticas. Larcher (2000) afirma que biomassa aérea é formada por, em média, 50% de carbono, 43% de oxigênio, 6% de hidrogênio e 1% de outros elementos minerais, podendo variar com a espécie, fase de desenvolvimento, estado nutricional e condições edafoclimáticas.

Higa *et al.* (2014) definem biomassa como: “total de matéria orgânica, morta ou viva, tanto acima quanto abaixo do solo, existente nos organismos (animais ou vegetais) de uma determinada comunidade”. E, para florestas, a biomassa viva é formada por troncos, galhos, raízes, cascas, sementes e folhagens. Já a biomassa morta é formada por serrapilheira, galhos e troncos caídos, além da biomassa morta abaixo do solo. O somatório da biomassa viva e morta resulta na biomassa total (HIGA *et al.*, 2014).

Outros autores afirmam que a biomassa florestal possui complexidade por integrar processos funcionais e atributos estruturais da floresta, como área basal, altura, densidade da madeira e produtividade (RÉJOU-MÉCHAIN *et al.*, 2017).

Conforme já retratado, a biomassa pode ser dividida em acima ou abaixo da superfície do solo. A biomassa acima do solo ou *Above Ground Biomass* (AGB) refere-se a toda biomassa vegetal viva lenhosa e herbácea acima do solo incluindo caule, galhos, cascas, sementes e folhagens (IPCC, 2007). Já a biomassa abaixo do solo ou *Below Ground Biomass* (BGB) envolve todos os órgãos vivos abaixo da linha do solo cujas funções são a fixação da vegetação, captação e transferência de recursos (IPCC, 2007). Segundo Ratuchne *et al.* (2016), corresponde a biomassa das raízes vivas, tendo contribuição significativa para a composição da biomassa total.

De acordo com IPCC (2014) a maior porcentagem de biomassa em uma espécie florestal encontra-se no fuste (madeira e casca). Isso deve-se a fase inicial de desenvolvimento de uma floresta, na qual grande parte de carboidratos é canalizada para a produção de biomassa da copa.

O entendimento das alterações na quantidade de biomassa florestal são fundamentais para o balanço do carbono nas florestas (PSISTAKI;

TSANTOPOULOS; PASCHALIDOU, 2024). A distribuição espacial e temporal dessa variável favorece a avaliação dos impactos dos processos de conversão e uso do solo e os impactos do efeito das mudanças climáticas, pois, ambos alteram o papel das florestas no ciclo global do carbono (SALUNKHE *et al.*, 2018).

Segundo Gonçalves (2024), para o primeiro reservatório de biomassa, os métodos de quantificação podem ser divididos em diretos e indiretos. Também podem ser baseados em fisiologia, em medições de fluxo de carbono, densidade do povoamento, inventário florestal ou por técnicas de detecção remota a partir de dados derivados de Sensoriamento Remoto.

Ainda de acordo com Gonçalves (2024), os métodos diretos são caracterizados por amostragem destrutiva e executados em campo, sendo possível obter medidas reais de uma dada área de interesse com alto grau de precisão. Tal metodologia resulta em uma medida real efetuada diretamente na biomassa. Porém, o tempo exigido para sua execução e seu custo, são fatores restritivos para sua operacionalização, além da inacessibilidade de áreas (FU *et al.*, 2015).

Os métodos indiretos, por sua vez, geram estimativas (RATUCHNE *et al.*, 2016; SANQUETTA, 2002) permitindo a escalabilidade em grandes áreas (GONÇALVES, 2024). Esses métodos utilizam equações alométricas combinadas com dados oriundos de SR (GONÇALVES, 2024).

Os métodos diretos permitem a obtenção de variáveis dendrométricas como o Diâmetro à Altura do Peito (D) e altura da árvore, resultando na estimativa do volume e densidade da madeira (GONÇALVES, 2024; SALUNKHE *et al.*, 2018). Para a estimativa da biomassa, esses dados podem ser aplicados em equações alométricas, especialmente em florestas homogêneas pela menor variabilidade, permitindo o uso de parâmetros para a espécie (GONÇALVES, 2024; SALUNKHE *et al.*, 2018).

A aplicação das equações alométricas, segundo Cunha Neto *et al.* (2022) geralmente ocorre de forma independente, ou seja, um ajuste para cada compartimento da árvore ou da floresta. Dessa maneira, os autores explicam que não há aditividade, pela existência de diferentes resultados entre a biomassa total e os compartimentos. Para preencher essa lacuna, diversos estudos buscam a aditividade dos compartimentos da biomassa, para que o somatório possa refletir a biomassa aérea total, como pode-se citar as pesquisas de Behling *et al.* (2019) e Behling, Koehler e Behling (2020).

Ainda nesse sentido, Coutinho *et al.* (2021) indicam três premissas que devem ser atendidas na aplicação de equações alométricas: i) performance na qualidade das estimativas de biomassa, ii) consistência, ou seja, aditividade dos componentes com a biomassa total e iii) eficiência dos estimadores das equações para diminuir a variância dos parâmetros estimados.

A precisão na quantificação das emissões e da remoção de carbono está relacionada com a representatividade das equações alométricas, o tamanho das amostras, a quantidade diversificada de carbono nas diferentes espécies de árvores, além da heterogeneidade da distribuição de carbono nos ecossistemas florestais (FU *et al.*, 2015).

Em relação as amostras utilizadas, deve-se atentar para a representatividade, abrangência e validação estatística além de considerar os três estimadores (intensidade amostral, erro de amostragem e intervalo de confiança) (SANQUETTA; ZILLOTTO; CORTE, 2006). Em florestas plantadas, Higa *et al.* (2014) recomendam o processo de amostragem sistemática, por representar toda a área plantada, com a alocação dos pontos em formato de *grid*.

De acordo com Sanquetta, Zillio e Corte (2006), as principais etapas para a determinação da biomassa florestal em processos de campo e de laboratório, compreendem:

- i) Seleção da árvore ou parcela a ser amostrada;
- ii) Medições das variáveis dendrométricas altura e diâmetro à altura do peito e medições de variáveis da copa;
- iii) Cortes e separação da biomassa fina e obtenção da biomassa de maior porte (fustes, casca, galhos, folhas e raízes);
- iv) Obtenção dos discos de madeira na base, D e parte inferior da copa;
- v) Pesagem das amostras;
- vi) Preparação das amostras para o laboratório e secagem do material;
- vii) Determinação dos pesos secos das amostras além da determinação da densidade básica do lenho;
- viii) Divisão do material e moagem para a obtenção das amostras que serão utilizadas para a quantificação dos teores de carbono.

Para a determinação do carbono, um dos métodos mais utilizados refere-se a combustão úmida ou seca. Na combustão seca, os materiais são inseridos em

recipientes de cerâmica e posteriormente no equipamento, no qual permanecem 60 segundos. Nesse período, a combustão é realizada, determinando o teor de carbono do material (SANQUETTA; ZILLOTTO; CORTE, 2006). Nesse método, os aparelhos utilizados, como analisadores elementares, determinam o tempo de combustão bem como o teor de carbono de cada amostra (SANQUETTA *et al.*, 2019).

Por fim, o IPCC também recomenda a utilização de equações de correções e fatores de expansão (IPCC, 2002). Assim, para converter a biomassa do fuste em biomassa aérea utiliza-se o fator de expansão da biomassa ou *Biomass Expansion Factor* (BEF) e o volume comercial de madeira, sendo convertido em biomassa acima do solo pelo fator de conversão de biomassa (IPCC, 2006). Para a biomassa abaixo do solo, dispõe-se da razão de raízes (R), o qual relaciona a biomassa aérea com a biomassa subterrânea (SANQUETTA *et al.*, 2019).

Diante da relevância dos sumidouros de carbono e do seu papel na redução do carbono atmosférico, que, por sua vez, está diretamente relacionado à mitigação dos efeitos das mudanças climáticas, o próximo tópico irá abordar as mudanças climáticas e seus impactos.

2.3 MUDANÇAS CLIMÁTICAS

2.3.1 Efeito estufa e aquecimento global

A temperatura da superfície da Terra é mantida por um fenômeno conhecido como efeito estufa, influenciado pelo equilíbrio entre a radiação solar oriunda do Sol e a radiação irradiada para o espaço. Estima-se que, aproximadamente metade dessa energia advinda seja absorvida por nuvens ou refletida para o espaço. A superfície terrestre absorve o restante, aumentando a temperatura.

De acordo com Ollila (2019) o fenômeno efeito estufa refere-se ao aquecimento adicional da atmosfera junto a superfície do planeta, intensificado pela concentração de alguns gases, que por sua vez, são transparentes à luz solar que aquece o planeta. Tais gases impedem a passagem das ondas de calor emitidas pelo planeta para o espaço externo.

Naturalmente, o efeito estufa causado pela atmosfera é uma pré-condição para a manutenção da vida terrestre (OLLILA, 2019) e os gases dióxido de carbono (CO₂), metano (CH₄), óxido nitroso (N₂O), hidrofluorcarbonos (HFCs),

perfluorcarbonos (PFCs) e hexafluoreto de enxofre (SF₆) podem ser encontrados na atmosfera impedindo a saída da radiação solar (OLLILA, 2019). Sem esses gases formando um “cobertor” ao redor da Terra, a radiação solar seria dissipada no espaço, tornando a superfície terrestre 33°C mais fria (OLLILA, 2019).

Porém, quando as concentrações de GEE estão em excesso na atmosfera, a radiação solar forma uma barreira no entorno de sua superfície, que elevam a sua temperatura e causam o aquecimento global, definido pelo IPCC (2007) como:

Aumento gradual (observado ou projetado) na temperatura da superfície global, como uma das consequências do forçamento radioativo (mudança na irradiação vertical líquida) causado pelas emissões antropogênicas (IPCC, 2007).

Com o aumento da temperatura decorrente dessas emissões, a concentração média global de CO₂ na atmosfera aumentou de 278 partes por milhão (ppm) em 1750 (GULEV *et al.*, 2021) para, aproximadamente, 419,2 ppm em 2023 (FRIEDLINGSTEIN *et al.*, 2023).

Conforme explorado anteriormente, a elevada concentração de GEE é resultante das emissões e remoções atmosféricas históricas (OLLALI, 2019). Porém, a mudança na temperatura global superficial para o período de 1850 a 2020 demonstrou que as mudanças estão ocorrendo há milhares de anos, afetando todas as áreas do planeta. Considerando o início do período analisado até meados de 1950 as causas naturais foram predominantes. A partir dessa data até o cenário atual, o aumento da temperatura terrestre foi extremamente influenciado pela ação antrópica (IPCC, 2023).

As consequências do número elevado de emissões de GEE são observadas desde a época da Revolução Industrial. Porém, as últimas três décadas foram as mais quentes desde 1850 (IPCC, 2014). E, caso o ritmo atual de emissões de GEE seja mantido, projeta-se um aumento de 1,5°C entre 2030 e 2052 (IPCC, 2021). Dados compartilhados pelo NOAA (2025) demonstram que a temperatura média global, abrangendo a superfície terrestre e marítima, foi quase 1,0° C mais quente em 2024 do que a média do século XX e 1,2°C superior aos tempos pré-industriais.

O aquecimento da superfície terrestre ocorreu em uma velocidade maior do que a admitida pelo ritmo do planeta, causando impactos em todas as esferas da vida terrestre (IPCC, 2023). Diante dessa instabilidade climática, o conceito de

mudança climática é de extrema relevância. Dessa forma, o IPCC, em 2014, a definiu como:

Variação estatisticamente significativa nas condições médias do clima ou em sua variabilidade, que persiste por um longo período – geralmente décadas ou mais. Pode advir de processos naturais internos ou de forçamentos naturais externos, ou ainda de mudanças antropogênicas persistentes na composição da atmosfera ou no uso do solo (IPCC, 2014, p. 32).

No contexto nacional, outra definição que converge com o conceito apresentado pelo IPCC foi apresentada na promulgação da Lei nº 12.187 (BRASIL, 2009) conhecida como Política Nacional sobre Mudança do Clima – PNMC:

Significa uma mudança de clima que possa ser direta ou indiretamente atribuída à atividade humana que altere a composição da atmosfera mundial e que se some àquela provocada pela variabilidade climática natural observada ao longo de períodos comparáveis (BRASIL, 2009, p. 1).

Embora a Lei nº 12.187 (BRASIL, 2009) seja de âmbito nacional, o conceito corrobora com o do IPCC, que está em nível mundial. Além disso, em ambos, a influência humana é destacada como causa do desequilíbrio climático e a duração e da intensidade da mudança são considerados.

As consequências do desequilíbrio climático para a humanidade estão descritas no *Sixth Assessment Report* (IPCC, 2021) em quatro classes: i) alimentação e água; ii) doenças; iii) condições meteorológicas; e iv) outras consequências. De acordo com essa fonte, projeta-se que, em 2050, entre 8 e 80 milhões de pessoas estarão em situação de risco de fome e diminuição de 4 a 10% da produção agrícola mundial nos últimos 30 anos e de 40 a 70% da pesca em regiões tropicais, além de alertar para a grande exposição da população mundial a doenças, condições meteorológicas extremas e escassez de água devido à seca (IPCC, 2021).

2.3.2 Emissões de GEE

A nível mundial, de acordo com o levantamento realizado pelo *Global Carbon Project*, considerando somente as emissões oriundas da queima de combustíveis fósseis e a indústria de cimento, 23 países desenvolvidos foram responsáveis por metade de todas as emissões de CO₂ desde 1850. Desse montante, os Estados Unidos (EUA) foram responsáveis por 24,6% das emissões, a Alemanha por 5,5%, Reino Unido por 4,4% e o Japão por 3,9% (FRIEDLINGSTEIN *et al.*, 2022).


De 2011 a 2020, foram emitidos 38,8 PgCO₂.ano⁻¹, sendo 34,8 PgCO₂.ano⁻¹ oriundos de processos industriais e 4,0 PgCO₂.ano⁻¹ da mudança de uso da terra. A remoção de carbono totalizou 21,7 PgCO₂.ano⁻¹, sendo que as florestas foram responsáveis pelo armazenamento de 11,4 PgCO₂.ano⁻¹ (FRIEDLINGSTEIN *et al.*, 2022).

Em relação as emissões de CO₂, houve um aumento de 1,0% em 2022 em relação a 2021 (0,1% a 1,9%), com emissões de 10 GtCO₂.ano⁻¹ (FRIEDLINGSTEIN *et al.*, 2022). Países como China e União Europeia tiveram redução nas emissões, de 0,9% e 0,8% aproximadamente. Em contrapartida, Estados Unidos e Índia tiveram aumentos nas emissões de CO₂, de 1,5% e 6%, respectivamente (FRIEDLINGSTEIN *et al.*, 2022).

Um estudo conduzido por Harris *et al.* (2021) apontou que, entre 2001 e 2019, o desmatamento e outros distúrbios florestais resultaram em emissões brutas globais de GEE de aproximadamente 8,1±2,5 GtCO_{2eq}.ano⁻¹. Desse montante, o CO₂ foi o GEE dominante. No mesmo período, as remoções brutas de carbono por florestas foram de -15,6±49 GtCO_{2eq}.ano⁻¹. Dessa forma, o balanço das emissões brutas e remoções brutas resultou em -7,6±49 GtCO_{2eq}.ano⁻¹ (HARRIS *et al.*, 2021).

A nível nacional, pode-se citar a análise das emissões produzidas entre 1990 e 2023, no relatório produzido pelo Sistema de Estimativas de Emissões e Remoções de Gases de Efeito Estufa (SEEG) (FIGURA 2). Tal fonte reporta um volume de emissões de 2,3 bilhões de GtCO_{2eq} (SEEG, 2024).

FIGURA 2 – EMISSÕES TOTAIS DE GEE NO BRASIL ENTRE 1990 E 2023



FONTE: SEEG (2024).

De acordo com as emissões brasileiras de GEE registradas em 2023, o setor de mudanças de uso da terra foi responsável pela emissão de 1,1 bilhão de toneladas de CO₂eq ou 48% das emissões, consolidando-se como a maior fonte de emissão bruta de GEE no país (SEEG, 2024).

A agropecuária destaca-se na sequência, com 631 milhões de toneladas de CO₂eq emitidas. Em 2023, o setor de energia e processos industriais foi responsável pela emissão de 510 milhões de toneladas de CO₂eq emitidas, ou seja, 21% das emissões brasileiras. O setor de resíduos, por sua vez, emitiu 92 milhões de toneladas de CO₂eq (SEEG, 2023).

Visando conter o avanço do aquecimento global e a criação de estratégias para a mitigação das mudanças climáticas, estudos com dados de Sensoriamento Remoto têm se destacado, sendo que a descrição dessa temática se inicia a seguir.

2.4 LIGHT DETECTION AND RANGING (LIDAR)

LiDAR é um sistema de sensoriamento remoto ativo de escaneamento a laser (*Light Amplification by Stimulated Emission of Radiation* (LASER)) que emite radiação eletromagnética a um dado comprimento de onda e sob uma alta taxa de frequência de repetição, com capacidade de detecção do gradiente de altura e profundidade de um determinado objeto ou superfície alvo escaneado (CORTE *et al.*, 2022).

É um método direto de coleta de dados que não depende de fonte de iluminação, com baixa influência das condições atmosféricas (GORGENS; SILVA; RODRIGUEZ, 2004), com precisão planimétrica de 1 metro, operando no comprimento de onda do infravermelho próximo entre 1040 µm a 1064 µm (GORGENS; SILVA; RODRIGUEZ, 2014).

A utilização deste tipo de sensor resulta em dados com alta densidade amostral, análise de superfícies, sensibilidade a pequenas mudanças no terreno e penetração significativa mesmo em vegetações mais densas (GORGENS; SILVA; RODRIGUEZ, 2014). A alta velocidade de aquisição de dados da estrutura vertical e horizontal de áreas florestais é um benefício destacado por Giongo *et al.* (2010).

O funcionamento baseia-se na emissão de um pulso *laser* à velocidade da luz de uma plataforma e com elevada frequência de repetição (GIONGO *et al.*, 2010), com taxas maiores que 200.000 pulsos *laser* por segundo (GORGENS; SILVA; RODRIGUEZ, 2014). O feixe é direcionado e distribuído por um sistema óptico constituído por espelhos visando atingir a área de cobertura do imageamento. Em seguida, esse sistema capta os sinais de retorno, direcionando-os ao receptor (GIONGO *et al.*, 2010).

Com isso, a mensuração entre o tempo decorrido entre a emissão do feixe e a detecção ao ser refletido fornece a estimativa das distâncias (Equação 1) (GIONGO *et al.*, 2010; GORGENS; SILVA; RODRIGUEZ, 2014). Na Equação 1, o denominador igual a dois deve-se ao registro do caminho de ida e volta do sensor (GORGENS; SILVA; RODRIGUEZ, 2014).

$$d = c * \frac{t}{2} \quad (1)$$

Em que: d: distância; c: velocidade da luz, aproximadamente 299.792.458 m.s⁻¹; t: tempo.

Outros componentes do sistema LiDAR são o *Global Positioning System* (GPS) e a *Inercial Operationg Unit* (IMU), responsáveis pela determinação da localização e a altitude da unidade *laser* no momento da emissão do feixe, gerando uma coordenada para cada ponto gerado (GORGENS; SILVA; RODRIGUEZ, 2014).

Em estudos com vegetação homogênea, ocorre maior concentração dos primeiros retornos causado pela pouca penetrabilidade do *laser* a nível do solo. Em florestas com maior heterogeneidade, a geração de múltiplos retornos também

aumenta resultante da presença das diferentes alturas, tamanhos e diversos formatos de copa e abertura de dossel (GORGENS; SILVA; RODRIGUEZ, 2014).

Dubayah e Drake (2000) classificam os sistemas LiDAR segundo: i) tamanho do *footprint*; ii) formato do sinal refletido e iii) frequência de amostragem e padrão de escaneamento.

O *footprint* compreende a área de amostragem do sensor e com formato, circular, variando de acordo com a topografia do terreno e com o ângulo de varredura/escaneamento (BALTSAVIAS, 1999). Os feixes *laser* emitidos podem atingir o solo com diâmetros ou *footprint* de até 90 cm. Essa variável pode ser obtida a partir do diâmetro do *laser* ao ser emitido, altura do voo e divergência do *laser* (Equação 2) (GORGENS; SILVA; RODRIGUEZ, 2014):

$$D_c = D + 2 * h * \tan \frac{\gamma}{2} \quad (2)$$

Em que: D_c : diâmetro do laser; h : altura do voo; γ : divergência do laser.

Em levantamentos florestais, o *footprint* pode influenciar no ângulo de escaneamento e consequentemente, no grau de penetração do feixe *laser*. Quanto maior o ângulo de escaneamento, maior será a penetração do feixe no dossel (GORGENS; SILVA; RODRIGUEZ, 2014).

Sendo assim, em plantios florestais com altura e densidade uniformes, Jensen (2009) recomenda que o ângulo de escaneamento seja maior para garantir o maior grau de penetração do feixe na vegetação, corroborando com a indicação de Dubayah e Drake (2000), os quais sugerem a utilização de sistemas com *footprint* de aproximadamente um diâmetro médio de copa, ou seja, de 10 a 25 metros.


Além disso, os feixes *laser* podem gerar inúmeros pontos de retorno em diferentes alturas, com o primeiro chamado de *first return*, refletindo, em sua grande maioria, a parte superior do dossel da floresta. Os demais retornos distribuem-se ao longo do eixo vertical da vegetação em direção ao solo (*last return*), representando a máxima penetração do sinal na vegetação (DONG; CHEN, 2018).

Em relação ao sistema de medições, os *lasers* podem ser divididos em pulsos discretos (*discrete return*) e ondas contínuas (*full waveform*). O primeiro sistema realiza o registro do intervalo para o primeiro ou o último dos pulsos. No segundo, a forma de onda é completa com sinal de retorno com intervalos fixos (DONG; CHEN, 2018).

Nos sistemas de retornos discretos, ao ser emitido em direção ao alvo, o pulso pode ser integralmente interceptado e refletido por uma única superfície. Além disso, o pulso também pode ser parcialmente interceptado a diferentes alturas (gerando um primeiro retorno e diversos retornos intermediários), ou ser integralmente refletido (um único retorno) (DONG; CHEN, 2018). Já os sistemas de onda contínua podem coletar a distribuição variável no tempo da radiação retroespalhada dos diferentes alvos dentro da superfície iluminada (DONG; CHEN, 2018).

Os voos com sensores LiDAR podem ser executados em plataformas terrestres (fixas ou móveis), aéreas (aeronaves) e orbitais (satélites) (FIGURA 3):

FIGURA 3 – PLATAFORMAS PARA AQUISIÇÃO DE DADOS LiDAR



FONTE: Adaptado de Guo *et al.* (2022).

Em plataformas aéreas, os sensores são instalados a bordo de veículos aéreos, nos quais a varredura ocorre pela junção da oscilação periódica da direção da emissão do *laser* com o movimento frontal do veículo (GUO *et al.*, 2022). Os sensores aerotransportados ou ALS podem ser transportados por aeronaves ou em Veículos Aéreos Não Tripulados (VANTs) (NISHIWAKI *et al.*, 2023). A nível orbital, citam-se as plataformas orbitais como os sensores GEDI.

Ainda sobre plataformas aéreas de LiDAR, Corte *et al.* (2022) indicam que o uso de aviões tripulados favorece a adaptação quanto a altitude do voo, porém, resultam em nuvem de pontos com baixa densidade, aproximadamente 5 a 30 pontos.m⁻². Sensores LiDAR embarcados em VANT geram nuvens de pontos de alta densidade, com até mais de 1000 pontos.m⁻², contudo, a altitude do voo possui limitações. A altitude do voo é um parâmetro primordial para a correta execução do voo, visto que pode influenciar na largura da faixa de varredura, a qual, por sua vez, depende do ângulo de varredura (DONG; CHEN, 2018).

Varreduras executadas com sistemas ALS e UAV diferem quanto a altura do voo, divergência do feixe, comprimento de onda do *laser*, energia do pulso e ângulo de varredura. Ademais, o planejamento do voo e a escolha do veículo também impactam na densidade e na disposição de pontos da nuvem (CORTE *et al.*, 2022).

Após a execução do voo, gera-se uma nuvem de pontos que contém dados de elevação arranjados de forma sistemática e temporal ao longo da faixa de voo (JENSEN, 2009). Nesse formato, cada ponto gerado contém a localização geográfica (x, y e z), o registro da intensidade do sinal, número do retorno, número de retornos do pulso, classificação, ângulo de varredura, número de identificação e a hora, segundo a *American Society for Photogrammetry and Remote Sensing* (ASPRS) (ASPRS, 2011).

Além da nuvem de pontos, os produtos derivados de uma coleta com sensor LiDAR podem ser classificados em três grandes grupos:

i) Modelos Digitais: Modelo Digital de Elevação, sendo subdivididos em Modelos Digitais de Superfície ou *Digital Surface Model* (DSM), Modelos Digitais de Terreno ou *Digital Terrain Model* (DTM) e o Modelo de Altura de Copas ou *Canopy Height Model* (CHM). O DSM é produzido com o ponto mais alto (*first return*) de cada pulso *laser*, e representa em áreas de floresta, a superfície do topo do dossel da floresta (SHAN; TOTH, 2018). Já a obtenção do MDT é baseada nos retornos que atingiram o solo, representando a elevação da superfície do terreno (SHAN; TOTH, 2018). A partir da diferença do DSM pelo DTM, obtém-se o CHM pela diferença da elevação de cada retorno em relação ao DTM (SHAN; TOTH, 2018).

ii) Intensidade: montante de energia que foi refletida pelo objeto e que retornou ao sensor (GIONGO *et al.*, 2010). Essa variável pode ser influenciada por diversos fatores como o sensor *laser*, o ângulo de incidência, a área, a reflectância do alvo, a absorção atmosférica e a distância (DONG; CHEN, 2018).

iii) Métricas estatísticas: superfícies matriciais contínuas com os parâmetros estatísticos (valores máximos, mínimos, variância, percentis, desvio padrão entre outros) que descrevem o conjunto de dados LiDAR, calculadas a partir da nuvem de pontos. Podem ser subdivididas em métricas de altura, intensidade e topografia (TABELA 2) (USFS, 2014).

TABELA 2 – CATEGORIA DE MÉTRICAS LiDAR

Grupo	Subgrupo	Métrica
Contagem	-	Contagem de retornos por tipo de retorno e número total de retornos
Contagem	-	Número total de retornos
Elevação ou altura	Posição	Elevação: mínima e máxima, média, mediana ou moda. Percentis de elevação: 1, 5, 10, 20, 25, 30, 40, 50, 60, 70, 75, 80, 90, 95, 99)
Elevação ou altura	Dispersão	Assimetria e curtose, coeficiente de variação, desvio padrão e variância, distância interquartil
Elevação ou altura	Proporção	Número de retornos > altura x (média ou outra) / total de primeiros retornos; Porcentagem de primeiros retornos > altura x (média, moda ou outra); Porcentagem de todos os retornos > altura x (média, moda ou outra)
Intensidade	Posição	Intensidade mínima e máxima, média, mediana e moda. Percentis de intensidade: 1, 5, 10, 20, 25, 30, 40, 50, 60, 70, 75, 80, 90, 95, 99)
Intensidade	Dispersão	Assimetria e curtose, coeficiente de variação, desvio padrão e variância, distância interquartil
Topografia	-	Declividade do terreno e aspecto do terreno

FONTE: Gorgens, Silva e Rodriguez (2014).

De acordo com a TABELA 2, as métricas do primeiro grupo servem para verificar a qualidade da nuvem de pontos, como a densidade espacial da nuvem e o grau de complexidade vertical da paisagem. Já as métricas de elevação compreendem as coordenadas de posicionamento vertical dos pontos na nuvem, sendo úteis para a caracterização da copa do dossel e para a estimativa da altura dominante do mesmo além do entendimento da dinâmica entre os estratos da floresta. As métricas de intensidade, por sua vez, são difundidas em pesquisas para identificação de espécies florestais, quantificação de carbono e análise de características topológicas das plantas (GORGENS; SILVA; RODRIGUEZ, 2014).

3 ESTIMATIVA DA BIOMASSA E DO CARBONO DE GENÓTIPOS DE *Eucalyptus* spp. COM UAV-LIDAR COM ABORDAGEM A NÍVEL DE ÁREA E APRENDIZADO DE MÁQUINA

RESUMO

Essa pesquisa teve como objetivo quantificar a biomassa e o carbono acima do solo por compartimento de *Eucalyptus* spp. utilizando dados UAV-LiDAR e diferentes técnicas de modelagem: regressão linear múltipla; *Artificial Neural Network* (ANN); *k-Nearest Neighbor* (kNN); *Random Forest* (RF); *Support Vector Regression* (SVR) e *Extreme Gradient Boosting* (XGBoost). A área de estudo localiza-se em São Paulo e pertence ao projeto EUCFLUX e é formada por cinco blocos experimentais conduzidos com regime alto fuste, com 25 genótipos de *Eucalyptus* spp. implantados em 2018. Em maio de 2023, ocorreu o censo florestal nas parcelas, seguido pela amostragem destrutiva realizada em 150 árvores para a obtenção da biomassa acima do solo. Posteriormente, ocorreu o voo UAV-LiDAR, com um sensor Zenmuse L1 embarcado em uma aeronave DJI Matrice 300 RTK. O processamento dos dados envolveu a classificação dos retornos, geração dos modelos digitais e a extração das métricas por parcela. Com o modelo de Schumacher-Hall adaptado para a inclusão dos genótipos como variáveis *dummy*, estimou-se a biomassa acima do solo dos genótipos avaliados. Para a obtenção do carbono, foi adotado um teor de carbono de 46% para *Eucalyptus* spp. disponível na literatura. As métricas UAV-LiDAR foram selecionadas para a construção dos modelos preditivos por meio da Análise de Componentes Principais. Todos os modelos foram avaliados pelas estatísticas de ajuste e por medidas de concordância. Em todos os compartimentos analisados, as técnicas de *Machine Learning* superaram a regressão tradicional. O modelo com o algoritmo RF foi o mais preciso para estimar a biomassa total (R^2_{ajustado} de 0,952 e RMSE de 5,42%) e do fuste (R^2_{ajustado} de 0,959 e RMSE de 4,59%). Para o carbono total e de fuste, o R^2_{ajustado} foi de 0,952 e 0,961, com RMSE de 5,38% e 4,54%, respectivamente. Esses resultados correspondem, em média, 110,97 t.ha⁻¹ de biomassa acima do solo, 51,16 t.ha⁻¹ de carbono acima do solo, 100,46 t.ha⁻¹ de biomassa do fuste, 46,34 t.ha⁻¹ de carbono de fuste. No compartimento copa, o algoritmo XGB teve performance superior aos demais métodos, estimando, em média, 10,72 t.ha⁻¹ de biomassa e 4,96 t.ha⁻¹ para o carbono, com R^2_{ajustado} de 0,765 e 0,707 e RMSE de 13,49% e 15,06%, respectivamente. De posse dos indicadores alcançados nessa pesquisa, pode-se comprovar o potencial da tecnologia LiDAR e o emprego de algoritmos não paramétricos para a quantificação da biomassa e do estoque de carbono acima do solo em genótipos de *Eucalyptus* spp.

Palavras-chave: estoque de carbono; inventário florestal; métricas UAV-LiDAR; modelagem não paramétrica.

3.1 INTRODUÇÃO

Com 10,5 milhões de hectares de florestas plantadas (IBÁ, 2025), o Brasil, país pertencente a América do Sul, possui uma das maiores coberturas florestais do mundo, com 12% (FAO, 2020). Dentre os principais gêneros plantados no país, o *Eucalyptus* spp. destaca-se como o mais plantado, com aproximadamente 8,1 milhões de hectares, representando 76% da área plantada nacional (IBÁ, 2025).

Diante desse potencial, destaca-se o protagonismo das florestas na mitigação das mudanças climáticas, especialmente pela conversão de carbono atmosférico em biomassa florestal, processo executado pelas florestas (ROUBUSTE *et al.*, 2022), além de sua importância no ciclo global de carbono (ZHANG *et al.*, 2022). A nível nacional, tamanha relevância aumentou após a implementação da Política Nacional sobre Mudanças do Clima (Lei Federal nº 12.187 de 29 de dezembro de 2009) (BRASIL, 2009) e a criação do Sistema Brasileiro de Comércio de Emissões de Gases de Efeito Estufa (SBCE), pela Lei Federal nº 15.042 de 11 de dezembro de 2024 (BRASIL, 2024).

O estoque de carbono em paisagens florestais concentra-se principalmente na estimativa da biomassa florestal, dividida em biomassa acima do solo (BAS) ou do inglês, *Above Ground Biomass* (AGB), biomassa abaixo do solo (do inglês, *Below Ground Biomass* (BGB), necromassa (troncos, tocos e galhos mortos), serapilheira e matéria orgânica estável distribuída no perfil do solo (IPCC, 2006). A maior concentração de biomassa florestal está na AGB (IPCC, 2014) podendo ser obtida por métodos diretos como o inventário florestal e amostragem destrutiva dos indivíduos e estimada indiretamente a partir de equações alométricas e dados derivados de tecnologias de Sensoriamento Remoto (ROMERO *et al.*, 2020).

Diante da limitação espacial dos métodos diretos, especialmente pelo custo e tempo de execução (visto que é realizado a derrubada do indivíduo arbóreo, seccionamento e a medição da massa dos componentes *in loco*) (SILVA *et al.*, 2022), abordagens não destrutivas, contínuas e espaciais têm se destacado nas estimativas de biomassa acima do solo, especialmente pela aplicação de dados de Sensoriamento Remoto, como o LiDAR (*Light Detection and Ranging*) (XU *et al.*, 2025).

LiDAR é um sensor ativo de escaneamento a *laser* (*Light Amplification by Stimulated Emission of Radiation*). Seu funcionamento baseia-se na emissão de

feixes *laser* em um determinado comprimento de onda com alta taxa de frequência de repetição penetrando nas florestas, gerando informações tridimensionais e com alta resolução (CORTE *et al.*, 2022). Esses sistemas podem ser divididos de acordo com as formas de sinal de pulso (discreto ou contínuo), pelo tipo de plataforma (aérea, terrestre ou orbital) e quanto ao tamanho do *footprint* (pequeno (~1m), médio (~10-30m) ou grande (~50m) (WANG *et al.*, 2024).

De acordo com essas características dos sensores, duas abordagens podem ser utilizadas para a estimativa da AGB a partir da tecnologia LiDAR: i) abordagem baseada em indivíduo (do inglês, *Individual Tree Detection* - ITD) e ii) abordagem baseada em área (do inglês ou *Area Based Approach* - ABA). Nesse último método, atributos a nível de parcela ou de povoamento são extraídos e utilizados na construção de modelos preditivos de AGB (WHITE *et al.*, 2017).

A abordagem baseada em área permite o cálculo de métricas que caracterizam a nuvem de pontos de uma área de interesse, que podem ser utilizadas em diferentes modelos estatísticos preditivos (ROUSSEL *et al.*, 2020), como técnicas tradicionais (regressão linear múltipla, por exemplo) e algoritmos de aprendizado de máquina (do inglês, *Machine Learning* - ML). A estimativa de AGB em plantios florestais utilizando regressão linear múltipla possui limitações, como a dificuldade em tratar relações complexas e não lineares ou problemas de multicolinearidade (TORRE-TOJAL *et al.*, 2022). Tal fato motivou a busca por técnicas de ML, para a predição de biomassa e estoque de carbono, como *Artificial Neural Networks* (ANN) (LIU *et al.*, 2023), *k-Nearest Neighbor* (kNN) (BALAZS *et al.*, 2022), *Random Forest* (RF) (TORRE-TOJAL *et al.*, 2022), *Support Vector Regression* (SVR) (LI *et al.*, 2022) e *Extreme Gradient Boosting* (XGBoost) (ZHANG; LIU, 2023).

Nesse âmbito, estimativas robustas do estoque de carbono armazenado na biomassa de florestas de *Eucalyptus* spp. tornam-se cada vez mais necessárias e urgentes, sendo fundamentais para o monitoramento do carbono e para subsidiar decisões em políticas públicas, para o manejo florestal sustentável e mecanismos de mitigação às mudanças climáticas (IPCC, 2023). Diante disso, essa pesquisa justifica-se pela estimativa da biomassa e do estoque de carbono em multicamadas, ou seja, em diferentes compartimentos da árvore, pela combinação de uma fonte de dados com alta precisão (plataforma *Unmanned Aerial Vehicle* LiDAR (UAV) ou

UAV-LiDAR, com alta densidade de pontos e técnicas de aprendizado de máquina (ANN, kNN, RF, SVR e XGBoost).

Apesar do número expressivo de pesquisas com UAV-LiDAR para a quantificação da biomassa acima do solo em plantações de *Eucalyptus* spp., ainda há algumas limitações a serem consideradas. A maioria desses estudos apresenta validação de campo insuficiente para obter um maior número de amostras (BORSAH *et al.*, 2023). Outro obstáculo diz respeito à demanda por modelos alométricos ajustados conforme a espécie, idade e local para a estimativa da biomassa e do carbono acima do solo (BORSAH *et al.*, 2023; MA *et al.*, 2024).

Ademais, a falta de modelos confiáveis para prever a biomassa por compartimento dificulta a estimativa precisa do estoque de carbono em várias partes da árvore. Outras restrições envolvem a variação na densidade e qualidade das nuvens de pontos, efeitos das condições de voo na coleta de dados, baixa transferibilidade espacial e temporal dos modelos, além do custo e da complexidade do processamento de grandes volumes de dados UAV-LiDAR (LI *et al.*, 2025; POLEY; McDERMID, 2020; ZHOU *et al.*, 2025). Essas lacunas destacam a importância do estudo, uma vez que o aprimoramento de métodos mais precisos e detalhados ajuda a otimizar o monitoramento do carbono florestal, apoiar políticas de mitigação das mudanças climáticas e fornecer dados para o manejo sustentável de plantações de *Eucalyptus* spp.

Este trabalho teve como objetivo estimar a biomassa acima do solo (BAS) e o respectivo carbono estocado de genótipos em *Eucalyptus* spp. a partir da abordagem de área para verificar se existem diferenças significativas entre tais estimativas e os valores derivados do censo florestal. Para tanto, foram considerados os diferentes compartimentos acima do solo (total, copa e fuste) relacionados com dados UAV-LiDAR de alta densidade e diferentes modelos de ML.


3.2 MATERIAL E MÉTODOS

3.2.1 Descrição da área

A área avaliada pertence à Fazenda Americana e está localizada no município de Itatinga, no estado de São Paulo, Brasil. A fazenda é de posse de uma empresa florestal no ramo de celulose e papel e possui uma área experimental de

192,54 hectares (FIGURA 4). Essa área está vinculada ao projeto EUCFLUX (Programa Cooperativo sobre Produtividade e Fluxos de Carbono e Água em *Eucalyptus* (fase 2)) desenvolvido em parceria com o Instituto de Pesquisas Florestais (IPEF) (IPEF, 2025) e com o CIRAD (*Le Centre de Coopération Internationale en Recherche Agronomique pour le Développement* ou Centro de Cooperação Internacional em Pesquisa Agrônômica para o Desenvolvimento).

FIGURA 4 – ÁREA EXPERIMENTAL COM *Eucalyptus* spp. EM ITATINGA, SÃO PAULO, BRASIL



FONTE: A autora (2026).

A área apresenta classificação climática como Cfa, ou seja, clima subtropical úmido e quente, com verões quentes e invernos secos de acordo com Köppen (ALVARES *et al.*, 2013). Está localizada a uma altitude de 845 metros ao nível do mar, com temperatura média anual de 19,4°C e precipitação média anual de 1.319 mm (ALVARES *et al.*, 2013). O relevo é majoritariamente plano, com solos classificados como Latossolo Vermelho Distrófico Típico (LVd4) e Latossolo Vermelho-Amarelo Distrófico Típico (LVAd4), com textura média arenosa e horizonte A moderado e Latossolo Vermelho Distrófico Típico (LVd2), de textura argilosa e horizonte A moderado (EMBRAPA, 2006).

A área experimental compreende uma plantação de 5 blocos (numerados como Bloco 2, Bloco 4, Bloco 7, Bloco 8 e Bloco 10 de acordo com os dados de campo) contendo 25 materiais genéticos (tratados como genótipos) do gênero *Eucalyptus* spp. plantados em 2018 provenientes do projeto EUCFLUX com espaçamento de 3m x 2m, totalizando 6 m² por árvore e 1.666 árv.ha⁻¹. O sistema de

manejo implantado foi o de alto fuste. Cada bloco contém aproximadamente 2,80 hectares e contém 25 parcelas que representam os 25 genótipos implantados. A área total do bloco é 180 m x 160 m, contendo 25 parcelas de 36 m x 32 m (12 linhas x 16 árvores), totalizando 192 árvores por parcela. Porém, a área útil ou a área interna efetiva de medição contém 30 m x 30 m, com área de 600m² ou 0,06 ha, formadas por 10 linhas x 10 árvores, totalizando 100 árvores por parcela.

Devido à ausência do georreferenciamento dos dados, as parcelas foram delimitadas a partir das linhas de plantio identificadas em imagens de satélite obtidas um ano após o plantio. Para isso, as linhas de plantio foram numeradas para a identificação do ponto inicial da parcela, que corresponde ao canto inferior direito.

A colheita da primeira rotação do projeto foi realizada entre maio e junho de 2018, aos 8,5 anos. Para tanto, foram utilizados um *Feller Buncher* modelo *Tigercat* 860C e um cabeçote modelo *Tigercat* DT5003 (SBARDELLA, 2021). A etapa do pré-plantio iniciou com o controle de formigas de forma manual (localizada e sistemática) com a aplicação de 5 kg.ha⁻¹ de isca formicida do tipo sulfuramida. Para o preparo da área, as copas foram dessecadas com capina química mecanizada com o produto *Touchdown* com 3 L.ha⁻¹ e o solara com 1 L.ha⁻¹. Adotou-se a prática de cultivo mínimo, com a realização da calagem em toda a área após 3 meses da colheita, com a aplicação de 2 t.ha⁻¹ de calcário dolomítico. Em seguida, o plantio foi realizado com plantadeira manual e o replantio ocorreu entre 20 a 30 dias após o plantio (SBARDELLA, 2021).

Posteriormente, foi feita a adubação de base em toda a área experimental (300 kg.ha⁻¹), com a aplicação conjugada de Nitrogênio (N), Fósforo (P) e Potássio (K) (06:30:10) + 2,0% enxofre (S) + 0,5% boro (B) + 0,5% zinco (Zn) + 0,5% cobre (Cu) e herbicida pré-emergente Fordor (0,07 kg.ha⁻¹) + Flumyzin (0,08 kg.ha⁻¹). A primeira adubação de cobertura foi realizada a aproximadamente 4 meses após o plantio, com a aplicação de 400 kg.ha⁻¹ de NPK (16:00:12) + 0,5% (B) + 0,6% (Zn) + 12% (S). A segunda adubação de cobertura foi realizada entre o oitavo e o décimo segundo mês após o plantio, com a aplicação de 400 kg.ha⁻¹ de NPK (00:0:51) + 1,5% (B) (SBARDELLA, 2021).

Para a condução do plantio, realizou-se o controle de plantas daninhas por meio de capina química mecanizada, realizado antes das adubações de cobertura (duas aplicações) e em época chuvosa (2º ano de plantio), com a aplicação de *Touchdown* (3,3 L.ha⁻¹). O controle de formigas pós plantio foi realizado duas vezes

no intervalo de 30 dias após o plantio, com a aplicação localizada de 2 kg.ha⁻¹ de isca formicida do tipo sulfluramida. Já o controle de formigas foi realizado nos meses secos, do 1º ao 5º ano, sendo aplicados 3 kg.ha⁻¹ de isca formicida (manual) e 5 kg.ha⁻¹ de isca formicida (mecanizado) (SBARDELLA, 2021).

Após a implantação dos genótipos e a execução dos tratamentos silviculturais descritos, o genótipo 23, pertencente ao bloco 10, apresentou mortalidade total e, portanto, não foi considerado nessa pesquisa. Assim, a análise englobou as demais 124 parcelas distribuídas nos cinco blocos experimentais.

3.2.2 Censo florestal

O censo florestal foi executado nas parcelas existentes no experimento, em maio de 2023. Em cada parcela, o Diâmetro a 1,30m do solo (D) foi mensurado com a suta e a altura total (H) das árvores localizadas na quarta e na quinta linha foi obtida com o Clinômetro Haglöff. Para as demais árvores (que não tiveram altura medida em campo) foram testados cinco modelos hipsométricos, listados na TABELA 3.

Para a obtenção do volume das parcelas, 150 árvores (seis árvores por genótipo) não pertencentes as parcelas (e localizadas somente no bloco 2) foram selecionadas em classes diamétricas considerando ± 2 desvios padrões. As árvores foram cubadas pelo método de Smalian, cujas medidas foram nas posições: 0,10 m, 0,30 m, diâmetro à 1,30m do solo, 3 m e a cada 3 m até o topo da árvore, respectivamente. Para a quantificação volumétrica dos genótipos, foram ajustados três modelos volumétricos (TABELA 3).

TABELA 3 – MODELOS HIPSONOMÉTRICOS E VOLUMÉTRICOS TESTADOS EM *Eucalyptus* spp. EM ITATINGA

Ajuste	Nome	Equação
Hipsométrico	Stoffels	$\ln(h) = \beta_0 + \beta_1 * \ln(d)$
Hipsométrico	Trorey	$h = \beta_0 + \beta_1 + \beta_2 * d^2$
Hipsométrico	Curtis	$\ln(h) = \beta_0 + \beta_1 * 1/d$
Hipsométrico	Azevedo	$h = \beta_0 + \beta_1 * d^2$
Hipsométrico	Henricksen	$h = \beta_0 + \beta_1 * \ln(d)$
Volumétrico	Husch	$\log(v) = \beta_0 + \beta_1 * \log(d)$
Volumétrico	Spurr	$v = \beta_0 + \beta_1 * (d^2 * h)$
Volumétrico	Schumacher-Hall	$\log(v) = \beta_0 + \beta_1 * \log(d) + \beta_2 * \log(h)$

FONTE: A autora (2026).

LEGENDA: h: altura total (m); d: diâmetro a 1,30m do solo; v: volume (m³); ln: logaritmo neperiano; β_n : coeficientes do modelo.

A seleção do modelo hipsométrico e volumétrico considerou as seguintes estatísticas de ajuste: coeficiente de determinação ajustado (R^2_{ajustado}), erro padrão da estimativa em porcentagem (S_{yx}), erro padrão da estimativa em porcentagem (S_{yx} (%)) e Raiz do Erro Quadrático Médio percentual, do inglês, *Root Mean Squared Error* (RMSE).

3.2.3 Quantificação da biomassa e do carbono acima do solo

A determinação da biomassa em campo considerou os componentes arbóreos acima do solo (lenho, casca, folhas, galhos vivos e galhos mortos) por árvore (kg.árv⁻¹), utilizando as 150 árvores cubadas durante a execução do censo florestal.

Após a derrubada das árvores, os componentes foram separados e pesados para a determinação do peso úmido. Para a coleta das amostras referentes ao lenho, foram retirados discos com espessura de 2,5 cm nas posições referentes na base (0,10 metros), no D (1,30 metros) e a cada três metros de altura da árvore abatida.

As amostras foram transportadas para o laboratório de Silvicultura e Hidrologia Florestal, localizado na Estação Experimental de Ciências Florestais de Itatinga, da Universidade de São Paulo (USP) e vinculado à Escola Superior de Agricultura “Luiz de Queiroz” (ESALQ). No referido laboratório, as amostras, inicialmente, foram submetidas ao processo de secagem a 65°C para a obtenção do peso seco. O período variou de acordo com o componente, tendo duração de quatro dias para folhas, galhos mortos e cascas, sete dias para galhos vivos e três semanas para o lenho. As etapas descritas estão ilustradas na FIGURA 5.

FIGURA 5 – AMOSTRAGEM DESTRUTIVA DE *Eucalyptus* spp. EM ITATINGA, SÃO PAULO, BRASIL



FONTE: A autora (2026).

Com a obtenção dos devidos pesos, calculou-se a porcentagem de matéria seca total (%) de cada amostra avaliada (Equação 5) e em seguida, obteve-se a biomassa seca total de cada componente da árvore (Equação 6):

$$MS_i = PS_i / PU_i \quad (5)$$

$$BS_i = MS_i * PU_t \quad (6)$$

Em que: MS_i : matéria seca do i-ésimo componente da árvore (%); PS_i : peso seco da amostra do i-ésimo componente da árvore (g); PU_i : peso úmido da amostra do i-ésimo componente da árvore (g); PU_t : peso úmido total da amostra no campo (kg) BS_i : Biomassa seca total do i-ésimo componente da árvore (Kg).

Para o teor de carbono, adotou-se um único teor de carbono para todos os compartimentos, sendo de 46% para plantios de *Eucalyptus* spp. com idade de 4,7 anos conforme a pesquisa de Silva *et al.* (2015). Esse valor foi utilizado por representar plantios com diferentes espécies de *Eucalyptus* spp. com idade similar a idade dos genótipos dessa pesquisa.

O estoque de carbono aéreo por compartimento da árvore foi derivado da multiplicação entre o teor de carbono pela biomassa seca de cada compartimento analisado. O somatório do estoque de carbono por componente da árvore resultou no estoque de carbono total da parte aérea (kg).

O modelo de Schumacher-Hall com a inclusão dos genótipos como variáveis *dummy* foi utilizado para a quantificação da biomassa acima do solo por compartimento (total, fuste e copa) (Equações 7, 8 e 9) e por genótipo. O ajuste foi realizado pelo método dos Mínimos Quadrados Ordinários (MQO). Posteriormente, o somatório da biomassa acima do solo por compartimento das árvores pertencentes a cada genótipo foi dividido por 1000 e multiplicado pelo fator de proporcionalidade (F) de 16,67 (10.000m²/600m²), resultando na biomassa acima do solo por compartimento em t.ha⁻¹.

$$\ln(w) = \beta_0 + \beta_1 * \ln(D) + \beta_2 * \ln(H) + \text{genótipo} \quad (7)$$

$$\ln(wf) = \beta_0 + \beta_1 * \ln(D) + \beta_2 * \ln(H) + \text{genótipo} \quad (8)$$

$$\ln(wc) = \beta_0 + \beta_1 * \ln(D) + \beta_2 * \ln(H) + \text{genótipo} \quad (9)$$

Em que: w: biomassa acima do solo (kg.árv⁻¹); wf: biomassa de fuste (kg.árv⁻¹); wc: biomassa de copa (kg.árv⁻¹); β_n : coeficientes do modelo; D: diâmetro à altura do peito (cm); H: altura total (m); ln: logaritmo natural; genótipo: genótipo.

Por fim, a biomassa acima do solo de cada compartimento por genótipo foi multiplicada pelo teor de carbono determinado na pesquisa de Silva *et al.* (2015), em plantios de *Eucalyptus* spp. com idade de 4,7 anos, resultando no estoque de carbono acima do solo por compartimento (total, copa e fuste) por árvore para cada um dos genótipos.

3.2.4 Varredura UAV-LiDAR

Os dados UAV-LiDAR foram adquiridos utilizando um Veículo Aéreo Não Tripulado (VANT) modelo *Matrice* DJI 300 RTK (DJI, 2023) e um sensor *Zenmuse* L1 (DJI, 2023) em maio de 2023. A altitude do voo foi de 80 m, com uma velocidade de 9 m.s⁻¹ e uma largura da faixa de cobertura de 450 m. O sensor *Zenmuse* L1 pode registrar até três retornos, coletando dados com comprimento de onda de 905 nanômetros, ângulo de varredura de 45°, campo de visada (*Field of View*) de 70,4°

(horizontal) e 77,2° (vertical) e precisão vertical de 5 cm a 50 m e horizontal de 10 cm a 50 m (DJI, 2023), resultando em uma nuvem de pontos com densidade média de pontos de 389 pontos.m⁻².

Inicialmente, avaliou-se a estatística descritiva da nuvem de pontos. Em seguida, os retornos de solo foram classificados para representar somente o solo (MOHAN *et al.*, 2021). Para tanto, utilizou-se o filtro *Cloth Simulation Filter* (CSF). Trata-se de um algoritmo preciso e de fácil implementação utilizado na validação dos pontos de solo com base em processos físicos (KUÇAK; BÜYÜKSALIH, 2023). Para tanto, o algoritmo realiza a simulação ou modelagem do tecido, relacionando essa superfície com o terreno inicial. Em seguida, adiciona pontos de terreno referentes aos pontos não filtrados do terreno inicial a partir de dados de elevação, supondo que o terreno real seja similar a um plano horizontal dentro de uma determinada área (HU *et al.*, 2014; CHEN *et al.*, 2016). Essas etapas foram executadas no *software* R, versão 4.2.0. (R CORE TEAM, 2025) com o auxílio da biblioteca *lidR* (ROUSSEL *et al.*, 2020).

Após a classificação dos pontos, os retornos extraídos como solo foram utilizados na geração do *Digital Terrain Model* (DTM) utilizando o algoritmo kNN (*k-Nearest Neighbor*) com IDW (*Inverse Distance Weighting*) (MOHAN *et al.*, 2021). O *Digital Surface Model* (DSM) foi obtido pelo algoritmo p2r (*point to raster*), o qual cria uma grade com uma resolução definida pelo usuário e atribui a elevação do ponto mais alto para cada *pixel* (ROUSSEL *et al.*, 2020). A geração dos modelos digitais foi realizada no *software* R, versão 4.2.0. (R CORE TEAM, 2025) com o auxílio da biblioteca *lidR* (ROUSSEL *et al.*, 2020).

Na sequência, a nuvem de pontos foi normalizada utilizando a função *normalize_height* (ROUSSEL *et al.*, 2020), subtraindo a elevação do DTM da elevação de todos os pontos, para que os valores de elevação da nuvem de pontos possam representar a altura verdadeira dos objetos (MOHAN *et al.*, 2021). Após a normalização, o *Canopy Height Model* (CHM) foi extraído com o método p2r (*point to raster*) (MOHAN *et al.*, 2021; ROUSSEL *et al.*, 2020). Todos os modelos digitais (DTM, DSM e CHM) foram extraídos com 50 cm de resolução. Os processamentos descritos foram executados no *software* R, versão 4.2.0. (R CORE TEAM, 2025) com o auxílio da biblioteca *lidR* (ROUSSEL *et al.*, 2020).

3.2.5 Abordagem a nível de área

Com os dados UAV-LiDAR devidamente processados, a aplicação da abordagem ABA consistiu no recorte da nuvem de pontos normalizada e dos modelos digitais para as parcelas. Por fim, as métricas referentes à altura (TABELA 4) foram extraídas com a biblioteca lidR (ROUSSEL *et al.*, 2020) no *software* R, versão 4.2.0. (R CORE TEAM, 2025).

TABELA 4 – MÉTRICAS UAV-LiDAR OBTIDAS PARA OS GENÓTIPOS DE *Eucalyptus* spp. EM ITATINGA, SÃO PAULO, BRASIL

Nome	Métrica
zmax	Altura máxima dos pontos (m)
zmean	Altura média dos pontos (m)
zsd	Desvio padrão da distribuição das alturas (m)
zskew	Assimetria da distribuição das alturas
zkurt	Curtose da distribuição das alturas
zentropy	Entropia da distribuição das alturas
pabovemean	Porcentagem de retornos acima da altura média
pabovex	Porcentagem de retornos acima de x
zqx (5 a 95%)	Altura abaixo do qual estão X% dos retornos (m)
zpcumx (10 a 90%)	Percentis cumulativos (10% a 90%) da distribuição das alturas (m)

FONTE: Roussel *et al.* (2020).

Para a construção dos modelos preditivos de biomassa e carbono acima do solo dos genótipos avaliados, foram adotadas duas abordagens: i) regressão linear múltipla pelo método *Stepwise* e ii) aplicação de algoritmos por aprendizado de máquina.

Para a construção dos modelos utilizando regressão linear múltipla, as 36 métricas UAV-LiDAR foram selecionadas a partir da Análise de Componentes Principais ou do inglês, *Principal Component Analysis* (PCA). Essa análise foi utilizada para selecionar quais componentes principais explicavam 80% da variação total dos dados originais.

Para a seleção das variáveis pela PCA as 36 métricas UAV-LiDAR extraídas foram submetidas a uma análise exploratória de forma a identificar valores discrepantes. Dessa forma, foram excluídas as métricas que apresentaram valores discrepantes ou iguais a 0. Em seguida, aplicou-se a PCA nas métricas restantes que foram novamente analisadas e submetidas a uma análise de correlação para a identificação de relações bivariadas fortes, cuja existência pode indicar possíveis problemas de multicolinearidade. Nessa etapa, foram removidas as métricas

altamente correlacionadas e a PCA foi aplicada nas métricas restantes, selecionando as métricas com o maior peso dentro das componentes principais.

Após a definição das métricas, o conjunto de dados foi dividido considerando 70% para a formação de um conjunto de treinamento e 30% para um conjunto de validação, utilizando o pacote *caret* (KUHN, 2008) no *software* R, versão 4.2.0 (R CORE TEAM, 2025).

Em seguida, as métricas candidatas à construção dos modelos foram selecionadas pelo método *Stepwise*, adicionando ou removendo variáveis (ABRAHAM *et al.*, 2017), pelo método “lmStepAIC” no pacote *caret* (KUHN, 2008; R CORE TEAM, 2025). Tais modelos foram avaliados quanto aos condicionantes da regressão, com os respectivos testes: i) Normalidade dos resíduos (Shapiro-Wilk) (SHAPIRO; WILK, 1965); ii) Independência dos resíduos (Teste de Durbin-Watson); iii) Homogeneidade de variâncias (teste de Breusch-Pagan) (CORTE *et al.*, 2022). Todas as análises foram executadas no ambiente R (R CORE TEAM, 2025) a 95% de probabilidade. Ademais, também foram consideradas as estatísticas de qualidade de ajuste sumarizados na TABELA 5, bem como a distribuição gráfica dos resíduos padronizados.

TABELA 5 – VALIDAÇÃO DOS MODELOS PREDITIVOS DE BIOMASSA E CARBONO ACIMA DO SOLO EM GENÓTIPOS DE *Eucalyptus* spp. COM REGRESSÃO LINEAR MÚLTIPLA

Parâmetro	Descrição	Equação
R^2_{ajustado}	Mede de 0 até 1 (ou de 0% a 100%) a explicação da variação da variável dependente pela variação da variável independente	$R^2_{\text{ajustado}} = 1 - \left\{ (1 - R^2) * \left(\frac{n-1}{n-p} \right) \right\}$
S_{yx}	Expressa o quanto em termos médios os valores observados variam em relação aos valores estimados	$S_{yx} = \sqrt{\frac{\sum (y - \hat{y}_i)^2}{n-p}}$
$S_{yx} (\%)$	Representa o erro padrão em porcentagem	$S_{yx} (\%) = \frac{S_{yx}}{\bar{Y}} * 100$
RMSE	É uma medida absoluta da precisão do modelo e indica o quão perto as estimativas estão dos valores de referência	$RMSE = \sqrt{\sum_{i=1}^n (y_i - \hat{y}_i)^2}$
RMSE (%)	Representa a raiz do erro médio quadrático em porcentagem	$RMSE (\%) = \frac{RMSE}{\bar{Y}} * 100$
AIC	Reflete a perda de informação associada as predições de um modelo e os valores observados	$AIC = -2 \log (L) + 2 * k$
BIC	Aumenta com a Soma de Quadrados dos resíduos e quanto menor for seu valor, melhor será o modelo	$BIC = -2 \log (L) + k * \log (n)$
MAE	Representa a soma média dos valores absolutos	$MAE = \frac{1}{N} \sum_{i=1}^n y_i - \hat{y}_i $

Parâmetro	Descrição	Equação
MPE	Reflete a média dos erros percentuais pelos quais os valores preditos diferem dos valores observados	$MPE = \sum_{i=1}^n \frac{y_i - \hat{y}_i}{y_i}$
MSE	Avalia o erro entre os valores observados e os valores preditos	$MSE = \sum_{i=1}^n (y_i - \hat{y}_i)^2$

FONTE: Cai *et al.* (2020); White *et al.* (2017).

LEGENDA: $R^2_{ajustado}$: Coeficiente de determinação ajustado; R: coeficiente de determinação; n: número de árvores medidas; p: número de parâmetros da equação; S_{yx} : erro padrão da estimativa ($t.ha^{-1}$); $S_{yx}(\%)$: erro padrão da estimativa percentual (%); y : i-ésimo valor observado da variável em estudo ($t.ha^{-1}$); y_i : i-ésimo valor predito da variável em estudo ($t.ha^{-1}$); $\bar{Y}$: média dos valores observados ($t.ha^{-1}$); RMSE: Raiz do Erro Quadrático Médio; AIC: Critério de Informação de Akaike; SQ_{res} : soma do quadrado dos resíduos obtido da Análise de Variância (ANOVA); BIC: Critério de Informação Bayesiano; L_p : função de máxima verossimilhança do modelo; k: número de parâmetros do modelo; MAE: *Mean Absolute Error* ou Erro Absoluto Médio; MPE: *Mean Percentage Error* ou Erro Percentual Médio; MSE: *Mean Squared Error* ou Erro Quadrático Médio.

A seleção dos algoritmos não paramétricos foi baseada nas suas características. As ANN foram selecionadas em função de sua capacidade de aprendizado de relações complexas e não lineares entre as variáveis. Já o algoritmo kNN foi escolhido devido a sua simplicidade baseado na distância entre as observações, realizando estimativas a partir dos vizinhos mais próximos no espaço das variáveis. O algoritmo RF foi escolhido por ser um método mais robusto e estável pela combinação de árvores de regressão para a redução do erro e do sobreajuste. O SVR, por sua vez, foi utilizado pela sua capacidade de generalização e por modelar funções não lineares utilizando a função *kernel*. O XGBoost, trata-se de um método moderno e preciso e foi escolhido por apresentar alta capacidade preditiva, combinando múltiplas árvores de decisão de forma iterativa.

Inicialmente, foram criadas combinações de hiper parâmetros utilizados no processo de treinamento dos modelos (TABELA 6). Para isso, foi utilizada a função *expand.grid* do pacote *caret* (KUHN, 2008). Para o ajuste dos algoritmos de ML, as ANN foram aplicadas usando o método *nnet* (pacote *nnet*) (VENABLES; RIPLEY, 2002), já o kNN foi testado pelo método *knn* e o RF foi testado pelo método *rf*, funções do pacote *caret* (KUHN, 2008). O algoritmo SVR foi testado pelo método *svmLinear* e o XGB pelo método *xgbTree*, ambas funções do pacote *caret* (KUHN, 2008). As etapas acima descritas foram executadas no *software* R (R CORE TEAM, 2025).

TABELA 6 – ALGORITMOS DE *MACHINE LEARNING* TESTADOS PARA A PREDIÇÃO DA BIOMASSA E DO CARBONO ACIMA DO SOLO DE GENÓTIPOS DE *Eucalyptus* spp. EM SÃO PAULO, BRASIL.

Algoritmo	Parâmetro	Variação	Descrição
ANN	<i>size</i>	1 a 10	Número de neurônios na camada oculta
ANN	<i>decay</i>	0,1 a 1	Termo de regularização
kNN	<i>k</i>	10, 12 e 14	Número de vizinhos
kNN	distância	-	Euclidiana
RF	<i>mtry</i>	10, 12, 14 e 16	Número de variáveis preditoras selecionadas aleatoriamente
RF	<i>ntree</i>	300	Número de árvores utilizadas no modelo
SVR	<i>sigma</i>	0,05 a 0,1	Parâmetro da função de kernel radial
SVR	<i>C</i>	5, 7 e 10	Parâmetro de regularização
XGB	<i>nrounds</i>	100	Número de árvores utilizadas no modelo
XGB	<i>max_depth</i>	3, 5 e 7	Profundidade máxima das árvores
XGB	<i>eta</i>	0,01, 0,05 e 0,1	Taxa de aprendizado (learning rate)
XGB	<i>gamma</i>	0, 0,01 e 0,02	Penalidade para divisão dos nós
XGB	<i>colsample_bytree</i>	0,2, 0,4 e 0,6	Percentual de colunas amostradas por árvore
XGB	<i>min_child_weight</i>	1, 3 e 5	Nº mínimo de amostras para divisão dos nós
XGB	<i>Subsample</i>	0,7, 0,8 e 0,9	Percentual de dados usados em cada árvore

FONTE: A autora (2026).

LEGENDA: ANN: *Artificial Neural Network*; kNN: *k-Nearest Neighbor*; Rf: *Random Forest*; SVR: *Support Vector Regression*; XGB: *Extreme Gradient Boosting*.

Para a validação e eleição do melhor modelo preditivo de biomassa aérea e carbono aéreo por compartimento, foram consideradas as medidas de concordância descritas na TABELA 7.

TABELA 7 – MEDIDAS DE CONCORDÂNCIA PARA A VALIDAÇÃO DA MODELAGEM DE BIOMASSA E CARBONO EM DIFERENTES COMPARTIMENTOS DE *Eucalyptus* spp.

Parâmetro	Descrição	Equação
A	Varia de 0 (não há concordância) a 1 (concordância perfeita)	$A = 1 - \frac{\sum (y_i - k_i)^2 + \sum (x_i - k_i)^2}{\sum (y_i - k)^2 + \sum (x_i - k)^2}$
P	Possui amplitude de -1 (discordância perfeita) a 1 (concordância perfeita)	$\rho = 1 - \frac{\delta}{\mu_\delta} = 1 - \frac{MSE}{\frac{1}{n^2} \sum_{i=1}^n (y_i - x_i)^2}$
CC2	Varia de -1 (discordância perfeita) a 1 (concordância perfeita)	$CC2 = r^* A_p$
λ	Varia de -1 (discordância perfeita) a 1 (concordância perfeita)	$\lambda = 1 - \frac{\sum (y_i - x_i)^2}{\sum (y - y_i)^2 + \sum (x_i - \bar{x})^2 + n (\bar{y} - \bar{x})^2 + k}$


FONTE: Duveiller, Fasbender e Meroni (2016); Huang *et al.* (2019); Lawrence e Lin (1989); Mielke (1984) e Robinson (1957).

LEGENDA: A: Coeficiente de Concordância; p: medida de concordância; CC2: Coeficiente de Correlação de Concordância Melhorado; λ : parâmetro de concordância; y_i : biomassa e carbono acima do solo estimados nos diferentes compartimentos para a árvore i ; x_i : biomassa e carbono acima do solo nos diferentes compartimentos observado em campo ($t \cdot ha^{-1}$) para a árvore i ; k_i : média de y_i e x_i para a árvore i ; k : média de todos os valores y_i e x_i ; n : número de observações; MSE: Erro Quadrático Médio; r : coeficiente de correlação; A_p : medida modificada de acurácia; $\bar{y}$: média de y ; $\bar{x}$: média de x .

As estimativas de biomassa aérea e carbono aéreo foram analisadas pelo gráfico de Bland-Altman (BLAND; ALTMAN, 1986), que ilustra as diferenças entre as estimativas derivadas por cada técnica de modelagem e pelo valor de referência (censo realizado nas parcelas) em função da média e das diferenças entre eles, no qual cada ponto representa uma parcela inventariada em campo. A elaboração do referido gráfico foi realizada no *software* R (R CORE TEAM, 2025), com o pacote *blandr* (DATTA, 2017) para a identificação de possíveis *outliers* e tendências (HUANG *et al.*, 2019).

Por fim, para avaliar se existem diferenças significativas entre os valores de biomassa e carbono acima do solo estimados pela abordagem a nível de área e os valores oriundos do censo florestal foram aplicados o teste de Shapiro-Wilk (para verificação da normalidade) e os testes T pareado (em caso de normalidade) e de Wilcoxon (sem normalidade). Todas as análises foram realizadas no *software* R, com 95% de confiança. Em suma, a FIGURA 6 sumariza as todas as etapas executadas.

FIGURA 6 – MODELAGEM DA BIOMASSA E DO CARBONO ACIMA DO SOLO DE *Eucalyptus* spp. A NÍVEL DE ÁREA



FONTE: A autora (2026).

3.3 RESULTADOS

3.3.1 Censo florestal e amostragem destrutiva da biomassa acima do solo

Os modelos hipsométricos testados em 2.148 pares de diâmetro à 1,30 m do solo (D) e altura (H) tiveram $R^2_{ajustado}$ variando de 0,591 a 0,724. Dentre eles, o modelo de Trorey teve o melhor desempenho, com $R^2_{ajustado}$ de 0,724 e Syx (%) de 11,29% e RMSE (%) de 13,08%. Já para a estimativa volumétrica, o modelo de Schumacher-Hall apresentou um $R^2_{ajustado}$ ligeiramente superior ao de Spurr, de 0,985 e erros abaixo de 12%, sendo utilizado para a quantificação volumétrica dos genótipos de *Eucalyptus* spp (TABELA 8).

TABELA 8 – MODELOS HIPSONOMÉTRICOS E VOLUMÉTRICOS TESTADOS EM *Eucalyptus* spp.

Nome	Equação	$R^2_{ajustado}$	Syx (%)	RMSE (%)
Stoffels	$\ln(h) = \beta_0 + \beta_1 * \ln(d)$	0,679	12,17	13,69
Trorey	$h = \beta_0 + \beta_1 + \beta_2 * d^2$	0,724	11,29	13,08
Curtis	$\ln(h) = \beta_0 + \beta_1 * 1/d$	0,716	11,46	13,18
Azevedo	$h = \beta_0 + \beta_1 * d^2$	0,591	13,75	15,38
Henricksen	$h = \beta_0 + \beta_1 * \ln(d)$	0,713	11,52	13,27
Husch	$\log(v) = \beta_0 + \beta_1 * \log(d)$	0,895	17,22	20,43
Spurr	$v = \beta_0 + \beta_1 * (d^2 * h)$	0,981	7,38	12,03
Schumacher-Hall	$\log(v) = \beta_0 + \beta_1 * \log(d) + \beta_2 * \log(h)$	0,985	6,46	11,57

FONTE: A autora (2026).

LEGENDA: h: altura total (m); d: diâmetro a 1,30m do solo; v: volume (m³); ln: logaritmo neperiano; β_n : coeficientes do modelo; $R^2_{ajustado}$: coeficiente de determinação ajustado; Syx (%): erro padrão da estimativa percentual (%); RMSE (%): Raiz do Erro Quadrático Médio percentual (%).

Complementarmente, o ajuste hipsométrico do modelo de Trorey estratificado por genótipo também foi realizado. Ao analisar os dois ajustes realizados (TABELA 9) nota-se que não houve diferenças nas estimativas das alturas entre os dois métodos. Por esse motivo, adotou-se o modelo geral para a estimativa das alturas dos genótipos de *Eucalyptus* spp.

TABELA 9 – AJUSTE HIPSONOMÉTRICO TOTAL E ESTRATIFICADO DE TROREY EM *Eucalyptus* spp.


Classe de DAP (cm)	Ajuste total		Ajuste estratificado	
	Altura média (m)	Desvio padrão (m)	Altura média (m)	Desvio padrão (m)
0 - 5	5,90	2,22	6,04	2,51
5 - 10	14,52	2,62	14,27	2,86
10 - 15	21,37	1,83	21,47	2,28

Classe de DAP (cm)	Ajuste total		Ajuste estratificado	
	Altura média (m)	Desvio padrão (m)	Altura média (m)	Desvio padrão (m)
15 - 20	24,27	1,25	24,34	1,80
20 - 25	25,69	1,06	25,27	2,32

FONTE: A autora (2026).

Com a relação hipsométrica ajustada pelo modelo de Trorey e a quantificação volumétrica pelo modelo de Schumacher-Hall, as variáveis biométricas dos genótipos avaliados (FIGURA 7), apresentaram diâmetro médio de 12,86 cm e altura média de 20,63 m. O bloco 7 apresentou as árvores mais altas (31,10 m), enquanto as árvores mais grossas foram predominantes no bloco 10 (13,35 cm). O maior estoque volumétrico ocorreu no bloco 10 (282,21 m³.ha⁻¹). O bloco 2, por sua vez, teve o menor volume (236,65 m³.ha⁻¹). No bloco 10, o genótipo 23 apresentou uma alta taxa de mortalidade logo após o plantio, não tendo mensurações de campo.

FIGURA 7 – VARIÁVEIS DENDROMÉTRICAS DE *Eucalyptus* spp. EM ITATINGA, SÃO PAULO, BRASIL




FONTE: A autora (2026).

Para os 150 indivíduos arbóreos abatidos no bloco 2 (FIGURA 8) a biomassa acima do solo foi, em média, de 81,30 kg.árv⁻¹, destacando-se os genótipos 20 (100,46 kg.árv⁻¹) e 18 (97,53 kg.árv⁻¹) com a maior quantidade de


biomassa acima do solo. Com a menor representatividade, têm-se os genótipos 16 (56,67 kg.árv⁻¹) e 25 (35,64 kg.árv⁻¹). O estoque de carbono acima do solo das árvores utilizadas na amostragem destrutiva da biomassa, teve uma média de 37,46 kg.árv⁻¹, com destaque para os genótipos 20 e 18, com 46,29 kg.árv⁻¹ e 44,94 kg.árv⁻¹, respectivamente. Por outro lado, os genótipos 16 e 25 apresentaram o menor potencial de fixação de carbono, com 26,11 kg.árv⁻¹ e 16,42 kg.árv⁻¹.

Ao avaliar a variação da biomassa e carbono acima do solo por genótipo, nota-se que o genótipo 23 apresentou o maior desvio padrão, com 59,63 kg.árv⁻¹ e 27,48 kg.árv⁻¹, respectivamente. Os genótipos 21 e 2 vêm em seguida, com 49,77 kg.árv⁻¹ e 49,29 kg.árv⁻¹ para a biomassa acima do solo e 22,94 kg.árv⁻¹ e 22,71 kg.árv⁻¹ para o carbono acima do solo. A menor variação ocorreu nos genótipos 24 e 25, com 24,67 kg.árv⁻¹ e 17,07 kg.árv⁻¹ para a biomassa e de 11,37 kg.árv⁻¹ e 7,87 kg.árv⁻¹ para o carbono (FIGURA 8).

FIGURA 8 – BIOMASSA ACIMA DO SOLO MÉDIA (kg.árv⁻¹) E CARBONO ACIMA DO SOLO MÉDIO (kg.árv⁻¹) PELA AMOSTRAGEM DESTRUTIVA DE 150 ÁRVORES DE GENÓTIPOS DE *Eucalyptus* spp. EM ITATINGA, SÃO PAULO, BRASIL




CONTINUAÇÃO DA FIGURA 8 - BIOMASSA ACIMA DO SOLO MÉDIA (kg.árv⁻¹) E CARBONO ACIMA DO SOLO MÉDIO (kg.árv⁻¹) PELA AMOSTRAGEM DESTRUTIVA DE 150 ÁRVORES DE GENÓTIPOS DE *Eucalyptus* spp. EM ITATINGA, SÃO PAULO, BRASIL



FONTE: A autora (2026).

Quanto aos componentes avaliados nas árvores cubadas notou-se, em média, a maior concentração de biomassa no lenho, com 64,20 kg.árv⁻¹ (78,96%), seguido da casca com 8,17 kg.árv⁻¹ (10,05%), galhos vivos com 4,74 kg.árv⁻¹ (5,83%), folhas com 2,80 kg.árv⁻¹ (3,45%) e galhos mortos com 1,39 kg.árv⁻¹ (1,71%) (FIGURA 9).

FIGURA 9 – BIOMASSA ACIMA DO SOLO (kg.árv⁻¹) POR COMPARTIMENTO EM GENÓTIPOS DE *Eucalyptus* spp.



FONTE: A autora (2026).

A performance do modelo adaptado de Schumacher-Hall com a inclusão dos genótipos como variáveis *dummy* para a estimativa da biomassa acima do solo em diferentes compartimentos está ilustrada na TABELA 10. Nota-se que o ajuste obteve coeficientes de determinação ajustado (R^2_{ajustado}) superiores a 0,960 e erros de aproximadamente 10% (RMSE (%)), com exceção do compartimento copa, cujo ajuste teve um R^2_{ajustado} de 0,808 e erros próximos a 30%.

TABELA 10 – ESTIMATIVA DA BIOMASSA ACIMA DO SOLO EM DIFERENTES COMPARTIMENTOS EM *Eucalyptus* spp. PELO MODELO ADAPTADO DE SCHUMACHER-HALL

Compartimento	R^2_{ajustado}	S_{yx} (kg.árv ⁻¹)	S_{yx} (%)	RMSE (kg.árv ⁻¹)	RMSE (%)
Total	0,960	8,65	10,64	7,84	9,65
Fuste	0,961	7,46	10,31	6,77	9,35
Copa	0,808	3,01	33,72	2,61	29,23

FONTE: A autora (2026).

LEGENDA: R^2_{ajustado} : Coeficiente de determinação ajustado; S_{yx} : erro padrão da estimativa (kg.árv⁻¹); S_{yx} (%): erro padrão da estimativa percentual (%); RMSE: Raiz do Erro Quadrático Médio (kg.árv⁻¹); RMSE (%): Raiz do Erro Quadrático Médio percentual (%).

A TABELA 11 sumariza a determinação da biomassa aérea em diferentes compartimentos pelo modelo de Schumacher-Hall e a posterior estimativa do estoque de carbono aéreo presente nos genótipos de *Eucalyptus* spp. A biomassa acima do solo foi, em média, de 111,22 t.ha⁻¹ e o estoque de carbono acima do solo teve uma média de 51,25 t.ha⁻¹. Quanto ao compartimento fuste, a biomassa média (100,01 t.ha⁻¹) foi ligeiramente inferior ao compartimento total, assim como o carbono médio (46,09 t.ha⁻¹). Para a copa, a biomassa teve uma média de 10,79 t.ha⁻¹ e 4,97 t.ha⁻¹ de carbono. Em todos os compartimentos, nota-se que o genótipo 21 apresenta a maior concentração de biomassa e carbono. Em contrapartida, têm-se o genótipo 25 com o menor estoque de biomassa e consequentemente, carbono acima do solo.

TABELA 11 – BIOMASSA ACIMA DO SOLO MÉDIA (t.ha⁻¹) E CARBONO ACIMA DO SOLO MÉDIO (t.ha⁻¹) POR COMPARTIMENTO DE GENÓTIPOS DE *Eucalyptus* spp. SÃO PAULO, BRASIL

Genótipo	Biomassa acima do solo (t.ha ⁻¹)			Carbono acima do solo (t.ha ⁻¹)		
	Total	Fuste	Copa	Total	Fuste	Copa
1	110,68	100,21	10,10	51,00	46,18	4,65
2	117,39	106,62	11,11	54,09	49,13	5,12
3	114,26	103,43	10,97	52,65	47,66	5,06
4	131,72	115,87	14,65	60,70	53,39	6,75
5	119,30	107,62	10,71	54,98	49,59	4,93
6	105,90	94,35	11,26	48,80	43,48	5,19


7	121,67	107,93	13,78	56,06	49,73	6,35
8	93,80	86,52	7,39	43,22	39,87	3,41
9	126,32	112,59	12,08	58,21	51,88	5,56
10	120,75	107,68	12,89	55,64	49,62	5,94
11	122,54	109,14	13,14	56,47	50,29	6,05
12	112,07	104,29	7,51	51,64	48,06	3,46
13	105,33	97,22	8,50	48,54	44,80	3,92
14	117,32	109,75	7,40	54,06	50,57	3,41
15	127,02	112,62	14,63	58,53	51,90	6,74
16	86,02	81,41	5,19	39,64	37,51	2,39
17	125,29	111,82	13,32	57,73	51,53	6,14
18	124,00	112,25	10,38	57,14	51,72	4,78
19	119,18	105,82	13,17	54,92	48,76	6,07
20	124,16	113,32	9,77	57,22	52,22	4,50
21	137,61	117,36	17,44	63,41	54,08	8,04
22	128,80	116,32	12,43	59,35	53,60	5,73
23	80,96	67,65	11,90	37,31	31,17	5,48
24	70,14	63,69	6,41	32,32	29,35	2,95
25	32,31	28,34	3,89	14,89	13,06	1,79
Média	111,22	100,01	10,79	51,25	46,09	4,97

FONTE: A autora (2026).

3.3.2 Modelagem da biomassa e carbono acima do solo

Para a aplicação da PCA, a análise exploratória identificou que das 36 métricas extraídas a partir dos dados UAV-LiDAR, 8 métricas apresentavam valores discrepantes ou iguais a 0, e por isso, elas foram removidas. Em seguida, aplicou-se a PCA nas 28 métricas restantes, que identificou que os dois primeiros componentes principais explicavam 81% da variação dos dados (FIGURA 10). Dessa forma, essas métricas foram submetidas a uma análise de correlação que identificou que 20 métricas apresentavam multicolinearidade, removendo-as da análise.

FIGURA 10 – ANÁLISE DE COMPONENTES PRINCIPAIS EM MÉTRICAS UAV-LIDAR EM GENÓTIPOS DE *Eucalyptus* spp.



FONTE: A autora (2026).

Das 8 métricas restantes, foram excluídas as 3 métricas com o menor peso na PCA, sendo elas (altura média, desvio padrão da altura e o percentil da altura a 95%). Assim, foram utilizadas 5 métricas na construção dos modelos preditivos de biomassa aérea e carbono aéreo nos diferentes compartimentos, sendo elas: percentil da altura a 70%, 75%, 80%, 85% e 90%, cujo modelo apresentou um coeficiente de determinação (R^2) de 0,73 e um RMSE de 3,05%.

O ajuste dos modelos construídos por *Stepwise* e por ML para a predição de biomassa aérea e do carbono aéreo nos diferentes compartimentos está sumarizado na TABELA 12. Os modelos ajustados pelo método *Stepwise* demonstraram um poder explicativo ($R^2_{ajustado}$) que variou entre 61% e 78% para as variáveis resposta analisadas. O RMSE percentual apresentou variação de 10,18% a 18,73%, sendo o valor mais elevado observado no carbono de copa.

Entre os métodos de aprendizado de máquina testados, de maneira geral, as técnicas de RF e XGBoost se destacaram; enquanto ANN manteve-se em terceiro lugar. Para a predição da biomassa aérea e do carbono aéreo no compartimento total, RF apresentou valores de $R^2_{ajustado}$ superiores a 0,95 e erros abaixo de 10,5%. Em seguida, XGBoost destacou-se com $R^2_{ajustado}$ de 0,893 para a biomassa e de 0,892 para o carbono acima do solo.

Na estimativa da biomassa e do carbono localizados no fuste, novamente, o algoritmo RF teve o melhor ajuste, com $R^2_{ajustado}$ de 0,959 e 0,961, respectivamente, e erros inferiores a 5%, superando os resultados obtidos com XGBoost e ANN. No compartimento copa, tanto para a biomassa quanto o carbono, o algoritmo RF destacou-se novamente, com $R^2_{ajustado}$ de 0,844 para a biomassa e de 0,924 para o carbono. XGBoost também apresentou ajuste igualmente satisfatório, todavia, ligeiramente inferior a RF, com $R^2_{ajustado}$ de 0,765 para a biomassa e de 0,707 para o carbono. Em contraste, os modelos oriundos das técnicas kNN e SVR para todos os compartimentos apresentaram $R^2_{ajustado}$ inferior a 0,782, com o menor valor observado na predição da biomassa de copa, que foi de 0,285. Esses métodos também apresentaram os maiores erros de predição (entre 10,10% e 28,65%), especialmente no compartimento copa.

TABELA 12 – MODELOS PREDITIVOS BASEADOS EM DADOS UAV-LIDAR PARA ESTIMATIVA DA BIOMASSA ACIMA DO SOLO (t.ha⁻¹) E CARBONO ACIMA DO SOLO (t.ha⁻¹) POR COMPARTIMENTO EM *Eucalyptus* spp.

	Biomassa acima do solo (t.ha ⁻¹)									
	Ajuste (70% dos dados)					Validação (30% dos dados)				
	R ² _{ajustado}	S _{yx} (t.ha ⁻¹)	S _{yx} (%)	RMSE (t.ha ⁻¹)	RMSE (%)	MAE	MPE	MSE	RMSE (t.ha ⁻¹)	RMSE (%)
STEP	0,744	13,30	12,04	13,14	11,90	9,08	8,64	134,69	11,61	10,25
ANN	0,829	10,55	9,56	10,43	9,45	9,59	8,89	159,50	12,63	11,44
kNN	0,758	12,54	11,36	12,40	11,23	10,51	11,09	174,47	13,21	11,96
RF	0,952	6,05	5,48	5,99	5,42	9,12	8,48	133,64	11,56	10,47
SVR	0,719	13,94	12,62	13,45	12,18	8,66	7,63	130,72	11,43	10,10
XGBoost	0,893	8,33	7,54	8,23	7,46	9,06	8,22	137,47	11,72	10,36
	Carbono acima do solo (t.ha ⁻¹)									
	Ajuste (70% dos dados)					Validação (30% dos dados)				
	R ² _{ajustado}	S _{yx} (t.ha ⁻¹)	S _{yx} (%)	RMSE (t.ha ⁻¹)	RMSE (%)	MAE	MPE	MSE	RMSE (t.ha ⁻¹)	RMSE (%)
STEP	0,744	6,13	12,04	6,06	11,90	4,18	8,64	28,60	5,35	10,25
ANN	0,807	5,16	10,15	5,11	10,03	4,41	8,77	33,34	5,77	11,35
kNN	0,758	5,78	11,36	5,71	11,23	4,84	11,09	37,05	6,09	11,96
RF	0,952	2,77	5,44	2,74	5,38	4,21	8,47	28,15	5,31	10,17
SVR	0,719	6,42	12,62	6,20	12,18	3,99	7,63	27,76	5,27	10,10
XGBoost	0,893	3,84	7,56	3,80	7,47	4,20	8,28	29,43	5,43	10,66
Algoritmo	Biomassa de fuste (t.ha ⁻¹)									
	Ajuste (70% dos dados)					Validação (30% dos dados)				
	R ² _{ajustado}	S _{yx} (t.ha ⁻¹)	S _{yx} (%)	RMSE (t.ha ⁻¹)	RMSE (%)	MAE	MPE	MSE	RMSE (t.ha ⁻¹)	RMSE (%)
STEP	0,780	10,39	10,42	10,15	10,18	8,97	10,48	136,20	11,67	11,59
ANN	0,853	8,24	8,26	8,15	8,17	8,34	8,56	130,44	11,42	11,45
kNN	0,782	10,03	10,06	9,92	9,94	10,09	13,91	162,93	12,76	12,80
RF	0,959	4,63	4,64	4,57	4,59	8,18	8,90	116,14	10,78	10,81
SVR	0,763	10,78	10,81	10,41	10,44	8,59	8,64	135,90	11,66	11,58
XGBoost	0,927	5,82	5,83	5,75	5,77	8,14	8,46	121,42	11,02	10,94
	Carbono de fuste (t.ha ⁻¹)									
	Ajuste (70% dos dados)					Validação (30% dos dados)				
	R ² _{ajustado}	S _{yx} (t.ha ⁻¹)	S _{yx} (%)	RMSE (t.ha ⁻¹)	RMSE (%)	MAE	MPE	MSE	RMSE (t.ha ⁻¹)	RMSE (%)
STEP	0,780	4,79	10,42	4,68	10,18	4,13	10,48	28,92	5,38	11,59
ANN	0,848	3,86	8,39	3,81	8,30	3,89	8,81	28,01	5,29	11,52
kNN	0,782	4,62	10,06	4,57	9,94	4,65	13,91	34,60	5,88	12,80
RF	0,961	2,11	4,59	2,09	4,54	3,81	9,16	25,29	5,03	10,84
SVR	0,763	4,97	10,81	4,80	10,44	3,96	8,64	28,86	5,37	11,58
XGBoost	0,932	2,58	5,61	2,55	5,54	3,73	8,37	26,31	5,13	11,16
	Biomassa de copa (t.ha ⁻¹)									
	Ajuste (70% dos dados)					Validação (30% dos dados)				
	R ² _{ajustado}	S _{yx} (t.ha ⁻¹)	S _{yx} (%)	RMSE (t.ha ⁻¹)	RMSE (%)	MAE	MPE	MSE	RMSE (t.ha ⁻¹)	RMSE (%)
STEP	0,610	2,23	20,71	2,02	18,73	2,24	25,55	9,31	3,05	28,22
ANN	0,609	1,90	17,60	1,88	17,40	2,18	23,29	8,24	2,87	26,62
kNN	0,564	2,29	21,26	2,27	21,02	2,58	27,78	9,54	3,09	28,65
RF	0,844	1,54	14,29	1,52	14,13	2,64	28,34	8,89	2,98	27,66
SVR	0,285	3,02	28,04	2,92	27,06	2,22	23,56	6,45	2,54	23,49
XGBoost	0,765	1,47	13,64	1,45	13,49	1,81	18,65	5,39	2,32	21,46
	Carbono de copa (t.ha ⁻¹)									
	Ajuste (70% dos dados)					Validação (30% dos dados)				
	R ² _{ajustado}	S _{yx} (t.ha ⁻¹)	S _{yx} (%)	RMSE (t.ha ⁻¹)	RMSE (%)	MAE	MPE	MSE	RMSE (t.ha ⁻¹)	RMSE (%)
STEP	0,610	1,03	20,71	0,93	18,73	1,03	25,53	1,98	1,41	28,22


ANN	0,609	0,87	17,61	0,86	17,41	1,00	23,16	1,66	1,29	25,97
kNN	0,557	0,93	18,73	0,92	18,52	0,99	23,58	1,48	1,22	24,48
RF	0,924	0,55	11,17	0,55	11,04	0,91	21,16	1,21	1,10	22,07
SVR	0,416	1,26	25,34	1,07	21,44	1,01	23,77	1,54	1,24	24,92
XGBoost	0,707	0,76	15,24	0,75	15,06	0,88	20,31	1,17	1,08	21,79

FONTE: A autora (2026).

LEGENDA: STEP: *Stepwise*; ANN: *Artificial Neural Networks*; kNN: *k-Nearest Neighbor*; RF: *Random Forest*; SVR: *Support Vector Regression*; XGBoost: *Extreme Gradient Boosting*; $R^2_{ajustado}$: Coeficiente de determinação ajustado; S_{yx} : erro padrão da estimativa ($t \cdot ha^{-1}$); S_{yx} (%): erro padrão da estimativa (%); RMSE: Raiz do Erro Quadrático Médio ($t \cdot ha^{-1}$); RMSE (%): Raiz do Erro Quadrático Médio percentual (%); MAE: Erro Absoluto Médio; MPE: Erro Percentual Médio; MSE: Erro Quadrático Médio.


Quanto a distribuição gráfica dos resíduos da base de validação dos modelos construídos com ML e regressão linear múltipla para a estimativa da biomassa acima do solo e do carbono acima do solo (FIGURA 11), nota-se a heterocedasticidade dos resíduos nos algoritmos testados (mas em menor intensidade em RF e XGBoost) especialmente com *Stepwise*, que não atenderam aos pressupostos de regressão avaliados.

FIGURA 11 – MODELOS PREDITIVOS DE A) BIOMASSA ACIMA DO SOLO E B) CARBONO ACIMA DO SOLO POR COMPARTIMENTO EM *Eucalyptus* spp. COM ML E *STEPWISE*




CONTINUAÇÃO DA FIGURA 11 – MODELOS PREDITIVOS DE A) BIOMASSA ACIMA DO SOLO E B) CARBONO ACIMA DO SOLO POR COMPARTIMENTO EM *Eucalyptus* spp. COM ML E

STEPWISE



CONTINUAÇÃO DA FIGURA 11 – MODELOS PREDITIVOS DE A) BIOMASSA ACIMA DO SOLO E
B) CARBONO ACIMA DO SOLO POR COMPARTIMENTO EM *Eucalyptus* spp. COM ML E
STEPWISE



FONTE: A autora (2026).

A TABELA 13 contém as medidas de concordância avaliadas para os modelos testados para a estimativa de biomassa e do carbono acima do solo. O algoritmo RF apresentou as melhores medidas de concordância nos compartimentos total e de fuste. Em seguida, têm-se XGBoost, ANN, SVR e kNN. Para o compartimento copa, o algoritmo XGBoost se destacou; seguido por RF, ANN, SVR e kNN.

TABELA 13 – MEDIDAS DE CONCORDÂNCIA DOS MODELOS PREDITIVOS DE BIOMASSA ACIMA DO SOLO ($t.ha^{-1}$) E CARBONO ACIMA DO SOLO ($t.ha^{-1}$) POR COMPARTIMENTO EM *Eucalyptus* spp.

Algoritmo	Biomassa acima do solo ($t.ha^{-1}$)											
	Total				Ajuste				Validação			
	A	P	CC2	λ	A	P	CC2	λ	A	P	CC2	λ
STEP	0,93	0,85	0,85	0,92	0,93	0,86	0,85	0,92	0,93	0,85	0,84	0,92
ANN	0,95	0,89	0,89	0,94	0,96	0,91	0,91	0,95	0,91	0,82	0,81	0,90
kNN	0,92	0,84	0,80	0,91	0,93	0,85	0,82	0,92	0,88	0,77	0,72	0,87
RF	0,97	0,94	0,94	0,97	0,99	0,97	0,97	0,99	0,93	0,85	0,84	0,92
SVR	0,93	0,86	0,86	0,92	0,93	0,86	0,85	0,92	0,93	0,86	0,86	0,93
XGBoost	0,96	0,92	0,92	0,96	0,97	0,95	0,94	0,97	0,92	0,84	0,83	0,92
Algoritmo	Carbono acima do solo ($t.ha^{-1}$)											
STEP	0,93	0,85	0,85	0,92	0,93	0,86	0,85	0,92	0,92	0,85	0,84	0,92
ANN	0,94	0,88	0,87	0,94	0,95	0,90	0,89	0,95	0,91	0,82	0,80	0,90
kNN	0,92	0,84	0,80	0,91	0,93	0,85	0,82	0,92	0,88	0,77	0,72	0,87
RF	0,97	0,95	0,94	0,97	0,99	0,97	0,97	0,99	0,93	0,85	0,84	0,92
SVR	0,85	0,71	0,71	0,83	0,93	0,86	0,85	0,92	0,59	0,18	0,18	0,31
XGBoost	0,96	0,92	0,91	0,96	0,97	0,94	0,94	0,97	0,92	0,84	0,83	0,91
Algoritmo	Biomassa de fuste ($t.ha^{-1}$)											
STEP	0,94	0,87	0,86	0,93	0,94	0,88	0,88	0,94	0,92	0,85	0,83	0,92
ANN	0,95	0,91	0,90	0,95	0,96	0,93	0,92	0,96	0,93	0,86	0,85	0,93
kNN	0,92	0,85	0,81	0,92	0,94	0,87	0,84	0,93	0,89	0,79	0,71	0,88
RF	0,97	0,95	0,94	0,97	0,99	0,98	0,97	0,99	0,94	0,87	0,86	0,93
SVR	0,94	0,87	0,87	0,93	0,94	0,88	0,88	0,94	0,93	0,86	0,85	0,93
XGBoost	0,97	0,94	0,93	0,97	0,98	0,96	0,96	0,98	0,94	0,87	0,86	0,93
Algoritmo	Carbono de fuste ($t.ha^{-1}$)											
STEP	0,94	0,87	0,86	0,93	0,94	0,88	0,88	0,94	0,92	0,85	0,83	0,92
ANN	0,95	0,90	0,90	0,95	0,96	0,92	0,92	0,96	0,93	0,86	0,85	0,92
kNN	0,92	0,85	0,81	0,92	0,94	0,87	0,84	0,93	0,89	0,79	0,71	0,88
RF	0,97	0,95	0,94	0,97	0,99	0,98	0,97	0,99	0,94	0,87	0,86	0,93
SVR	0,94	0,87	0,87	0,93	0,94	0,88	0,88	0,94	0,93	0,86	0,85	0,93
XGBoost	0,97	0,94	0,93	0,97	0,98	0,97	0,96	0,98	0,94	0,87	0,86	0,93
Algoritmo	Biomassa de copa ($t.ha^{-1}$)											
STEP	0,86	0,71	0,70	0,83	0,90	0,81	0,80	0,89	0,70	0,39	0,39	0,56
ANN	0,87	0,74	0,72	0,85	0,91	0,83	0,81	0,90	0,72	0,44	0,42	0,61
kNN	0,82	0,64	0,63	0,78	0,87	0,74	0,72	0,85	0,65	0,29	0,29	0,45
RF	0,88	0,76	0,73	0,86	0,94	0,88	0,85	0,94	0,65	0,29	0,28	0,45
SVR	0,76	0,51	0,48	0,68	0,76	0,53	0,51	0,69	0,73	0,46	0,38	0,63
XGBoost	0,92	0,83	0,80	0,91	0,95	0,90	0,87	0,95	0,79	0,59	0,53	0,74
Algoritmo	Carbono de copa ($t.ha^{-1}$)											
STEP	0,86	0,71	0,70	0,83	0,90	0,81	0,80	0,89	0,70	0,39	0,39	0,56
ANN	0,87	0,75	0,73	0,85	0,91	0,83	0,81	0,91	0,72	0,44	0,42	0,61
kNN	0,87	0,74	0,72	0,85	0,90	0,80	0,78	0,89	0,65	0,29	0,29	0,45
RF	0,93	0,85	0,81	0,92	0,96	0,93	0,90	0,96	0,65	0,29	0,28	0,45
SVR	0,84	0,68	0,66	0,81	0,87	0,73	0,72	0,85	0,73	0,46	0,38	0,63


XGBoost	0,90	0,80	0,76	0,89	0,93	0,87	0,83	0,93	0,79	0,59	0,53	0,74
---------	------	------	------	------	------	------	------	------	------	------	------	------

FONTE: A autora (2026).


LEGENDA: A: Coeficiente de Concordância; p: Medida de Concordância; CC1: Coeficiente de Correlação de Concordância; CC2: Coeficiente de Correlação de Concordância Melhorado; λ : parâmetro de concordância; STEP: *Stepwise*; ANN: *Artificial Neural Networks*; kNN: *k-Nearest Neighbor*; RF: *Random Forest*; SVR: *Support Vector Regression*; XGBoost: *Extreme Gradient Boosting*.

A FIGURA 12 ilustra o gráfico de concordância de Bland-Altman considerando a base de validação dos modelos preditivos de biomassa e para o carbono acima do solo por compartimento (FIGURA 12).


FIGURA 12 – GRÁFICO DE BLAND-ALTMAN PARA OS MODELOS DE BIOMASSA (t.ha⁻¹) TOTAL (A), DE FUSTE (B) E DE COPA (C) E DE CARBONO (t.ha⁻¹) TOTAL (D), FUSTE (E) E COPA (F) EM *Eucalyptus* spp.



CONTINUAÇÃO DA FIGURA 12 – GRÁFICO DE BLAND-ALTMAN PARA OS MODELOS DE BIOMASSA ($\text{t} \cdot \text{ha}^{-1}$) TOTAL (A), DE FUSTE (B) E DE COPA (C) E DE CARBONO ($\text{t} \cdot \text{ha}^{-1}$) TOTAL (D), FUSTE (E) E COPA (F) EM *Eucalyptus* spp.



CONTINUAÇÃO DA FIGURA 12 – GRÁFICO DE BLAND-ALTMAN PARA OS MODELOS DE BIOMASSA (t.ha^{-1}) TOTAL (A), DE FUSTE (B) E DE COPA (C) E DE CARBONO (t.ha^{-1}) TOTAL (D), FUSTE (E) E COPA (F) EM *Eucalyptus* spp.



FONTE: A autora (2026).

Com base nas métricas de ajuste e validação, nas medidas de concordância e nos gráficos de Bland-Altman, o algoritmo RF foi eleito como o melhor para a estimativa da biomassa total e do fuste, bem como para a avaliação do estoque de carbono total e do carbono do fuste ao passo que os modelos construídos por

XGBoost foram mais eficientes na predição da biomassa e do carbono no compartimento da copa nos genótipos de *Eucalyptus* spp., a partir das métricas UAV-LiDAR.

A TABELA 14 apresenta as estimativas de biomassa e carbono acima do solo por compartimento obtidas a partir dos diferentes métodos de modelagem avaliados. De modo geral, observa-se que as estimativas apresentaram valores muito próximos aos obtidos pelo censo florestal, indicando boa capacidade preditiva dos modelos testados.

O algoritmo RF destacou-se por apresentar as menores diferenças em relação ao censo florestal, com variações médias de 0,23% para a biomassa acima do solo e 0,19% para o carbono acima do solo. No compartimento fuste, o RF manteve o melhor desempenho entre os métodos, com diferenças médias de 0,45% na biomassa e 0,56% no carbono, reforçando sua eficiência na estimativa de componentes mais uniformes da árvore. Já para o compartimento copa, o algoritmo XGBoost apresentou as predições mais próximas ao censo florestal, com diferenças médias de 0,63% para a biomassa e 0,24% para o carbono.

TABELA 14 – ESTIMATIVA DA BIOMASSA ACIMA DO SOLO (t.ha⁻¹) E CARBONO ACIMA DO SOLO (t.ha⁻¹) POR COMPARTIMENTO EM *Eucalyptus* spp. COM STEPWISE E ML

Bloco	Biomassa acima do solo (t.ha ⁻¹)						
	Censo	STEP	ANN	kNN	RF	SVR	XGBoost
2	100,70	105,45	105,07	107,75	103,67	102,57	103,31
4	107,29	109,79	109,84	111,64	107,86	107,26	107,83
7	111,99	111,12	110,42	112,34	110,30	108,45	109,24
8	115,39	113,40	112,40	113,40	113,38	111,03	111,84
10	121,15	118,63	118,85	119,15	120,02	116,92	117,66
Média	111,22	111,62	111,26	112,80	110,97	109,18	109,92
Bloco	Carbono abaixo do solo (t.ha ⁻¹)						
	Censo	STEP	ANN	kNN	RF	SVR	XGBoost
2	46,40	48,59	48,73	49,65	47,75	46,76	47,63
4	49,44	50,59	50,87	51,44	49,74	49,34	49,66
7	51,60	51,20	50,95	51,77	50,82	50,63	50,37
8	53,17	52,26	51,65	52,25	52,27	50,67	51,50
10	55,82	54,66	54,47	54,90	55,36	52,90	54,26
Média	51,25	51,44	51,31	51,98	51,16	50,04	50,65
Bloco	Biomassa de fuste (t.ha ⁻¹)						
	Censo	STEP	ANN	kNN	RF	SVR	XGBoost
2	90,37	95,05	95,23	96,90	93,83	92,93	93,69
4	96,46	98,83	99,17	100,20	97,70	97,08	97,23
7	101,17	99,56	99,85	101,17	100,68	98,25	99,81
8	103,87	101,23	101,00	102,14	102,35	100,38	100,94
10	108,51	105,57	106,32	107,21	108,06	105,26	106,45
Média	100,01	100,00	100,26	101,48	100,46	98,73	99,57
Bloco	Carbono de fuste (t.ha ⁻¹)						
	Censo	STEP	ANN	kNN	RF	SVR	XGBoost

2	41,64	43,80	43,97	44,65	43,23	42,82	43,15
4	44,45	45,54	45,75	46,17	45,08	44,74	44,88
7	46,62	45,88	46,01	46,62	46,47	45,27	45,92
8	47,86	46,65	46,53	47,07	47,20	46,25	46,51
10	50,00	48,65	48,97	49,40	49,87	48,51	49,15
Média	46,09	46,08	46,23	46,76	46,34	45,49	45,89
Bloco	Biomassa de copa (t.ha⁻¹)						
	Censo	STEP	ANN	kNN	RF	SVR	XGBoost
2	9,84	10,20	10,15	10,14	10,03	10,00	9,86
4	10,40	11,03	11,06	10,22	10,40	10,44	10,62
7	10,38	10,84	10,99	10,51	10,32	10,50	10,71
8	11,06	10,45	10,39	11,11	11,28	10,80	10,86
10	12,34	11,67	11,50	11,66	11,96	11,44	11,60
Média	10,79	10,83	10,81	10,72	10,79	10,63	10,72
Bloco	Carbono de copa (t.ha⁻¹)						
	Censo	STEP	ANN	kNN	RF	SVR	XGBoost
2	4,53	4,70	4,69	4,54	4,63	4,52	4,55
4	4,79	5,08	5,08	4,95	4,97	4,90	4,90
7	4,78	5,00	5,08	5,10	4,99	4,97	5,01
8	5,10	4,81	4,81	5,02	5,14	4,85	5,01
10	5,69	5,38	5,31	5,58	5,46	5,22	5,35
Média	4,97	4,99	4,99	5,03	5,04	4,89	4,96

FONTE: A autora (2026).

LEGENDA: STEP: *Stepwise*; ANN: *Artificial Neural Networks*; kNN: *k-Nearest Neighbor*; RF: *Random Forest*; SVR: *Support Vector Regression*; XGBoost: *Extreme Gradient Boosting*.

Por fim, a análise comparativa entre as estimativas de biomassa e carbono acima do solo e os valores do censo florestal revelou a ausência de normalidade nas diferenças entre a abordagem em nível de área em todos os compartimentos pelo teste de Shapiro-Wilk. Dessa forma, a aplicação do teste de Wilcoxon, cujos valores de p foram menores que 0,05, evidenciou as diferenças significativas entre os valores de biomassa e carbono acima do solo estimados a nível de área e os valores do censo florestal. O ANEXO 1 contém a espacialização da biomassa e do carbono acima do solo preditos para cada bloco de *Eucalyptus* spp. a partir do algoritmo RF nos compartimentos total e fuste e do algoritmo XGBoost no compartimento copa.

3.4 DISCUSSÃO

Esta pesquisa objetivou quantificar a biomassa e o estoque de carbono considerando os compartimentos fuste e copa e ambos (acima do solo) de genótipos de *Eucalyptus* spp. pela abordagem ABA a partir da integração de dados UAV-LiDAR e diferentes técnicas de modelagem.

De acordo com as variáveis dendrométricas provenientes do censo florestal, pode-se observar variações no crescimento dos genótipos entre os blocos,

evidenciando a interação genótipo com o ambiente e seu impacto na produção de biomassa, sendo esta maior nos genótipos 20 e 18 e menor nos genótipos 16 e 25 (FIGURA 7). Na distribuição da biomassa nos componentes arbóreos, o fuste (lenho e casca) representou 89% da biomassa total dos genótipos. O maior acúmulo de biomassa no lenho deve-se a idade dos genótipos, pois, com o desenvolvimento desses plantios, houve redução na biomassa da copa e um aumento na proporção de biomassa no lenho e na casca. Além disso, fatores como as condições do local, da espécie e dos materiais genéticos, das condições climáticas, da densidade do plantio e da duração da rotação também podem influenciar a distribuição da biomassa nos reservatórios de armazenamento (OLEMBERG; LUPI, 2024).

O lenho também foi o compartimento com a maior contribuição na biomassa de plantios com idades entre 4 a 6 anos de *Eucalyptus urophylla* x *Eucalyptus grandis*. Nas quatro áreas analisadas, a concentração do lenho na biomassa foi entre 69% a 86%, na sequência, têm-se os demais componentes: casca (6% a 11%), raízes (1% a 10%), galhos (1% a 9%) e folhas (1% a 4%) (RIBEIRO *et al.*, 2024).

As estimativas de biomassa e o carbono acima do solo nos diferentes compartimentos pelo modelo de Schumacher-Hall foram consistentes com estudos conduzidos com os genótipos similares cultivados em outras condições, conforme Ribeiro *et al.* (2024). Na referida pesquisa, plantios de *E. urophylla* x *E. grandis* com 4 anos de idade, implantados com espaçamentos de 3,5 m x 1,7 m e 3 m x 2 m, armazenaram nos compartimentos aéreos, em média, 41,75 kg.árv⁻¹ de carbono em 12 hectares (RIBEIRO *et al.*, 2024).

Em outra pesquisa, conduzida em dois locais experimentais com condições climáticas contrastantes e com espaçamento de 3 m x 3 m, pertencentes ao Programa Cooperativo de Pesquisa para a Tolerância de *Eucalyptus* spp. a Estresses Hídrico, Térmico e Biótico (TECHS) do IPEF, os resultados indicaram que as plantações de *E. urophylla* e *E. grandis* x *E. camaldulensis* armazenaram, em média, 38,7 t.ha⁻¹ de carbono aos 3 anos de idade e 81,2 t.ha⁻¹ de carbono no final da rotação (seis anos) (BASÍLIO *et al.*, 2024).

Quanto a biomassa acima do solo, os resultados dessa pesquisa (111,22 t.ha⁻¹) estão em concordância com a literatura. Santos *et al.* (2019) quantificaram a biomassa acima do solo de cinco genótipos de *Eucalyptus* spp. de 4 anos localizados em Eldorado do Sul, no Rio Grande do Sul, encontrando valores

similares para genótipos semelhantes de 92,19 t.ha⁻¹ em *E. benthamii* e de 102,04 t.ha⁻¹ em *E. benthamii* na área 2, de 89,25 t.ha⁻¹ em *E. saligna*, de 68,40 t.ha⁻¹ em *E. dunnii*, de 117,52 t.ha⁻¹ em *E. uroglobulus* e de 101,80 t.ha⁻¹ *E. urograndis*.

As disparidades encontradas nas estimativas de biomassa e carbono decorrentes do uso de cada algoritmo relacionam-se diretamente com quatro fatores principais: i) características do plantio e da área experimental (espaçamento, idade, topografia); ii) conjunto de dados UAV-LiDAR (densidade de pontos, interação dos retornos *laser* com a copa, conjunto de métricas) e abordagem ABA; iii) interações genótipo-ambiente (eficiência nutricional, absorção de luz solar, capacidade fotossintética, resistência e tolerância a condições adversas) e, iv) parâmetros de otimização de cada algoritmo.

Quanto ao conjunto de dados UAV-LiDAR, a alta densidade de pontos (média de 389 pontos.m⁻²) contribuiu para a geração de modelos digitais representativos, mesmo com o adensamento e a homogeneidade existente nos genótipos, o que pode aumentar a interceptação dos pulsos *laser* pela copa e a concentração de retornos nos pontos mais altos da nuvem, que irá representar a superfície do topo do dossel da floresta (SHAN; TOTH, 2018). Dessa forma, pode-se observar que os pontos mais altos e mais baixos foram representados de forma coerente nos modelos digitais e conseqüentemente, no CHM e nas respectivas métricas, conforme foi evidenciado pelas análises estatísticas que não encontraram diferenças significativas entre as alturas obtidas em campo com as alturas oriundas do LiDAR.

A abordagem ABA possui ampla utilização na área florestal, especialmente para inventário e mapeamento, porém, limita-se ao uso de métricas derivadas da distribuição vertical dos retornos do LiDAR (WHITE *et al.*, 2017). Assim, as métricas contidas no tamanho de célula utilizado compreendem a principal fonte de análise dessa abordagem (WHITE *et al.*, 2017).

Ainda nesse quesito, a influência das parcelas também deve ser considerada, pois o número, tamanho, formato e precisão da geolocalização das mesmas interferem na precisão das estimativas de biomassa (SCHÄFER *et al.*, 2023). Nesse estudo, apenas 124 parcelas foram utilizadas; sendo parcelas com área de 0,06 ha e formato retangular. Packalen *et al.* (2023) recomendam que um maior número de parcelas e dimensões maiores pode reduzir os erros de geolocalização e conseqüentemente, no processo de estimativas da biomassa.

As interações genótipo e ambiente também podem ter influenciado na produção de biomassa e no estoque de carbono, pois, dentre essas interações, a eficiência nutricional pode variar para cada espécie, pelas características morfológicas (sistema radicular eficiente, alta relação raiz parte aérea e sistema radicular extensivo) e fisiológicas (taxa fotossintética e a capacidade de manter o metabolismo com baixo teor de nutrientes nos tecidos) (CUNHA *et al.*, 2023).

A modelagem de biomassa e carbono por compartimento revelou que, nos compartimentos total e fuste o melhor modelo preditivo foi derivado do algoritmo RF. Já no compartimento copa, o algoritmo XGBoost foi superior aos demais, visto que esse algoritmo tem capacidade de capturar relações não lineares complexas presentes na copa, onde a distribuição e a densidade da folhagem variaram entre genótipos e entre os blocos experimentais.

O algoritmo RF mescla previsões de diversas árvores de decisão utilizando a amostragem *bootstrap*, escolhendo subconjuntos de variáveis de forma aleatória em cada divisão. Isso diminui a variância em previsões complexas (BREIMAN, 2001; TORRE-TOJAL *et al.*, 2022), o que permite reduzir o risco de *overfitting* e aumentar a precisão (PINEDO *et al.*, 2025).

O RF tem demonstrado consistência na estimativa de biomassa com base em dados LiDAR em aplicações florestais. Por exemplo, Pinedo *et al.* (2025) relataram alta precisão na estimativa da biomassa acima do solo de *Eucalyptus globulus* no Peru, utilizando dados LiDAR adquiridos com um DJI Zenmuse L1. O modelo criado com RF alcançou uma acurácia de R^2 de 0,76 no conjunto de treinamento e de 0,66 no conjunto de teste. Em contrapartida, a regressão linear múltipla apresentou um R^2 de 0,647, enquanto a *Elastic Net* obteve um R^2 de 0,58 na fase de treinamento e de 0,57 na fase de teste (PINEDO *et al.*, 2025). Marchesan *et al.* (2020) alcançaram um R^2 de 0,69 e um RMSE de 47 mg.ha⁻¹ em floresta tropical com corte seletivo, utilizando a altura média derivada dos dados LiDAR como métrica principal.

No entanto, em situações complexas que envolvem grandes volumes de dados, algoritmos como o XGBoost têm se destacado em relação ao RF em termos de precisão e eficácia. Uma revisão recente sobre estoques de carbono florestal revelou que, apesar do RF ser amplamente empregado (cerca de 88% dos estudos), o algoritmo XGBoost apresentou melhor desempenho em 75% das comparações diretas (NGUYEN; SAHA, 2024).

Em relação ao XGBoost, seu desempenho é atribuído à técnica de aprendizado aditivo, que envolve um processo de aprendizagem ajustado conforme os dados de entrada, seguido pela adaptação aos resíduos (CHEN; GUESTRIN, 2016). Esse processo de ajuste é reiterado até que os critérios de parada sejam atingidos. Desse modo, esse algoritmo se fundamenta em árvores de decisão de reforço, que empregam aprendizado de máquina supervisionado com estratégias de treinamento aditivo. Isso minimiza o problema de *overfitting*, otimizando a função de perda não por meio da derivada de primeira ordem, mas por uma expressão eficaz de segunda ordem (CHEN; GUESTRIN, 2016).

Em aplicações florestais que utilizam dados UAV-LiDAR, o XGBoost consegue identificar relações não lineares complexas entre métricas de altura, densidade de pontos e intensidade, geralmente superando o *Random Forest* em situações com alta heterogeneidade espacial ou em casos com múltiplos compartimentos da árvore (NGUYEN; SAHA, 2024). Contudo, seu desempenho está fortemente ligado ao ajuste de hiperparâmetros (como número de árvores, profundidade máxima e taxa de aprendizado) (CHEN; GUESTRIN, 2016), demandando mais recursos computacionais do que o RF.

Pesquisas com plantações de *Eucalyptus* spp. usando LiDAR por UAV confirmam esses resultados. Por exemplo, Ye *et al.* (2025) usaram o XGB para estimar a biomassa aérea acima do solo de *Eucalyptus globoides* e *Eucalyptus bosistoana*, empregando métricas estruturais da copa obtidas do LiDAR. O modelo alcançou um R^2 de 0,903, sendo o mais preciso em relação ao RF e SVR. Em pesquisas anteriores utilizando o XGB, a combinação de imagens Landsat-8 e Sentinel-1A como variáveis preditoras para a estimativa de biomassa pelo XGB alcançou um R^2 de 0,75 e um RMSE (%) de 38,28 em florestas subtropicais na China (LI *et al.*, 2020). A biomassa acima do solo em florestas de Jharkhand, Índia, foi estimada com um R^2 de 0,83, utilizando índices de vegetação obtidos a partir de imagens Sentinel (ANANDITA; SINHA; JEGANATHAN, 2024).

De forma geral, a ANN foi o terceiro método com melhor desempenho. Apesar de ter identificado relações não lineares, o modelo apresentou maior sensibilidade em relação à quantidade de dados disponíveis. Ademais, Lu *et al.* (2016) apontam que diversos fatores podem afetar o desempenho das ANN, como a quantidade de dados nos conjuntos de teste e validação (considerando que seu uso demanda uma grande quantidade de dados), processamento paralelo distribuído e

aprendizado não linear e adaptativo. Algumas dessas características fazem com que seu processamento seja considerado uma "caixa preta", o que dificulta a explicação das variáveis e a incapacidade de convergência no treinamento e na aproximação de funções (LU *et al.*, 2016).

Conforme a literatura disponível, a estimativa da biomassa aérea e do carbono aéreo em *Eucalyptus* utilizando dados UAV-LiDAR por meio da aplicação de ANNs apresentou resultados semelhantes aos desta pesquisa, como demonstrado no estudo realizado por Li *et al.* (2022). Neste estudo, a biomassa aérea de *Eucalyptus globulus* foi estimada com R^2 variando entre 0,85 e 0,92, dependendo da densidade de pontos dos dados LiDAR e das características do dossel.

No entanto, apesar de serem eficientes na modelagem de padrões não lineares, as ANNs costumam ser superadas por algoritmos como o XGB em compartimentos com alta heterogeneidade espacial, como a copa. Isso se deve à superior capacidade do XGB em apresentar maior otimização a função de perda e adaptação a resíduos complexos.

Similarmente aos estudos com os outros algoritmos, existe uma lacuna de estudos com ANN e métricas UAV-LiDAR para a predição de biomassa e carbono de plantios clonais de *Eucalyptus* spp. no Brasil. Com outros dados de SR, pode-se citar a pesquisa conduzida por Domingues *et al.* (2020) com o uso de dados multiespectrais e SAR (*Synthetic Aperture Radar*) na estimativa da biomassa de *Eucalyptus urophylla* x *Eucalyptus grandis* em Minas Gerais, Brasil. Os dados foram provenientes de 206 parcelas de inventário e os modelos derivados das ANN obtiveram um R^2 de 0,95 e RMSE de 2,87% com erros variando de -8% a 4% (DOMINGUES *et al.*, 2020).

Os resultados para a predição da biomassa e de carbono nos compartimentos total e fuste nos genótipos de *Eucalyptus* spp. reforçam que, embora a regressão linear tenha sido superior a alguns métodos de aprendizado de máquina (kNN e SVR), esse método baseia-se em relações lineares de variáveis como a biomassa e carbono com as variáveis preditoras, não identificando as relações complexas existentes entre a biomassa e/ou carbono e as variáveis oriundas de dados UAV-LiDAR. Porém, Pinedo *et al.* (2025) destacam que a regressão linear múltipla pode basear comparações com métodos mais complexos, como os algoritmos de aprendizado de máquina ou modelos não lineares.

Na presente pesquisa, a regressão linear múltipla não gerou estimativas adequadas, ao contrário de outros estudos, nos quais demonstrou excelente desempenho na estimativa da biomassa e carbono de *Eucalyptus* spp. Em clones de *Eucalyptus urophylla* x *Eucalyptus grandis*, os modelos derivados dessa técnica estimaram o estoque de carbono com R^2_{ajustado} superior a 0,98 e RMSE (%) inferiores a 12,86% (RIBEIRO *et al.*, 2024). Em *Eucalyptus grandis* de 6,5 anos de idade, modelos de regressão linear simples construídos com métricas LiDAR para a estimativa de carbono obtiveram um R^2_{ajustado} de 0,97 (SILVA *et al.*, 2015).

Quanto a aplicação dos algoritmos com os maiores erros, no caso do SVR, a ausência de uma abordagem padrão para a otimização dos parâmetros do modelo assim como em Cherkassky e Ma (2004) pode ter resultado em estimativas imprecisas. Quanto ao kNN, deve-se destacar a otimização do número de vizinhos mais próximos a partir de diferentes distâncias e métodos de ponderação. Tais parâmetros podem melhorar a performance desse algoritmo (McROBERTS; NÆSSET; GOBAKKEN, 2015) em predições de biomassa e carbono visto que a métrica de distância é utilizada para determinar quais observações de treinamento se aproximam mais do valor alvo considerando as variáveis preditoras (COSENZA *et al.*, 2021).

O kNN mostrou um desempenho consistente, porém inferior ao dos outros algoritmos, exceto o SVR. Isso pode ser atribuído à sua natureza não paramétrica e à forte dependência na seleção do número de vizinhos e da métrica de distância. Em regiões florestais, a diversidade estrutural afeta diretamente a proximidade dos vizinhos, o que pode resultar em uma maior variação nas estimativas de biomassa. Pesquisas como a de Li *et al.* (2020) apontam que o kNN é sensível a conjuntos de dados de alta dimensionalidade e que seu desempenho tende a cair na ausência de uma correlação espacial ou estrutural significativa entre as parcelas vizinhas.

Por outro lado, o SVR apresentou um ajuste superior em diversas condições, corroborando os estudos de Lu *et al.* (2016) e Gao e Zhang (2021). Esses estudos destacaram a habilidade do algoritmo em lidar com relações não lineares complexas entre as variáveis oriundas dos dados UAV-LiDAR e a biomassa. A utilização de funções *kernel*, como a função de base radial (*Radial Basis Function*), possibilita que o SVR identifique padrões não lineares de maneira mais eficaz do que métodos baseados em proximidade, como o kNN. Entretanto, a calibração dos parâmetros (C , ϵ e γ) é fundamental e pode demandar um alto custo computacional. Ademais, o

SVR é menos intuitivo e sua interpretação é mais restrita quando comparado a métodos baseados em vizinhança.

Além disso, deve-se levar em consideração algumas limitações desta pesquisa, como o sensor *Zenmuse L1* empregado. O tipo de sensor e, particularmente a taxa de pulso e o tipo de retorno, afeta a penetração do dossel, a densidade de pontos e a altitude de voo (POLEY; McDERMID, 2020). Esses fatores podem impactar a estimativa da biomassa em copas que são muito densas ou heterogêneas. Ademais, o desempenho do modelo pode ser afetado pela heterogeneidade espacial das parcelas e pela quantidade limitada de dados.

Apesar de os métodos convencionais de aprendizado de máquina (RF, XGB, ANN, SVR e kNN) terem sido apropriados para o escopo deste estudo experimental com um número restrito de parcelas, a literatura recente aponta que as técnicas modernas de *Deep Learning* (DL) têm se revelado mais eficientes na estimativa de biomassa acima do solo em cenários mais complexos e com dados multimodais. Por exemplo, Oehmcke *et al.* (2021) empregaram redes neurais convolucionais tridimensionais adaptadas diretamente em nuvens de pontos LiDAR aéreo para estimar biomassa e volume de madeira, observando melhorias consideráveis em relação aos métodos estatísticos tradicionais.

Ainda nesse contexto, Sarafov *et al.* (2024) aplicaram o *ForestIQNet*, uma arquitetura multimodal que integra imagens multiespectrais de UAV e modelos 3D provenientes de CHM em um modelo fundamentado em *Convolutional Neural Network*. Esse modelo alcançou um R^2 superior a 0,89, em comparação com os R^2 variando entre 0,78 e 0,82 obtidos por RF e XGBoost. Dong *et al.* (2023) utilizaram um modelo baseado em atenção (*Attention-Based Deep Learning*), combinado com dados *Global Ecosystem Dynamics Investigation* (GEDI), Sentinel-1, PALSAR-2 (*Phased Array L-band Synthetic Aperture Radar*) e Sentinel-2. Esse modelo apresentou um desempenho superior ao RF na estimativa de biomassa acima do solo.

Diante disso, recomenda-se que futuros estudos sejam conduzidos com a integração de outras plataformas de aquisição de dados LiDAR, como *Terrestrial Laser Scanning* (TLS) e ortofotos com alta resolução adquiridas por UAV. Nesse contexto, Li *et al.* (2022) mostrou que a fusão de dados LiDAR adquiridos em plataforma aérea e dados multiespectrais permite uma distribuição mais precisa da vegetação, aprimorando a estimativa de biomassa. Zhou, Li e Li (2025) propuseram

um *framework* automatizado para extrair atributos individuais de árvores usando UAV-LiDAR de alta densidade, indicando que a combinação com ortofotos aumenta a precisão do inventário e monitoramento. De forma complementar, Huang *et al.* (2022) utilizou a fusão de dados de câmera digital aérea e UAV-LiDAR, evidenciando que a integração de diferentes fontes de informação proporciona vantagens na estimativa de biomassa, sugerindo potencial para análises mais detalhadas em múltiplos compartimentos da árvore.

Por fim, salienta-se que o uso da abordagem ABA utilizada nessa pesquisa em plantios de *Eucalyptus* spp. deve considerar a formação de estratos (mesma espécie e data de plantio) e amostragem destrutiva de biomassa aérea juntamente com voos UAV-LiDAR sazonais, para a obtenção das métricas. Recomenda-se o uso de um cronograma de voos, com início após o plantio e posteriormente, de forma anual. Com a devida aplicação desses dados nos modelos preditivos de biomassa aérea e carbono aéreo, os resultados gerados podem subsidiar decisões para o monitoramento do estoque dessas áreas, além de identificar seu ritmo de crescimento e seu papel no enfrentamento da emergência climática.

3.5 CONCLUSÃO

A partir dos métodos de modelagem testados para a quantificação da biomassa e do carbono em diferentes compartimentos (total, copa e fuste) de genótipos de *Eucalyptus* spp. aos 4,5 anos de idade utilizando dados UAV-LiDAR, o algoritmo RF foi eleito para a para a predição da biomassa acima do solo e carbono acima do solo, além da biomassa do fuste e do carbono do fuste. Para o compartimento copa, o algoritmo XGB foi superior aos demais na estimativa da biomassa e do carbono. Ademais, os resultados revelaram que existem diferenças significativas entre as estimativas de biomassa e carbono acima do solo obtidas a nível de área e pelo censo florestal.

Tais resultados reforçam a eficácia dos dados UAV-LiDAR associados a métodos avançados de modelagem, como algoritmos de aprendizado de máquina, para a quantificação do estoque de biomassa e do carbono acima do solo em plantios clonais de *Eucalyptus* spp. Por fim, recomenda-se a integração da abordagem a nível de área com dados UAV-LiDAR adquiridos em outras plataformas,

considerando outras espécies e diferentes técnicas para a extração de métricas, visando aumentar a precisão das estimativas de biomassa e carbono.

4 DETECÇÃO E MODELAGEM INDIVIDUAL DE BIOMASSA E CARBONO ACIMA DO SOLO DE GENÓTIPOS DE *Eucalyptus* spp. COM UAV-LIDAR

RESUMO

Essa pesquisa teve como objetivo detectar automaticamente copas de *Eucalyptus* spp. utilizando algoritmos tradicionais e de *Deep Learning* e estimar a biomassa e o carbono acima do solo, por compartimento, em nível individual, com dados UAV-LiDAR. A área de pesquisa integra o projeto EUCFLUX e está localizada em Itatinga, São Paulo, sendo composta por cinco blocos experimentais implantados em 2018, com 25 genótipos de *Eucalyptus* spp. Em maio de 2023, foi realizado o censo florestal nas parcelas e a amostragem destrutiva da biomassa acima do solo em 150 árvores. Posteriormente, os dados UAV-LiDAR foram adquiridos com um sensor *Zenmuse* L1 embarcado em um DJI Matrice 300, originando a nuvem de pontos e o ortomosaico da área de estudo. O processamento envolveu a geração dos modelos digitais e a extração das métricas derivadas dos dados UAV-LiDAR. A biomassa acima do solo foi estimada pelo modelo adaptado de Schumacher-Hall, utilizando o percentil da altura a 95% e o diâmetro estimado pelo modelo linear, enquanto o carbono acima do solo foi calculado pela multiplicação da biomassa pelo teor de carbono de 46%. Para a detecção automática das copas, foram avaliados três algoritmos: *Local Maxima Filter* (LMF), *Segment Anything Model* (SAM) e o *Detectron2*, utilizando copas delineadas por interpretação visual como referência. A acurácia da detecção foi avaliada por meio do F1-Score e o *Intersect over Union* (IoU). A modelagem individual da biomassa e do carbono acima do solo iniciou com a seleção das métricas por Análise de Componentes Principais, seguida pelo ajuste dos modelos com *Stepwise*, ANN, kNN, RF, SVR e XGBoost e a validação baseada em medidas de concordância. Os resultados indicaram que a vetorização por interpretação visual identificou 7.613 copas, enquanto a detecção automática identificou 7.135 copas (94%) pelo *Detectron2*, 6.816 copas (90%) com o SAM e 4.148 copas (54%) com o LMF. Entre os métodos de modelagem avaliados, o XGBoost foi o método mais eficiente na estimativa da biomassa e do carbono acima do solo em todos os compartimentos, com R^2_{ajustado} de 0,961 e erros inferiores a 5,8% nos compartimentos total e de fuste e R^2_{ajustado} de 0,836 e erros inferiores a 16,3% na copa. A partir da integração entre a detecção de copas com o *Detectron2* e os modelos baseados em XGBoost, foi possível estimar a biomassa e o carbono acima do solo em nível individual, evidenciando o elevado potencial da combinação entre dados UAV-LiDAR, algoritmos avançados de detecção de copas e técnicas robustas de modelagem para a quantificação da biomassa e do carbono acima do solo em genótipos de *Eucalyptus* spp.

Palavras-chave: aprendizado profundo; *Canopy Height Model*; *Detectron2*; modelagem individual; *Segment Anything Model*.

4.1 INTRODUÇÃO

Em um cenário marcado pela emergência climática, os plantios florestais, como os de *Eucalyptus* spp., desempenham papel importante na remoção de CO₂ da atmosfera e no seu armazenamento na biomassa, contribuindo para estratégias de mitigação das mudanças climáticas (PSISTAKI; TSANTOPOULOS; PASCHALIDOU, 2024). Nesse contexto, a quantificação precisa da biomassa e do carbono acima do solo é fundamental para o planejamento e a gestão florestal, especialmente em iniciativas voltadas ao monitoramento dos estoques de carbono (PSISTAKI; TSANTOPOULOS; PASCHALIDOU, 2024).

Os métodos diretos de quantificação de biomassa florestal, como a amostragem destrutiva, são reconhecidos por sua elevada robustez, porém, são limitados pelo tempo de execução e custo (MORAES *et al.*, 2025). Diante disso, os métodos indiretos que combinam equações alométricas com dados de Sensoriamento Remoto (ROMERO *et al.*, 2020) têm se destacado como alternativas eficientes para a estimativa da biomassa florestal em larga escala, especialmente com o uso da tecnologia LiDAR (PERTILLE *et al.*, 2025; PINEDO *et al.*, 2025; YE *et al.*, 2025).

As aplicações de dados LiDAR aerotransportados em inventários florestais tem possibilitado avanços importantes na detecção de árvores individuais e estimativas de biomassa e carbono, tradicionalmente realizadas em nível de povoamento (CAMPBELL *et al.*, 2023; DUBROVIN *et al.*, 2024; LIN *et al.*, 2024). Para a identificação dos indivíduos, diversos métodos têm sido desenvolvidos, incluindo métodos baseados diretamente na nuvem de pontos LiDAR explorando padrões de densidade e topologia, métodos baseados em arquivos *raster*, como os modelos de altura de dossel ou CHM e abordagens híbridas que combinam ambas as fontes de informação (nuvens de pontos e imagens) (BORGOGNO MONDINO *et al.*, 2020; SPARKS; SMITH, 2022).

Além desses métodos, avanços recentes em segmentação de imagens e *Deep Learning* (DL), têm ampliado as possibilidades de detecção de copas e indivíduos a partir de imagens, nos quais regiões ou objetos são identificados e segmentados (OSCO *et al.*, 2023). Nesse contexto, destacam-se modelos como o *Segment Anything Model* (SAM) (OSCO *et al.*, 2023) criado pela Meta AI e o *Detectron2*, desenvolvido pelo *Facebook AI Research* (FAIR) (RAKSHITHA *et al.*,

2024), os quais representam abordagens inovadoras para a segmentação de objetos, com alta capacidade de generalização a partir de poucos ou nenhum dado de treinamento (OSCO *et al.*, 2023).

Dessa forma, os avanços na identificação e segmentação de indivíduos a partir de imagens ou dados UAV-LiDAR tem impulsionado a adoção da abordagem em nível individual, possibilitando a extração de métricas relacionadas à altura e atributos de copa (ROUSSEL *et al.*, 2020). Tais informações são utilizadas para a construção de modelos preditivos de biomassa e carbono acima do solo em escala individual com maior precisão, a partir de diferentes técnicas de modelagem, como *k-Nearest Neighbor* (kNN) (YAN *et al.*, 2024a), *Random Forest* (RF) (PINEDO *et al.*, 2025), *Support Vector Regression* (SVR) (YAN *et al.*, 2024a) e *Extreme Gradient Boosting* (XGBoost) (YE *et al.*, 2025).

Apesar do grande potencial da abordagem individual, a maioria das pesquisas ainda está concentrada em estimativas de biomassa e carbono acima do solo com a abordagem a nível de área (povoamento ou por parcelas), a qual desconsidera a variabilidade estrutural existente entre os indivíduos. Essa limitação pode resultar em incertezas nas estimativas especialmente em plantios com genótipos de *Eucalyptus* spp., em que diferenças genéticas, efeitos de competição e condições micro ambientais podem influenciar o crescimento e o armazenamento de biomassa e, conseqüentemente, o estoque de carbono acima do solo.

Nesse contexto, a estimativa em nível individual permite maior detalhamento estrutural, especialmente em áreas heterogêneas, reduzindo erros associados a média por área e gerando informações com maior detalhamento para o manejo florestal e para o monitoramento do estoque de carbono. Além disso, fatores como o número de amostras em campo e o ajuste de modelos alométricos conforme a espécie, idade e local também influenciam a quantificação da biomassa e do carbono acima do solo (BORSAH *et al.*, 2023; MA *et al.*, 2024).

Diante da temática abordada, essa pesquisa justifica-se por representar um avanço metodológico ao integrar algoritmos avançados para a detecção automática de indivíduos de *Eucalyptus* spp. e a posterior modelagem de biomassa e carbono acima do solo por compartimento em nível individual. Ainda nesse contexto, este trabalho teve como objetivo identificar indivíduos de genótipos de *Eucalyptus* spp. utilizando algoritmos tradicionais e de DL para quantificar, com enfoque em árvore individual, a biomassa e o estoque de carbono acima do solo usando regressão


linear múltipla e métodos de aprendizado de máquina e verificar se existem diferenças significativas entre tais estimativas a nível individual e o censo florestal.

4.2 MATERIAL E MÉTODOS

4.2.1 Descrição da área

A área avaliada pertence a fazenda Americana e está localizada no município de Itatinga, no estado de São Paulo, Brasil. A fazenda é de posse de uma empresa florestal no ramo de celulose e papel e possui uma área experimental de 192,54 hectares na qual foi conduzida essa pesquisa (FIGURA 13). Essa área está vinculada ao projeto EUCFLUX desenvolvido em parceria com o IPEF (IPEF, 2025) e com o CIRAD.

FIGURA 13 – GENÓTIPOS DE *Eucalyptus* spp. EM ITATINGA, SÃO PAULO, BRASIL



FONTE: A autora (2026).

A área apresenta clima subtropical úmido e quente, com verões quentes e invernos secos de acordo com Köppen, classificada como Cfa (ALVARES *et al.*, 2013). Possui altitude de 845 metros ao nível do mar, temperatura média anual de 19,4°C e precipitação média anual de 1.319 mm (ALVARES *et al.*, 2013), seu relevo é majoritariamente plano, com Latossolo Vermelho Distrófico Típico (LVd4), Latossolo Vermelho-Amarelo Distrófico Típico (LVAd4) e Latossolo Vermelho Distrófico Típico (LVd2) (EMBRAPA, 2006).

A área experimental é formada por 5 blocos: 2, 4, 7, 8 e 10 (a nomenclatura segue a dos dados de campo) com 25 materiais genéticos do gênero *Eucalyptus* spp. plantados em 2018 provenientes do projeto EUCFLUX com espaçamento de 3 m x 2 m com sistema de manejo de alto fuste e 1.666 árv.ha⁻¹. Cada bloco contém uma área aproximada de 2,80 hectares, com 60 linhas x 80 árvores, sendo formado por 25 parcelas ou sub-blocos. O bloco contém 180 m x 160 m, com 25 parcelas de 36 m x 32 m, dispostas em 12 linhas e 16 árvores, totalizando 192 árvores por parcela. Dentro da parcela, a área de efetiva medição é formada por 600 m² ou 0,06 ha (30 m x 20 m), ou seja, somente por 10 linhas x 10 árvores, totalizando 100 árvores por parcela nos blocos avaliados.

A delimitação das parcelas foi realizada a partir da identificação visual das linhas de plantio no ortomosaico. Adotou-se o canto inferior direito como ponto inicial da parcela, e a partir dele, a parcela foi delimitada seguindo a orientação das linhas de plantio e o respectivo número de árvores presentes em cada linha. Esse procedimento foi adotado em função da ausência de dados georreferenciados das parcelas.

4.2.2 Estoque de biomassa e carbono acima do solo

Para a quantificação da biomassa acima do solo utilizou-se os dados da amostragem destrutiva de 150 árvores (seis árvores por genótipo), localizadas somente no primeiro bloco de análise (Bloco 2), conforme descrito no capítulo anterior.

O modelo de Schumacher-Hall com a inclusão dos genótipos como variáveis *dummy*, foi aplicado para a estimativa da biomassa acima do solo por compartimento (Equações 10, 11 e 12), utilizando a altura e o diâmetro derivado dos dados UAV-LiDAR. Para a altura, adotou-se a métrica zq95, ou percentil da altura a 95%, derivada dos dados UAV-LIDAR que representa a altura na qual 95% dos retornos estão abaixo. Tal métrica foi escolhida por ser menos influenciada pelos retornos mais altos e por apresentar maior proximidade com a altura total. A partir do percentil da altura a 95%, o diâmetro foi obtido pelo modelo linear (Equação 13) com a padronização do diâmetro e da altura obtidos pelo censo florestal executado em maio de 2023, com R² ajustado de 0,775.

$$\ln(w) = \beta_0 + \beta_1 * \ln(y_D) + \beta_2 * \ln(H_P95) + \text{genótipo} \quad (10)$$

$$\ln(wf) = \beta_0 + \beta_1 * \ln(y_D) + \beta_2 * \ln(H_P95) + \text{genótipo} \quad (11)$$

$$\ln(wc) = \beta_0 + \beta_1 * \ln(y_D) + \beta_2 * \ln(H_P95) + \text{genótipo} \quad (12)$$

$$y_D = 0,8805 * H_P95 \quad (13)$$

Em que: w: biomassa acima do solo (kg.árv⁻¹); wf: biomassa de fuste (kg.árv⁻¹); wc: biomassa de copa (kg.árv⁻¹); β_n : coeficientes do modelo; D: diâmetro à 1,30 do solo (cm); H_P95: percentil de altura a 95% (m); ln: logaritmo natural; genótipo: genótipo; y_D: diâmetro estimado (cm); 0,8805: coeficiente do modelo linear.

Para a obtenção do estoque de carbono acima do solo por compartimento, a biomassa acima do solo por compartimento foi multiplicada pelo teor de carbono médio de 46% (considerado para todos os compartimentos), derivado da pesquisa de Silva *et al.* (2015) em *Eucalyptus* spp. aos 4,7 anos de idade. É válido ressaltar que esse o teor de carbono foi adotado por ser de *Eucalyptus* spp. com idade próxima dos genótipos avaliados nesse estudo. O somatório do carbono de todos os compartimentos resultou no carbono acima do solo por árvore (kg.árv⁻¹).

4.2.3 UAV-LiDAR

A varredura UAV-LiDAR ocorreu em maio de 2023, com um VANT modelo *Matrice* DJI 300 e um sensor *Zenmuse* L1 (DJI, 2023). O voo teve uma altitude de 80 m, velocidade de 9 m.s⁻¹ e largura da faixa de cobertura de 450 m, com densidade média de pontos de 389 pontos.m⁻².

O processamento da nuvem de pontos foi realizado no *software* R, versão 4.2.0. (R CORE TEAM, 2025) com a biblioteca *lidR* (ROUSSEL *et al.*, 2020). Após a avaliação da conformidade e da estatística descritiva da nuvem de pontos, executou-se a classificação dos retornos em solo (*ground*) e não solo (*no ground*), com o filtro *Cloth Simulation Filter* (CSF). A partir dos retornos classificados como solo, o DTM foi gerado com o algoritmo kNN (*k-Nearest Neighbor*) com IDW (*Inverse Distance Weighting*) (MOHAN *et al.*, 2021) por equilibrar qualidade e tempo de processamento. Em seguida, o DSM foi derivado pelo algoritmo *p2r* (*point to raster*). Posteriormente, a normalização da nuvem de pontos foi executada com a função *normalize_height* (ROUSSEL *et al.*, 2020), e o CHM foi gerado pelo algoritmo *p2r*

(MOHAN *et al.*, 2021; ROUSSEL *et al.*, 2020). Os modelos digitais (DTM, DSM e CHM) foram extraídos com 50 cm.

Após o processamento, o CHM e a nuvem de pontos normalizada foram extraídos para cada parcela dos blocos avaliados para a posterior aplicação dos algoritmos de ITD.

4.2.4 Detecção manual

As copas dos genótipos de *Eucalyptus* spp. foram delineadas por interpretação visual no ortomosaico derivado do levantamento UAV-LiDAR, com resolução espacial de 14 cm. O ortomosaico foi utilizado por facilitar a inclusão de critérios de interpretação visual, como o formato e a coloração das copas, além da separação das áreas de vegetação e locais com solo exposto (FIGURA 14).

FIGURA 14 – COPAS DOS GENÓTIPOS DE *Eucalyptus* spp. EM ITATINGA, SÃO PAULO, BRASIL



FONTE: A autora (2026).

Diante da ausência de dados georreferenciados, adotou-se a metodologia baseada no espaço físico para a numeração e classificação das copas delineadas por interpretação visual. Para isso, o espaço teórico ocupado por cada árvore foi reconstruído dentro da parcela, considerando o espaçamento do plantio (3 m x 2 m).

Em seguida, as copas foram numeradas de 1 a 100 considerando o lado inferior direito como o início da parcela e alternando a orientação (da direita para a esquerda e da esquerda para a direita) entre as linhas da parcela.

Uma vez numeradas, as copas foram classificadas de acordo com o censo florestal em três classes:

- i) Árvores: mensuradas no censo e com altura maior do que 5 metros;
- ii) Falhas: copas classificadas como falha no censo florestal;
- iii) Altura menor que 5 metros ($h < 5$): árvores com altura menor que 5 metros de acordo com as medições de campo e o ajuste hipsométrico de Trorey.

Em função da ausência do georreferenciamento dos dados e da consequente dificuldade de correspondência exata da posição da árvore na imagem com a de campo, foram consideradas somente as copas classificadas como árvores e com altura inferior a 5 m para a modelagem da biomassa e do carbono acima do solo por compartimento em *Eucalyptus* spp.

4.2.5 Detecção automática

4.2.5.1 *Local Maximum Filter* (LMF)

O algoritmo *Local Maximum Filter* (LMF) foi testado no CHM suavizado pelo filtro gaussiano e pelo filtro da média. Tais filtros foram utilizados pela capacidade de redução de picos falsos dentro de um mesmo objeto, nesse caso, as copas. A suavização do CHM foi realizada com funções disponíveis nas bibliotecas *lidR* e *rLIDAR* (ROUSSEL *et al.*, 2020; SILVA *et al.*, 2019) para a eliminação de pontos espúrios que podem interferir na qualidade da detecção.

Além disso, foram considerados três diferentes tamanhos de janela, definidos pelo tamanho e formato das copas dos genótipos, sendo de (1 x 1 *pixels*, 1,5 x 1,5 *pixels* e 2 x 2 *pixels*) e o CHM com a resolução espacial de 50cm. A delimitação das copas foi realizada com a função *locate_trees* do pacote *lidR* (ROUSSEL *et al.*, 2020). Para a implementação do LMF, 70% dos dados foram utilizados para o treinamento do algoritmo e 30% dos dados foram utilizados na etapa de validação.

4.2.5.2 *Segment Anything Model (SAM)*

Para a aplicação do SAM, foi utilizado o modelo ViT-H (sam_vit_h_4b8939), por ser o mais avançado e complexo disponível atualmente (OSCO *et al.*, 2023). Para a implementação desse método, foram utilizadas as imagens aéreas extraídas para cada parcela dos genótipos e a delimitação manual das copas. A primeira etapa consistiu na separação dos dados em dois conjuntos: treinamento (70% dos dados) e validação (30% dos dados).

Para a segmentação das imagens e a criação das máscaras foi utilizada a segmentação semântica, na qual cada *pixel* em uma imagem é atribuído a uma classe específica, agrupando efetivamente regiões da imagem com base no interesse semântico (ADAM *et al.*, 2023). Ainda nessa etapa, caixas delimitadoras ou “*boundary_boxes*” (caixas retangulares que destacam áreas específicas dentro das imagens) foram fornecidas para restringir a segmentação do SAM por objeto, assim como em Osco *et al.* (2023).

Para essa abordagem, foi utilizada a instância SamGeo, a qual realiza uma segmentação na imagem inteira e armazena o resultado em um arquivo *raster* que representa as máscaras de segmentação. Cada máscara delimita o primeiro plano da imagem, sendo que cada máscara distinta está alocada a um valor exclusivo. Dessa forma, o resultado é uma imagem segmentada não classificada que também pode ser convertida em forma vetorial. Esse procedimento seguiu as instruções contidas em Osco *et al.* (2023).

O processamento iniciou com a instância do preditor. Na primeira etapa, a imagem foi segmentada e passada pelo preditor juntamente com um ponto de verificação do modelo utilizado, nesse caso, o ViT-H SAM. Na sequência, o preditor realizou o processamento de cada caixa delimitadora, criando as máscaras para as regiões segmentadas, permitindo que essas caixas fossem analisadas como máscaras de segmentação de instância.


Por fim, as máscaras binárias foram mescladas e salvas em uma única imagem. Feito isso, aplicou-se uma etapa de pós processamento por meio da operação morfológica *erode*, que além de reduzir o tamanho das copas detectadas também refina o formato dos objetos. Esse resultado foi recortado para cada uma das parcelas analisadas e exportadas em formato matricial e vetorial no mesmo sistema de referência das parcelas.

script personalizado em linguagem *Python*, utilizando a biblioteca *OpenCV* para a extração de contornos das máscaras binárias com os limites dos objetos.

Em seguida, os contornos foram transformados em anotações, com as caixas delimitadoras, área e informações de segmentação. Cada anotação é associada a um ID de imagem, ID de categoria e outras propriedades exigidas pelo formato COCO. Os detalhes de cada anotação (ID de imagem, altura, largura, nome do arquivo, ID de categoria e coordenadas de caixa delimitadora) foram extraídos das imagens individuais e seus arquivos de rótulo e compilados em um único arquivo JSON (RAKSHITHA *et al.*, 2024).

O treinamento do modelo envolveu o ajuste dos arquivos de configuração para alinhamento e segmentação dos *pixels*. A etapa de treinamento utilizou o número de classes como 1, tamanho de lote de 2, uma taxa de aprendizado base de 0,00025 e com 1000 épocas de treinamento. Após o treinamento do modelo, os dados foram submetidos ao *erode*, para refinar a borda das copas dos genótipos. A avaliação da acurácia da detecção gerada pelo *Detectron2*, assim como os demais métodos de detecção será abordada no próximo item.

FIGURA 16 – IMPLEMENTAÇÃO DO DETECTRON2 PARA A DETECÇÃO DE COPAS DOS GENÓTIPOS DE *Eucalyptus* spp.



FONTE: A autora (2026).

4.2.5.4 Acurácia de detecção

Para avaliar a acurácia da detecção dos métodos tradicionais e avançados, foram computadas as estatísticas descritas na TABELA 15. Quanto maior o valor do F1-score e do *Intersect over Union* (IoU), melhor a qualidade da detecção dos objetos, conforme Sparks *et al.* (2022) e Osco *et al.* (2023).

TABELA 15 – MEDIDAS DE ACURÁCIA PARA A VALIDAÇÃO DA DETECÇÃO DE COPAS DE *Eucalyptus* spp.

Parâmetro	Descrição	Equação
r	Denota a fração dos verdadeiros positivos entre todas as instâncias reais	$r = \frac{VP}{(VP + FN)}$
p	Denota a fração dos verdadeiros positivos considerando os falsos positivos	$p = \frac{VP}{(VP + FP)}$
F1-score	Medida de precisão que determina a média harmônica de recall e a precisão da detecção	$F1\text{-score} = \frac{2 * r * p}{(r + p)}$
IoU	Área de sobreposição dividida pela área da união da segmentação prevista	$IoU = \frac{VP}{FP + VP + FN}$

FONTE: Osco *et al.* (2023) e Sparks *et al.* (2022).

LEGENDA: r: *recall*; p: *precision*; F1-score: F1-score; IoU: *Intersection over Union*; VP: verdadeiros positivos; FN: falsos negativos; FP: falsos positivos.

4.2.6 Modelagem individual de biomassa e carbono acima do solo

Para a modelagem individual da biomassa e do carbono acima do solo dos genótipos de *Eucalyptus* spp., foram consideradas apenas as copas identificadas como árvores e com altura inferior a 5 m na vetorização manual. A partir desses dados, foram selecionadas somente as árvores cuja diferença de altura entre o percentil da altura a 95% (derivado dos dados UAV-LiDAR) e a altura do censo florestal foi inferior a 5 m, para evitar a presença de *outliers*. Por fim, as copas com métricas UAV-LiDAR que apresentaram *outliers* (valores acima de 40 m, abaixo de 1 m e valores negativos ou nulos) foram excluídas.

Após a formação do banco de dados para a modelagem individual, as 36 métricas UAV-LIDAR foram submetidas a uma PCA, selecionando os componentes responsáveis por 80% da variação dos dados, iniciando pela remoção de valores discrepantes ou iguais a zero. Na sequência, a PCA e a análise de correlação foram aplicadas nas métricas restantes para identificação de padrões de multicolinearidade

nas métricas. Após a remoção dessas métricas, aplicou-se, novamente, a PCA para seleção das métricas com o maior peso dentro das componentes principais.

Após a indicação das métricas candidatas a construção dos modelos, o conjunto de dados foi dividido 70% para o treinamento e 30% para a validação dos modelos. Para a divisão dos dados, utilizou-se o pacote *caret* (KUHN, 2008) no *software* R, versão 4.2.0 (R CORE TEAM, 2025).

Para a construção do modelo a partir da regressão linear múltipla, as métricas UAV-LiDAR foram selecionadas pela técnica *Stepwise*, com a adição e/ou remoção de variáveis (ABRAHAM *et al.*, 2017), pelo método “*lmStepAIC*” no pacote *caret* (KUHN, 2008) no *software* R (R CORE TEAM, 2025). Como critério de escolha do modelo mais assertivo, foram consideradas as estatísticas tradicionais de ajuste (R^2_{ajustado} , S_{yx} absoluto e percentual e RMSE absoluto e percentual).

Para a aplicação dos algoritmos não paramétricos, foram testadas combinações dos hiper parâmetros ilustrados na TABELA 16, a partir da função *expand.grid* do pacote *caret* (KUHN, 2008) e com a inclusão da função *early stopping* do pacote *XGBoost* (CHEN *et al.*, 2024) para impedir *overfitting* no *XGBoost*. Os demais algoritmos foram treinados com as funções *expand.grid* do pacote *caret* (KUHN, 2008) e pelos métodos *nnet* (pacote *nnet*) (VENABLES; RIPLEY, 2002), *knn rf*, *svmLinear* *xgbTree*, do pacote *caret* (KUHN, 2008). O ajuste dos modelos e da otimização dos parâmetros descritos anteriormente foram executadas no *software* R (R CORE TEAM, 2025).

TABELA 16 – GRADE DE HIPER PARÂMETROS TESTADOS NOS ALGORITMOS DE *MACHINE LEARNING* PARA A PREDIÇÃO DA BIOMASSA E DO CARBONO ACIMA DO SOLO INDIVIDUAL DE GENÓTIPOS DE *Eucalyptus* spp. EM SÃO PAULO, BRASIL.

Algoritmo	Parâmetro	Variação	Descrição
ANN	<i>size</i>	1 a 10	Número de neurônios na camada oculta
ANN	<i>decay</i>	0,1 a 1	Termo de regularização
kNN	<i>k</i>	10, 12 e 14	Número de vizinhos
kNN	distância	-	Euclidiana
RF	<i>mtry</i>	2	Número de variáveis preditoras selecionadas aleatoriamente
RF	<i>ntree</i>	300	Número de árvores utilizadas no modelo
SVR	<i>sigma</i>	0,05 a 0,1	Parâmetro da função de kernel radial
SVR	<i>C</i>	5, 7 e 10	Parâmetro de regularização
XGBoost	<i>nrounds</i>	100	Número de árvores utilizadas no modelo
XGBoost	<i>max_depth</i>	2 a 4	Profundidade máxima das árvores
XGBoost	<i>eta</i>	0,005 a 0,2	Taxa de aprendizado (learning rate)
XGBoost	<i>gamma</i>	0,01 a 0,05	Penalidade para divisão dos nós
XGBoost	<i>colsample_bytree</i>	0,3 a 0,5	Percentual de colunas amostradas por árvore
XGBoost	<i>min_child_weight</i>	3 a 7	Nº mínimo de amostras para divisão dos nós
XGBoost	<i>Subsample</i>	0,5 a 0,7	Percentual de dados usados em cada árvore

FONTE: A autora (2026).


LEGENDA: ANN: *Artificial Neural Network*; kNN: *k-Nearest Neighbor*; Rf: *Random Forest*; SVR: *Support Vector Regression*; XGBoost: *Extreme Gradient Boosting*.

Para a validação do melhor modelo para a estimativa da biomassa e do carbono acima do solo dos genótipos de *Eucalyptus* spp. foram consideradas as medidas de concordância (Coeficiente de Concordância, medida de concordância, Coeficiente de Correlação de Concordância Melhorado e parâmetro de concordância) e o gráfico de Bland-Altman (BLAND; ALTMAN, 1986), elaborado no *software* R (R CORE TEAM, 2025), com o pacote *blandr* (DATTA, 2017).

A predição da biomassa acima do solo individual (kg.árv^{-1}) e do carbono acima do solo individual (kg.árv^{-1}) foram convertidas para hectare (t.ha^{-1}) considerando o número de indivíduos detectados via imagem para cada um dos métodos testados. Em seguida, as estimativas de biomassa e carbono acima do solo a nível individual foram comparadas com o censo florestal por meio do teste de Shapiro-Wilk para verificação da normalidade e pelos testes T pareado (presença de normalidade) e pelo teste de Wilcoxon (ausência de normalidade). Todos os testes estatísticos foram executados no *software* R, com 95% de confiança.

Por fim, a FIGURA 17 contém o fluxograma das atividades executadas para a detecção de indivíduos de *Eucalyptus* spp. nos blocos experimentais e a posterior modelagem individual de biomassa e do carbono acima do solo a nível individual.

FIGURA 17 – DETECÇÃO E MODELAGEM INDIVIDUAL DE BIOMASSA E CARBONO ACIMA DO SOLO DE *Eucalyptus* spp.



FONTE: A autora (2026).

4.3 RESULTADOS

4.3.1 Detecção manual

A partir do ortomosaico oriundo do voo UAV-LiDAR, foram identificados 7.613 indivíduos de *Eucalyptus* spp. de forma manual (TABELA 17). O bloco com o maior percentual de identificação foi o 7, com 23% e em seguida, os blocos 4 e 8, com 22% e 21%, respectivamente. O bloco 2 teve um percentual de identificação de 19% e o bloco 10 teve o menor montante de copas identificadas, com 15% (por não incluir o genótipo 23). Nota-se que a taxa final de detecção foi de 69%, evidenciando que aproximadamente 3.427 árvores inventariadas em campo, ou seja, 461 árv.ha⁻¹, não foram identificadas no ortomosaico.

TABELA 17 – DETECÇÃO MANUAL DE COPAS DE *Eucalyptus* spp. EM SÃO PAULO, BRASIL


Bloco	Censo em campo			Imagem (ortomosaico)			Diferença		TD (%)
	N° árv	N° árv (%)	N.ha ⁻¹	N° árv	N° árv (%)	N.ha ⁻¹	N° árv	N/ha	
2	2.105	19%	1.403	1.443	19%	962	662	441	69%
4	2.230	20%	1.487	1.641	22%	1.094	589	393	74%
7	2.312	21%	1.541	1.720	23%	1.147	592	395	74%
8	2.319	21%	1.546	1.631	21%	1.087	688	459	70%
10	2.074	19%	1.440	1.178	15%	818	896	622	57%
Total	11.040	100%	1.484	7.613	100%	1.023	3.427	461	69%

FONTE: A autora (2026).

LEGENDA: N° árv: número de árvores; N.ha: número de árvores por hectare; TD: taxa de detecção (%).

Ao considerar a influência dos genótipos na detecção (FIGURA 18), foi possível perceber três grupos de genótipos de acordo com a taxa de detecção: i) acima de 4,5%, ii) entre 4,5 a 3,5% e iii) menor que 3,5%. Na classe I, destacam-se os genótipos 8, 16, 10, 18, 7, 9 e 20. A classe II concentra o maior número de genótipos, sendo eles: 12, 4, 14, 3, 5, 13, 15, 17, 11, 6, 22 e 1. A classe III, por sua vez, é formada pelos genótipos 2, 21, 19, 24, 25 e 23, evidenciando a menor detecção nesse genótipo, por apresentar plantios em apenas quatro dos cinco blocos avaliados.


FIGURA 18 – REPRESENTATIVIDADE DOS GENÓTIPOS DE *Eucalyptus* spp. NA DETECÇÃO MANUAL DAS COPAS



FONTE: A autora (2026).

Na FIGURA 19 é possível analisar a distribuição, estrutura e formato das copas de um exemplo de genótipo para cada uma das classes de detecção. O genótipo 8 ilustra a primeira classe, evidenciando que as copas estão bem distribuídas e de fácil visualização. Para exemplificar a segunda classe de detecção, têm-se o genótipo 12, com indivíduos com copas semelhantes, porém, com menor adensamento quando comparado com o genótipo 8. O genótipo 25 exemplifica o menor percentual de identificação, em função da distribuição e irregularidade das copas, influência de sombra e alto grau de mortalidade destacando o solo exposto nesses locais.

FIGURA 19 – DELIMITAÇÃO MANUAL DE COPAS DOS GENÓTIPOS 8 (A), 14 (B) E 25 (C) DE *Eucalyptus* spp. EM ITATINGA, SÃO PAULO, BRASIL



FONTE: A autora (2026).

4.3.2 Detecção automática

4.3.2.1 *Local Maximum Filter* (LMF)

O desempenho do algoritmo LMF foi similar tanto no conjunto de treinamento quanto no de validação, cuja acurácia da detecção aumentou com o tamanho de janela, independentemente do tipo de suavização aplicado (TABELA 18). Nos dados utilizados no treinamento aplicados no CHM suavizado com o filtro gaussiano, nota-se que a precisão apresentou valores próximos ou iguais a 1, resultando em métricas de acurácia superiores a 0,95 (F1-score e IoU), especialmente nos blocos 8 e 10. Com o filtro da média, por sua vez, pode-se perceber os valores ligeiramente inferiores de recall e IoU nas menores janelas de busca, evidenciando a sensibilidade do algoritmo com o tamanho da janela. De maneira geral, os resultados reforçam que o filtro gaussiano apresentou o melhor delineamento espacial das copas de *Eucalyptus* spp. quando comparado com o filtro da média.

TABELA 18 – ACURÁCIA DA DETECÇÃO INDIVIDUAL DE *Eucalyptus* spp. COM LMF NOS CONJUNTOS DE TREINAMENTO E VALIDAÇÃO

Bloco	WS	Treinamento							
		Gaussiano				Média			
		r	p	F1-score	IoU	r	p	F1-score	IoU
2	1	0,691	0,907	0,770	0,648	0,662	0,802	0,714	0,573
4	1	0,733	0,907	0,801	0,681	0,751	0,912	0,810	0,695
7	1	0,755	0,911	0,811	0,702	0,739	0,885	0,792	0,671
8	1	1,000	0,845	0,913	0,845	0,791	0,855	0,817	0,704
10	1	1,000	0,740	0,844	0,740	1,000	0,860	0,921	0,860
2	1,5	0,720	0,970	0,815	0,714	0,696	0,927	0,787	0,671
4	1,5	0,761	1,000	0,855	0,761	0,778	0,988	0,860	0,771
7	1,5	0,786	0,982	0,860	0,774	0,774	0,968	0,848	0,753
8	1,5	1,000	0,984	0,991	0,984	0,841	0,960	0,892	0,815
10	1,5	1,000	0,982	0,990	0,982	1,000	0,947	0,972	0,947
2	2	0,724	0,984	0,820	0,720	0,703	0,939	0,794	0,682
4	2	0,766	1,000	0,857	0,766	0,785	0,997	0,869	0,784
7	2	0,788	0,982	0,862	0,776	0,786	0,969	0,856	0,766
8	2	1,000	0,989	0,994	0,989	0,850	0,968	0,901	0,829
10	2	1,000	0,982	0,990	0,982	1,000	0,961	0,980	0,961
Bloco	WS	Validação							
		Gaussiano				Média			
		r	p	F1-score	IoU	r	p	F1-score	IoU
2	1	0,677	0,837	0,732	0,605	0,605	0,772	0,667	0,520
4	1	0,774	0,901	0,819	0,708	0,735	0,868	0,785	0,668
7	1	0,861	0,848	0,851	0,745	0,779	0,861	0,814	0,690
8	1	1,000	0,791	0,879	0,791	0,603	0,811	0,671	0,515
10	1	1,000	0,745	0,849	0,745	1,000	0,749	0,849	0,749
2	1,5	0,705	0,937	0,792	0,697	0,663	0,915	0,757	0,636


4	1,5	0,814	1,000	0,887	0,814	0,774	0,970	0,853	0,761
7	1,5	0,900	0,992	0,943	0,894	0,820	0,959	0,883	0,792
8	1,5	1,000	0,985	0,992	0,985	0,662	0,985	0,777	0,654
10	1,5	1,000	0,981	0,990	0,981	1,000	0,919	0,956	0,919
2	2	0,708	0,981	0,799	0,701	0,661	0,921	0,759	0,636
4	2	0,817	1,000	0,890	0,817	0,785	0,974	0,861	0,774
7	2	0,914	1,000	0,955	0,914	0,831	0,965	0,891	0,806
8	2	1,000	0,992	0,996	0,992	0,662	0,986	0,776	0,658
10	2	1,000	0,981	0,990	0,981	1,000	0,936	0,965	0,936

FONTE: A autora (2026).

LEGENDA: WS: *Window size* ou tamanho de janela; r: *recall*; p: *precision*; F1-score: F1-score; IoU: *Intersect over Union*.

Os resultados também variaram de acordo com os tamanhos de janela testados (TABELA 18). Nos menores raios de busca (1 x 1 *pixels* e 1,5 x 1,5 *pixels*), o número de árvores falsamente detectadas foi maior. Ao aumentar o tamanho de janela (2 x 2 *pixels*), houve maior omissão na detecção, reduzindo o número de árvores identificadas, assim como o número de falsos positivos. De forma comparativa, a FIGURA 20 ilustra as diferenças na detecção gerada pelo algoritmo LMF com o filtro de suavização gaussiano nas janelas de busca testadas em um genótipo adensado (16) e um genótipo com grande presença de falhas (25).

FIGURA 20 – DETECÇÃO DE COPAS COM LMF NOS GENÓTIPOS 16 (A) E 25 (B) DE *Eucalyptus* spp. NO BLOCO 2



FONTE: A autora (2026).

Nota-se na FIGURA 20 que o genótipo 16 apresentou muitos verdadeiros positivos, copas identificadas incorretamente e árvores omitidas. O genótipo 25, que apresenta menor adensamento, apresentou muitas árvores detectadas incorretamente e um maior número de árvores omitidas. Isso está diretamente relacionado com a qualidade dos dados de entrada e com o grande número de falhas desse genótipo, que não se adaptou as condições da área experimental.

O comportamento de detecção evidenciado na FIGURA 20 demonstra que o filtro de suavização gaussiano com o raio de busca intermediário (1,5 x 1,5 *pixels*) resultou na melhor taxa de detecção dos genótipos de *Eucalyptus* spp., identificando 4.148 copas (TABELA 19), ou 54% das copas delineadas por interpretação visual.

TABELA 19 – TAXA DE DETECÇÃO DE COPAS DE GENÓTIPOS DE *Eucalyptus* spp. COM LMF

Gen	Bloco 2		Bloco 4		Bloco 7		Bloco 8		Bloco 10		Total		
	N.ár	TD (%)	N.ár	TD (%)	N.ár	TD (%)	N.ár	TD (%)	N.ár	TD (%)	N.ár	N.ár LMF	N.ár (%)
1	66	48%	52	48%	60	52%	59	56%	43	63%	280	148	53%
2	62	48%	58	48%	54	56%	47	51%	39	97%	260	150	58%
3	64	52%	81	64%	60	72%	61	64%	60	63%	326	205	63%
4	71	39%	72	60%	73	52%	66	24%	53	45%	335	149	44%
5	55	53%	72	50%	75	45%	75	44%	47	70%	324	165	51%
6	50	66%	63	57%	70	46%	61	75%	47	77%	291	183	63%
7	63	46%	68	29%	69	25%	83	37%	64	67%	347	140	40%
8	72	63%	79	58%	87	46%	76	47%	63	59%	377	204	54%
9	76	57%	84	51%	82	51%	71	38%	37	68%	350	180	51%
10	66	18%	79	58%	83	59%	83	42%	49	57%	360	170	47%
11	48	35%	73	58%	66	61%	61	56%	47	87%	295	174	59%
12	62	68%	80	48%	70	50%	70	57%	64	55%	346	190	55%
13	70	47%	70	47%	77	45%	61	41%	43	65%	321	154	48%
14	70	41%	68	26%	72	50%	74	54%	49	55%	333	150	45%
15	58	14%	71	49%	67	63%	75	68%	50	82%	321	177	55%
16	72	50%	79	65%	74	64%	82	29%	58	62%	365	194	53%
17	47	55%	66	56%	80	43%	78	55%	51	76%	322	179	56%
18	74	43%	72	63%	89	56%	66	70%	59	78%	360	219	61%
19	47	40%	51	53%	49	47%	60	43%	30	97%	237	124	52%
20	71	61%	63	44%	77	42%	72	65%	64	75%	347	198	57%
21	28	100%	61	56%	60	60%	60	68%	31	77%	240	163	68%
22	49	71%	56	73%	74	64%	67	64%	45	73%	291	199	68%
23	26	100%	29	90%	55	69%	28	64%	-	-	138	108	78%
24	41	54%	43	58%	63	37%	54	54%	36	58%	237	120	51%
25	35	66%	51	43%	34	38%	41	46%	49	57%	210	105	50%
Total	1.443	51%	1.641	53%	1.720	52%	1.631	52%	1.178	68%	7.613	4.148	54%

FONTE: A autora (2026).

LEGENDA: Gen: genótipo; N° ár: número de copas identificadas na detecção manual; N° ár LMF: número de copas identi-ficadas na detecção automática pelo Local Maxima Filter; TD: taxa de detecção (%).

4.3.2.2 Segment Anything Model (SAM)

A detecção dos genótipos de *Eucalyptus* spp. utilizando o algoritmo SAM alcançou acurácia superior a 65%, tanto no conjunto de treinamento quanto no conjunto de teste (TABELA 20).

TABELA 20 – MEDIDAS DE ACURÁCIA DA DETECÇÃO DE COPAS DE GENÓTIPOS DE *Eucalyptus* spp. COM SAM

Bloco	Treinamento				Validação			
	r	p	F1-score	IoU	r	p	F1-score	IoU
2	0,797	0,857	0,825	0,704	0,815	0,817	0,813	0,687
4	0,776	0,842	0,806	0,677	0,797	0,816	0,805	0,676
7	0,782	0,851	0,813	0,687	0,837	0,844	0,839	0,723
8	0,787	0,855	0,816	0,693	0,730	0,820	0,769	0,633
10	0,795	0,815	0,803	0,675	0,858	0,805	0,830	0,712


FONTE: A autora (2026).

LEGENDA: r: *recall*; p: *precision*; F1-score: F1-score; IoU: *Intersect over Union*.

Ao comparar os conjuntos de treinamento e de validação na época selecionada, observa-se que o desempenho do modelo SAM foi consistente entre ambos, com resultados semelhantes em ambas as bases (TABELA 20). A performance do SAM também variou entre os blocos analisados. No conjunto de treinamento, o bloco 2 foi sobressalente aos demais, seguido pelos blocos 8 e 7, com resultados semelhantes. O bloco 10 apresentou os menores valores de F1-score e IoU. Nos dados de validação, o desempenho do algoritmo apresentou outro comportamento, com a superioridade do bloco 7, seguido pelos blocos 10, 2 e 4. O desempenho no bloco 8 foi inferior aos demais, com F1-score abaixo de 0,80 e IoU abaixo de 0,65.

Para fins ilustrativos, a FIGURA 21 contém a detecção das copas de três genótipos de *Eucalyptus* spp. em diferentes condições de adensamento nos blocos avaliados pela aplicação do modelo SAM.

FIGURA 21 – COPAS DE GENÓTIPOS DE *Eucalyptus* spp. IDENTIFICADAS COM SAM: A) GENÓTIPO 16; B) GENÓTIPO 25 NOS BLOCOS EXPERIMENTAIS



FONTE: A autora (2026).

No primeiro genótipo, é possível perceber um padrão de copas homogêneas, com delimitações regulares e com boa separação espacial entre os indivíduos. O genótipo 12, apresenta variabilidade no tamanho das copas com copas pequenas concentradas nos blocos 2 e 4 e copas grandes, principalmente nos blocos 7 e 10. Já o genótipo 25, apresenta copas visualmente maiores e próximas umas das outras, dificultando sua delimitação individual. Esse genótipo também apresentou a maior quantidade de falhas e mortalidade, evidenciando a dificuldade de adaptação dessa espécie.

O emprego do algoritmo SAM detectou 6.816 indivíduos de *Eucalyptus* spp. (TABELA 21). É possível observar que o número de árvores variou entre blocos e entre genótipos, refletindo as diferenças no desenvolvimento das parcelas analisadas. Os genótipos 13 e 7 destacaram-se por apresentar médias de detecção acima de 96%, seguido pelo genótipo 3 com 94% e pelos genótipos 4, 6, 14, 16 e 20 com 93%. Em contrapartida, têm-se os genótipos 17 e 23 com a menor taxa de detecção (68% e 79%) em decorrência do menor número de indivíduos do genótipo 23 em campo e pela dificuldade na separação das copas do genótipo 17.

TABELA 21 – DETECÇÃO DE COPAS DE GENÓTIPOS DE *Eucalyptus* spp. COM SAM

Gen	Bloco 2		Bloco 4		Bloco 7		Bloco 8		Bloco 10		Total		
	N.º árv	TD (%)	N.º árv	TD (%)	N.º árv	TD (%)	N.º árv	TD (%)	N.º árv	TD (%)	N.º árv	N.º árv SAM	N.º árv (%)
1	66	86%	52	90%	60	100%	59	92%	43	93%	280	258	92%
2	62	94%	58	88%	54	91%	47	91%	39	82%	260	233	90%
3	64	92%	81	98%	60	95%	61	90%	60	97%	326	308	94%
4	71	92%	72	97%	73	96%	66	86%	53	96%	335	313	93%
5	55	93%	72	86%	75	95%	75	89%	47	74%	324	286	88%
6	50	98%	63	84%	70	93%	61	93%	47	98%	291	270	93%
7	63	98%	68	94%	69	91%	83	98%	64	98%	347	333	96%
8	72	100%	79	95%	87	83%	76	82%	63	87%	377	336	89%
9	76	99%	84	86%	82	88%	71	83%	37	95%	350	313	89%
10	66	88%	79	89%	83	89%	83	84%	49	94%	360	318	88%
11	48	96%	73	88%	66	73%	61	98%	47	96%	295	263	89%
12	62	95%	80	89%	70	97%	70	96%	64	84%	346	319	92%
13	70	94%	70	100%	77	99%	61	97%	43	100%	321	314	98%
14	70	97%	68	94%	72	90%	74	91%	49	94%	333	310	93%
15	58	95%	71	89%	67	81%	75	89%	50	94%	321	286	89%
16	72	93%	79	95%	74	95%	82	93%	58	88%	365	339	93%
17	47	89%	66	61%	80	65%	78	64%	51	69%	322	219	68%
18	74	95%	72	93%	89	76%	66	88%	59	88%	360	315	88%
19	47	91%	51	92%	49	86%	60	95%	30	87%	237	215	91%
20	71	94%	63	90%	77	92%	72	94%	64	91%	347	321	93%
21	28	82%	61	66%	60	83%	60	95%	31	90%	240	198	83%
22	49	86%	56	91%	74	89%	67	93%	45	91%	291	262	90%
23	26	77%	29	86%	55	80%	28	71%	-	-	138	109	79%
24	41	90%	43	100%	63	68%	54	91%	36	89%	237	204	86%
25	35	100%	51	88%	34	85%	41	73%	49	71%	210	174	83%
Total	1.443	93%	1.641	89%	1.720	87%	1.631	89%	1.178	89%	7.613	6.816	90%

FONTE: A autora (2026).

LEGENDA: Gen: genótipo; N.º árv: número de copas identificadas na detecção manual; N.º árv SAM: número de copas identificadas na detecção automática pelo Segment Anything Model; TD: taxa de detecção (%).

4.3.2.3 Detectron2

A implementação do algoritmo Detectron2 para a detecção de copas de *Eucalyptus* spp. apresentou F1-score e IoU superiores a 0,82 nos dois conjuntos analisados (TABELA 22) destacando elevada acurácia e robustez desse algoritmo. No conjunto de treinamento, o bloco 8 apresentou a maior acurácia na detecção, com F1-score de 0,971 e IoU de 0,947. Na base de validação, os resultados foram semelhantes, com valores elevados de precisão e recall, refletindo a elevada concordância espacial entre as copas detectadas pelo método com os dados de entrada.

TABELA 22 – MEDIDAS DE ACURÁCIA DA DETECÇÃO DE COPAS DE GENÓTIPOS DE *Eucalyptus* spp. COM DETECTRON2


Bloco	Treinamento				Validação			
	r	p	F1-score	IoU	r	p	F1-score	IoU
2	0,847	0,974	0,901	0,823	0,846	0,974	0,902	0,824
4	0,883	0,982	0,928	0,867	0,912	0,969	0,937	0,880
7	0,938	0,995	0,965	0,934	0,976	0,980	0,978	0,955
8	0,947	1,000	0,971	0,947	0,908	1,000	0,950	0,908
10	0,869	0,992	0,925	0,862	0,834	0,988	0,900	0,824
Média	0,897	0,989	0,938	0,887	0,896	0,982	0,934	0,879

FONTE: A autora (2026).

LEGENDA: r: *recall*; p: *precision*; F1-score: F1-score; IoU: *Intersect over Union*.

Para fins de exemplificação, a FIGURA 22 apresenta o resultado da segmentação por instância das copas nos genótipos (16 e 25) de *Eucalyptus* spp. utilizando o algoritmo *Detectron2*. O desempenho foi consistente nos dois genótipos, confirmando o potencial do algoritmo *Detectron2* como uma abordagem eficiente para a detecção automática de copas apesar da variabilidade estrutural entre blocos e genótipos.

FIGURA 22 – DETECÇÃO DE COPAS DOS GENÓTIPOS 16 (A) E 25 (B) DE *Eucalyptus* spp. COM DETECTRON2



FONTE: A autora (2026).

A partir da aplicação desse algoritmo foram detectadas 7.135 copas, ou seja, 94% das copas identificadas na vetorização por interpretação visual (TABELA 23). Ao contrário da detecção manual, cuja maior identificação ocorreu no bloco 4, com o

Detectron2 a maior quantidade de copas detectadas ocorreu no bloco 8 apresentou 1.532 copas, ou 21%. Na sequência, os blocos 7 e 4 se destacam com a segunda maior taxa de detecção (22%), com uma diferença de apenas 38 copas. Já o bloco 2, teve 1.351 copas identificadas (19%). O bloco 10, por sua vez, permaneceu com o menor número de copas detectadas (16%), por não apresentar o genótipo 23. Em média, os genótipos 5, 7 e 13 apresentaram maior eficiência na detecção das copas com taxas de detecção de 100%, considerando todos os blocos avaliados. Por outro lado, os genótipos 25 e 23 apresentaram menor quantidade de copas detectadas, com 84% e 90%, por apresentarem o menor número de indivíduos em campo devido à alta mortalidade.

TABELA 23 – DETECÇÃO DE COPAS DE *Eucalyptus* spp. COM DETECTRON2 NA ÁREA EXPERIMENTAL EM ITATINGA, SÃO PAULO, BRASIL

Gen	Bloco 2		Bloco 4		Bloco 7		Bloco 8		Bloco 10		Total		
	N.º árv	TD (%)	N.º árv	TD (%)	N.º árv	TD (%)	N.º árv	TD (%)	N.º árv	TD (%)	N.º árv	N.º árv Det	N.º árv (%)
1	66	94%	52	94%	60	97%	59	95%	43	93%	280	265	95%
2	62	89%	58	95%	54	96%	47	98%	39	100%	260	247	95%
3	64	86%	81	96%	60	93%	61	98%	60	100%	326	309	95%
4	71	94%	72	94%	73	92%	66	92%	53	98%	335	315	94%
5	55	95%	72	94%	75	97%	75	96%	47	96%	324	310	96%
6	50	84%	63	87%	70	99%	61	90%	47	98%	291	267	92%
7	63	100%	68	96%	69	93%	83	93%	64	100%	347	333	96%
8	72	99%	79	94%	87	77%	76	92%	63	94%	377	341	90%
9	76	89%	84	93%	82	91%	71	96%	37	97%	350	325	93%
10	66	92%	79	94%	83	94%	83	95%	49	94%	360	338	94%
11	48	100%	73	90%	66	94%	61	97%	47	94%	295	279	95%
12	62	94%	80	90%	70	99%	70	97%	64	94%	346	327	95%
13	70	90%	70	100%	77	94%	61	97%	43	100%	321	307	96%
14	70	96%	68	94%	72	89%	74	95%	49	98%	333	313	94%
15	58	93%	71	92%	67	90%	75	99%	50	98%	321	302	94%
16	72	100%	79	96%	74	92%	82	88%	58	100%	365	346	95%
17	47	96%	66	89%	80	94%	78	87%	51	100%	322	298	93%
18	74	96%	72	99%	89	92%	66	91%	59	98%	360	342	95%
19	47	96%	51	88%	49	96%	60	95%	30	97%	237	223	94%
20	71	94%	63	97%	77	99%	72	99%	64	86%	347	330	95%
21	28	100%	61	98%	60	90%	60	90%	31	97%	240	226	94%
22	49	92%	56	96%	74	88%	67	96%	45	93%	291	270	93%
23	26	96%	29	100%	55	82%	28	89%	-	-	138	124	90%
24	41	98%	43	100%	63	84%	54	96%	36	94%	237	222	94%
25	35	77%	51	80%	34	79%	41	85%	49	94%	210	176	84%
Total	1.443	94%	1.641	94%	1.720	92%	1.631	94%	1.178	96%	7.613	7.135	94%

FONTE: A autora (2026).

LEGENDA: Gen: genótipo; N.º árv: número de copas identificadas na detecção manual; N.º árv Det: número de copas identificadas na detecção automática pelo Detectron2; TD: taxa de detecção (%).

4.3.2.4 Comparação dos métodos de detecção automática

As abordagens de detecção testadas tiveram diferentes performances para a detecção de genótipos de *Eucalyptus* spp., quando comparadas com os resultados da vetorização por interpretação visual das copas realizado no ortomosaico (TABELA 24). O algoritmo LMF apresentou a maior diferença, identificando apenas 54% das árvores vetorizadas, ou seja, 4.148 copas. O SAM identificou 6.816 árvores, ou seja, 90% das árvores identificadas na etapa manual. E o *Detectron2*, por sua vez, detectou 94% copas além das copas delimitadas manualmente, ou seja, 7.135 copas de *Eucalyptus* spp.

TABELA 24 – IDENTIFICAÇÃO DE COPAS DE *Eucalyptus* spp. COM DIFERENTES MÉTODOS DE DETECÇÃO

Bloco	Imagem	N° árvores			Diferenças					
		LM	SAM	Detec.	LM		SAM		Detectron2	
					N°árv	%	N°árv	%	N°árv	%
2	1.443	733	1346	1351	710	20%	97	12%	92	19%
4	1.641	877	1465	1540	764	22%	176	22%	101	21%
7	1.720	887	1499	1578	833	24%	221	28%	142	30%
8	1.631	846	1452	1532	785	23%	179	22%	99	21%
10	1.178	805	1054	1134	373	11%	124	16%	44	9%
Total	7.613	4.148	6.816	7.135	3.465	100%	797	100%	478	100%

FONTE: A autora (2026).

LEGENDA: Imagem: copas vetorizadas por fotointerpretação; LM: *Local Maxima Filter*; SAM: *Segment Antyhing Model*; Detec: *Detectron2*.

A análise comparativa apresentada na TABELA 24 indica que o *Detectron2* identificou um número de copas superior ao observado na fotointerpretação manual. Esse comportamento está associado, principalmente, a segmentação de copas maiores em múltiplas copas menores pelo algoritmo, resultando no maior número de copas detectadas. Apesar do seu robusto desempenho, tal resultado evidencia a sensibilidade desse algoritmo as condições estruturais heterogêneas do dossel dos genótipos de *Eucalyptus* spp.

4.3.3 Modelagem individual de biomassa e carbono acima do solo

A seleção das métricas candidatas a construção dos modelos preditivos de biomassa aérea e carbono aéreo por compartimento pela PCA revelou que na primeira rodada de avaliação, 85% da variação dos dados foi encontrada nos dois

primeiros componentes principais. Após a remoção das métricas altamente correlacionadas e a aplicação da PCA, identificou-se que na primeira componente principal, as métricas de menor peso (percentil da altura a 95%, altura média e desvio padrão da altura), foram excluídas, resultando em cinco métricas finais relacionadas ao percentil da altura a 70%, 75%, 80%, 85% e 90%, com estatísticas de ajuste de R^2 de 0,90 e um RMSE (%) de 9,24.

A estimativa da biomassa aérea e do carbono aéreo individual nos diferentes compartimentos de *Eucalyptus* spp. está representado na TABELA 25. Nota-se que, os modelos construídos com regressão linear múltipla tiveram desempenho similar a alguns algoritmos de *Machine Learning*, como XGBoost e RF, com $R^2_{ajustado}$ entre 0,622 a 0,990 e erros abaixo de 12%, com exceção do compartimento copa.

O desempenho dos métodos de aprendizado de máquina foi similar por compartimento testado. De maneira geral, observou-se a tendência de *overfitting* nos modelos gerados com RF, evidenciado pelos altíssimos valores de $R^2_{ajustado}$ (~0,990) e erros inferiores a 6,5% nos compartimentos total e fuste e abaixo de 8,1% para a copa. Em segundo lugar, têm-se o XGBoost, com $R^2_{ajustado}$ de ~0,961 e erros abaixo de 6,2% nos compartimentos total e fuste, além de $R^2_{ajustado}$ de ~0,836 e erro abaixo de 15,2% no compartimento copa. Apesar de permanecerem elevados, os resultados obtidos demonstram maior coerência com o comportamento esperado das relações alométricas diante da variabilidade intrínseca da biomassa aérea e carbono aéreo. Na sequência, destaca-se a performance intermediária das ANN e do kNN, já o SVR apresentou menor capacidade preditiva para os diferentes compartimentos analisados.

TABELA 25 – BIOMASSA ACIMA DO SOLO INDIVIDUAL (kg.árv⁻¹) E CARBONO ACIMA DO SOLO INDIVIDUAL (kg.árv⁻¹) POR COMPARTIMENTO DE *Eucalyptus* spp. ESTIMADOS COM ML E UAV-LIDAR

Algoritmo	Comp.	Ajuste (4.290 árvores)					Validação (1.839 árvores)	
		R^2 ajustado	S_{yx} (kg.árv ⁻¹)	S_{yx} (%)	RMSE (kg.árv ⁻¹)	RMSE (%)	RMSE (kg.árv ⁻¹)	RMSE (%)
STEP	B. total	0,910	8,32	9,36	8,31	9,36	9,19	10,39
ANN	B. total	0,928	7,45	8,39	7,45	8,39	8,06	9,07
kNN	B. total	0,926	7,57	8,52	7,57	8,52	8,10	9,11
RF	B. total	0,988	3,03	3,40	3,02	3,40	7,17	8,07
SVR	B. total	0,908	8,44	9,50	8,44	9,49	9,20	10,41
XGBoost	B. total	0,961	5,48	6,16	5,48	6,16	6,28	7,10
STEP	C. total	0,910	3,83	9,36	3,83	9,36	4,23	10,39
ANN	C. total	0,930	3,40	8,30	3,40	8,30	3,65	8,91
kNN	C. total	0,926	3,49	8,52	3,49	8,52	3,73	9,11


RF	C. total	0,988	1,41	3,43	1,41	3,43	3,30	8,10
SVR	C. total	0,908	3,89	9,50	3,89	9,49	4,24	10,41
XGBoost	C. total	0,961	2,53	6,18	2,53	6,18	2,90	7,08
STEP	B. fuste	0,919	7,12	8,86	7,12	8,86	7,39	9,24
ANN	B. fuste	0,937	6,29	7,83	6,29	7,83	6,35	7,91
kNN	B. fuste	0,936	6,34	7,89	6,33	7,88	6,46	8,05
RF	B. fuste	0,990	2,56	3,19	2,56	3,19	5,71	7,11
SVR	B. fuste	0,916	7,27	9,05	7,27	9,04	7,42	9,28
XGBoost	B. fuste	0,962	4,88	6,07	4,88	6,07	5,16	6,46
STEP	C. fuste	0,919	3,28	8,86	3,28	8,86	3,40	9,24
ANN	C. fuste	0,940	2,81	7,60	2,81	7,60	2,87	7,74
kNN	C. fuste	0,936	2,92	7,89	2,92	7,88	2,98	8,05
RF	C. fuste	0,990	1,18	3,19	1,18	3,19	2,63	7,14
SVR	C. fuste	0,916	3,35	9,05	3,35	9,04	3,42	9,28
XGBoost	C. fuste	0,962	2,24	6,05	2,24	6,05	2,37	6,40
STEP	B. copa	0,638	1,84	22,54	1,84	22,52	1,86	22,89
ANN	B. copa	0,667	1,76	21,59	1,76	21,59	1,81	22,14
kNN	B. copa	0,680	1,73	21,16	1,73	21,16	1,82	22,25
RF	B. copa	0,960	0,66	8,06	0,66	8,06	1,48	18,07
SVR	B. copa	0,621	1,88	23,05	1,88	23,03	1,90	23,36
XGBoost	B. copa	0,837	1,24	15,13	1,24	15,13	1,35	16,55
STEP	C. copa	0,638	0,85	22,54	0,85	22,52	0,86	22,89
ANN	C. copa	0,678	0,80	21,23	0,80	21,23	0,83	21,98
kNN	C. copa	0,680	0,80	21,16	0,80	21,16	0,84	22,25
RF	C. copa	0,960	0,30	8,08	0,30	8,07	0,68	18,24
SVR	C. copa	0,622	0,87	23,05	0,87	23,03	0,88	23,35
XGBoost	C. copa	0,836	0,57	15,18	0,57	15,18	0,62	16,47

FONTE: A autora (2026).


LEGENDA: B.: biomassa; C.: carbono; B. total: biomassa acima do solo; C. total: carbono acima do solo; STEP: *Stepwise*; ANN: *Artificial Neural Networks*; kNN: *k-Nearest Neighbor*; RF: *Random Forest*; SVR: *Support Vector Regression*; XGBoost: *Extreme Gradient Boosting*; R^2 ajustado: Coeficiente de determinação ajustado; S_{yx} : erro padrão da estimativa (kg.árv⁻¹); S_{yx} (%): erro padrão da estimativa percentual (%); RMSE: Raiz do Erro Quadrático Médio (kg.árv⁻¹); RMSE (%): Raiz do Erro Quadrático Médio percentual (%).

A distribuição gráfica dos resíduos dos modelos construídos para a estimativa da biomassa individual em *Eucalyptus* spp. e do carbono individual em *Eucalyptus* spp. (FIGURA 23) revelou a heterocedasticidade dos resíduos nos modelos construídos com *Stepwise* em todos os compartimentos. Nota-se a menor influência da heterocedasticidade nos modelos construídos com técnicas de ML, visto que eles não dependem da variância da variância constante dos resíduos.


FIGURA 23 – MODELOS PREDITIVOS DE BIOMASSA INDIVIDUAL A) ACIMA DO SOLO, B) FUSTE e C) COPA E CARBONO INDIVIDUAL D) ACIMA DO SOLO, E) FUSTE E F) COPA ($\text{kg} \cdot \text{árv}^{-1}$) DE *Eucalyptus* spp.



CONTINUAÇÃO DA FIGURA 23 – MODELOS PREDITIVOS DE BIOMASSA INDIVIDUAL A) ACIMA DO SOLO, B) FUSTE e C) COPA E CARBONO INDIVIDUAL D) ACIMA DO SOLO, E) FUSTE E F) COPA (kg.árv⁻¹) POR COMPARTIMENTO DE *Eucalyptus* spp.



CONTINUAÇÃO DA FIGURA 23 – MODELOS PREDITIVOS DE BIOMASSA INDIVIDUAL A) ACIMA DO SOLO, B) FUSTE e C) COPA E CARBONO INDIVIDUAL D) ACIMA DO SOLO, E) FUSTE E F) COPA (kg.árv⁻¹) POR COMPARTIMENTO DE *Eucalyptus* spp.



FONTE: A autora (2026).

A validação dos modelos preditivos de biomassa aérea e carbono aéreo individual por compartimento pelas medidas de concordância (TABELA 26) revelou que o algoritmo XGBoost resultou no modelo com as maiores medidas de concordância (~ 1) em todos os compartimentos. Ademais, as medidas de concordância desse algoritmo não apresentaram diferenças entre as bases consideradas (total, ajuste e validação).

TABELA 26 – MEDIDAS DE CONCORDÂNCIA DOS MODELOS PREDITIVOS DE BIOMASSA ACIMA DO SOLO ($\text{kg.}\dot{\text{a}}\text{rv}^{-1}$) E DO CARBONO ACIMA DO SOLO ($\text{kg.}\dot{\text{a}}\text{rv}^{-1}$) POR COMPARTIMENTO EM *Eucalyptus* spp. A NÍVEL INDIVIDUAL

Algoritmo	Biomassa acima do solo ($\text{kg.}\dot{\text{a}}\text{rv}^{-1}$)											
	Total				Ajuste				Validação			
	A	P	CC2	λ	A	P	CC2	λ	A	P	CC2	λ
STEP	0,98	0,95	0,95	0,98	0,98	0,95	0,95	0,98	0,97	0,94	0,94	0,97
ANN	0,98	0,96	0,96	0,98	0,98	0,96	0,96	0,98	0,98	0,96	0,95	0,98
kNN	0,98	0,96	0,96	0,98	0,98	0,96	0,96	0,98	0,98	0,95	0,95	0,98
RF	0,99	0,99	0,98	0,99	1,00	0,99	0,99	1,00	0,98	0,96	0,96	0,98
SVR	0,98	0,95	0,95	0,98	0,98	0,96	0,95	0,98	0,97	0,95	0,94	0,97
XGBoost	0,99	0,98	0,98	0,99	0,99	0,98	0,98	0,99	0,99	0,97	0,97	0,99
Algoritmo	Carbono acima do solo ($\text{kg.}\dot{\text{a}}\text{rv}^{-1}$)											
	Total				Ajuste				Validação			
	A	P	CC2	λ	A	P	CC2	λ	A	P	CC2	λ
STEP	0,98	0,95	0,95	0,98	0,98	0,95	0,95	0,98	0,97	0,94	0,94	0,97
ANN	0,98	0,96	0,96	0,98	0,98	0,96	0,96	0,98	0,98	0,96	0,96	0,98
kNN	0,98	0,96	0,96	0,98	0,98	0,96	0,96	0,98	0,98	0,95	0,95	0,98
RF	0,99	0,99	0,98	0,99	1,00	0,99	0,99	1,00	0,98	0,96	0,96	0,98
SVR	0,98	0,95	0,95	0,98	0,98	0,96	0,95	0,98	0,97	0,95	0,94	0,97
XGBoost	0,99	0,98	0,98	0,99	0,99	0,98	0,98	0,99	0,99	0,97	0,97	0,99
Algoritmo	Biomassa de fuste ($\text{kg.}\dot{\text{a}}\text{rv}^{-1}$)											
	Total				Ajuste				Validação			
	A	P	CC2	λ	A	P	CC2	λ	A	P	CC2	λ
STEP	0,98	0,96	0,96	0,98	0,98	0,96	0,96	0,98	0,98	0,96	0,95	0,98
ANN	0,98	0,97	0,97	0,98	0,98	0,97	0,97	0,98	0,98	0,97	0,97	0,98
kNN	0,98	0,97	0,96	0,98	0,98	0,97	0,96	0,98	0,98	0,96	0,96	0,98
RF	0,99	0,99	0,99	0,99	1,00	0,99	0,99	1,00	0,99	0,97	0,97	0,99
SVR	0,98	0,96	0,96	0,98	0,98	0,96	0,96	0,98	0,98	0,96	0,96	0,98
XGBoost	0,99	0,98	0,98	0,99	0,99	0,98	0,98	0,99	0,99	0,98	0,98	0,99
Algoritmo	Carbono de fuste ($\text{kg.}\dot{\text{a}}\text{rv}^{-1}$)											
	Total				Ajuste				Validação			
	A	P	CC2	λ	A	P	CC2	λ	A	P	CC2	λ
STEP	0,98	0,96	0,96	0,98	0,98	0,96	0,96	0,98	0,98	0,96	0,95	0,98
ANN	0,98	0,97	0,97	0,98	0,98	0,97	0,97	0,98	0,98	0,97	0,97	0,98
kNN	0,98	0,97	0,96	0,98	0,98	0,97	0,96	0,98	0,98	0,96	0,96	0,98
RF	0,99	0,99	0,99	0,99	1,00	0,99	0,99	1,00	0,99	0,97	0,97	0,99
SVR	0,98	0,96	0,96	0,98	0,98	0,96	0,96	0,98	0,98	0,96	0,96	0,98
XGBoost	0,99	0,98	0,98	0,99	0,99	0,98	0,98	0,99	0,99	0,98	0,98	0,99
Algoritmo	Biomassa de copa ($\text{kg.}\dot{\text{a}}\text{rv}^{-1}$)											
	Total				Ajuste				Validação			
	A	P	CC2	λ	A	P	CC2	λ	A	P	CC2	λ
STEP	0,89	0,78	0,76	0,87	0,89	0,78	0,76	0,87	0,89	0,77	0,76	0,87
ANN	0,90	0,80	0,79	0,89	0,90	0,80	0,79	0,89	0,90	0,79	0,78	0,88
kNN	0,90	0,80	0,79	0,89	0,90	0,81	0,79	0,89	0,89	0,79	0,77	0,88
RF	0,97	0,94	0,94	0,97	0,99	0,97	0,97	0,99	0,93	0,86	0,85	0,93
SVR	0,89	0,77	0,76	0,87	0,89	0,77	0,76	0,87	0,89	0,77	0,76	0,87
XGBoost	0,95	0,90	0,88	0,95	0,95	0,90	0,89	0,95	0,94	0,88	0,87	0,94
Algoritmo	Carbono de copa ($\text{kg.}\dot{\text{a}}\text{rv}^{-1}$)											
	Total				Ajuste				Validação			
	A	P	CC2	λ	A	P	CC2	λ	A	P	CC2	λ
STEP	0,89	0,78	0,76	0,87	0,89	0,78	0,76	0,87	0,89	0,77	0,76	0,87
ANN	0,90	0,80	0,79	0,89	0,90	0,80	0,79	0,89	0,90	0,79	0,78	0,88
kNN	0,90	0,80	0,79	0,89	0,90	0,81	0,79	0,89	0,89	0,79	0,77	0,88
RF	0,97	0,94	0,94	0,97	0,99	0,97	0,97	0,99	0,93	0,86	0,85	0,93
SVR	0,89	0,77	0,76	0,87	0,89	0,77	0,76	0,87	0,89	0,77	0,76	0,87


XGBoost	0,95	0,90	0,88	0,95	0,95	0,90	0,89	0,95	0,94	0,88	0,87	0,94
---------	------	------	------	------	------	------	------	------	------	------	------	------

FONTE: A autora (2026).


LEGENDA: A: Coeficiente de Concordância; p: Medida de Concordância; CC1: Coeficiente de Correlação de Concordância; CC2: Coeficiente de Correlação de Concordância Melhorado; λ : parâmetro de concordância; STEP: *Stepwise*; ANN: *Artificial Neural Networks*; kNN: *k-Nearest Neighbor*; RF: *Random Forest*; SVR: *Support Vector Regression*; XGBoost: *Extreme Gradient Boosting*.

De acordo com o gráfico de Bland-Altman (FIGURA 24) o algoritmo XGBoost apresentou o melhor desempenho, com maior concentração de pontos dentro dos limites de concordância e menor dispersão das diferenças, indicando precisão e consistência nas estimativas de biomassa acima do solo individual e carbono acima do solo individual por compartimento.


FIGURA 24 – GRÁFICO DE BLAND-ALTMAN PARA A BIOMASSA ACIMA DO SOLO INDIVIDUAL POR COMPARTIMENTO: TOTAL (A), FUSTE (B) E COPA (C) E DO CARBONO ACIMA DO SOLO TOTAL (D), FUSTE (E) E COPA (F) EM *Eucalyptus* spp.



CONTINUAÇÃO DA FIGURA 24 – GRÁFICO DE BLAND-ALTMAN PARA A BIOMASSA ACIMA DO SOLO INDIVIDUAL POR COMPARTIMENTO: TOTAL (A), FUSTE (B) E COPA (C) E DO CARBONO ACIMA DO SOLO TOTAL (D), FUSTE (E) E COPA (F) EM *Eucalyptus* spp.



CONTINUAÇÃO DA FIGURA 24 – GRÁFICO DE BLAND-ALTMAN PARA A BIOMASSA ACIMA DO SOLO INDIVIDUAL POR COMPARTIMENTO: TOTAL (A), FUSTE (B) E COPA (C) E DO CARBONO ACIMA DO SOLO TOTAL (D), FUSTE (E) E COPA (F) EM *Eucalyptus* spp.



FONTE: A autora (2026).

Ao avaliar a estimativa da biomassa acima do solo e do carbono acima do solo a nível individual, a partir do número de árvores detectadas por cada método testado (LMF, SAM e Detectron2) (TABELA 27) nota-se a inferioridade do método LMF, com subestimativas em todos os compartimentos. Dentre os métodos avançados de detecção, as estimativas de biomassa e carbono acima do solo por compartimento foram mais consistentes considerando as copas identificadas pelo

Detectron2, conforme evidenciado pelas medidas de acurácia e pelo maior número de copas detectadas corretamente.

TABELA 27 – COMPARATIVO DA BIOMASSA (t.ha^{-1}) E DO CARBONO ACIMA DO SOLO INDIVIDUAL (t.ha^{-1}) POR COMPARTIMENTO EM *Eucalyptus* spp. PELOS MÉTODOS DE DETECÇÃO

Compartimento	Detecção	Média (t.ha^{-1})						
		Censo	STEP	ANN	kNN	RF	SVR	XGBoost
Biomassa acima do solo	LMF	129,95	49,47	49,39	49,15	49,45	48,96	49,28
	SAM	129,95	81,00	80,84	80,40	80,81	80,23	80,59
	Detectron2	129,95	84,93	84,76	84,28	84,75	84,11	84,49
Carbono acima do solo	LMF	59,88	22,79	22,76	22,65	22,79	22,56	22,71
	SAM	59,88	37,33	37,25	37,05	37,24	36,97	37,14
	Detectron2	59,88	39,14	39,06	38,83	39,05	38,75	38,93
Biomassa de fuste	LMF	117,47	44,73	44,72	44,47	44,71	44,11	44,55
	SAM	117,47	73,24	73,19	72,73	73,06	72,29	72,87
	Detectron2	117,47	76,79	76,74	76,24	76,62	75,78	76,39
Carbono de fuste	LMF	54,13	20,61	20,58	20,49	20,60	20,33	20,53
	SAM	54,13	33,75	33,68	33,51	33,67	33,31	33,58
	Detectron2	54,13	35,39	35,32	35,13	35,30	34,92	35,20
Biomassa de copa	LMF	11,98	4,55	4,55	4,51	4,55	4,76	4,53
	SAM	11,98	7,45	7,45	7,39	7,41	7,80	7,40
	Detectron2	11,98	7,81	7,81	7,74	7,79	8,17	7,76
Carbono de copa	LMF	5,52	2,09	2,10	2,08	2,09	2,19	2,09
	SAM	5,52	3,43	3,43	3,40	3,42	3,59	3,41
	Detectron2	5,52	3,60	3,60	3,57	3,59	3,77	3,58

FONTE: A autora (2026).

LEGENDA: LMF: *Local Maximum Filter*; SAM: *Segment Anything Model*; Detectron2: Detectron2; Censo: biomassa e carbono acima do solo individual obtidos pelo modelo de Schumacher-Hall considerando as árvores mensuradas no censo florestal; STEP: *Stepwise*; ANN: *Artificial Neural Networks*; kNN: *k-Nearest Neighbor*; RF: *Random Forest*; SVR: *Support Vector Regression*; XGBoost: *Extreme Gradient Boosting*.

A TABELA 28 contém as estimativas de biomassa e carbono acima do solo a nível individual obtidas pelo melhor método de modelagem (XGBoost) considerando o número de indivíduos identificados pelo Detectron2. Nota-se que no compartimento total, a biomassa acima do solo foi, em média, de $84,49 \text{ t.ha}^{-1}$ e o carbono acima do solo foi de $38,93 \text{ t.ha}^{-1}$. No compartimento fuste, os valores médios foram de $76,39 \text{ t.ha}^{-1}$ para a biomassa e de $35,20 \text{ t.ha}^{-1}$ já o carbono. No compartimento copa, a biomassa média foi de $7,76 \text{ t.ha}^{-1}$, enquanto o carbono apresentou uma média de $3,58 \text{ t.ha}^{-1}$.

TABELA 28 – ESTIMATIVA DA BIOMASSA ACIMA DO SOLO (t.ha⁻¹) E CARBONO ACIMA DO SOLO (t.ha⁻¹) INDIVIDUAL POR COMPARTIMENTO EM *Eucalyptus* spp. COM DETECTRON2

Bloco	Biomassa acima do solo (t.ha ⁻¹)						
	Censo	STEP	ANN	kNN	RF	SVR	XGBoost
2	108,52	71,52	71,85	70,99	71,81	71,52	71,55
4	123,74	85,49	85,40	85,07	86,00	85,09	85,91
7	131,69	93,07	92,05	91,49	92,05	92,08	91,78
8	140,59	94,96	94,52	94,45	94,20	93,55	94,01
10	145,21	79,61	79,99	79,38	79,70	78,29	79,19
Média	129,95	84,93	84,76	84,28	84,75	84,11	84,49
Bloco	Carbono abaixo do solo (t.ha ⁻¹)						
	Censo	STEP	ANN	kNN	RF	SVR	XGBoost
2	50,01	32,96	33,05	32,71	33,09	32,95	32,97
4	57,02	39,40	39,40	39,20	39,63	39,21	39,60
7	60,68	42,89	42,54	42,16	42,41	42,43	42,30
8	64,78	43,76	43,51	43,52	43,40	43,11	43,32
10	66,91	36,68	36,80	36,58	36,74	36,08	36,49
Média	59,88	39,14	39,06	38,83	39,05	38,75	38,93
Bloco	Biomassa de fuste (t.ha ⁻¹)						
	Censo	STEP	ANN	kNN	RF	SVR	XGBoost
2	97,84	64,55	64,92	64,11	64,85	64,27	64,54
4	111,68	77,32	77,39	77,04	77,69	76,61	77,62
7	118,85	84,12	83,44	82,78	83,11	82,95	82,96
8	127,10	85,96	85,43	85,28	85,18	84,40	85,05
10	131,87	72,00	72,50	71,98	72,28	70,66	71,79
Média	117,47	76,79	76,74	76,24	76,62	75,78	76,39
Bloco	Carbono de fuste (t.ha ⁻¹)						
	Censo	STEP	ANN	kNN	RF	SVR	XGBoost
2	45,08	29,74	29,87	29,54	29,87	29,62	29,74
4	51,46	35,63	35,64	35,50	35,80	35,30	35,77
7	54,77	38,76	38,32	38,15	38,30	38,23	38,22
8	58,57	39,61	39,29	39,30	39,25	38,89	39,18
10	60,76	33,18	33,47	33,17	33,31	32,56	33,10
Média	54,13	35,39	35,32	35,13	35,30	34,92	35,20
Bloco	Biomassa de copa (t.ha ⁻¹)						
	Censo	STEP	ANN	kNN	RF	SVR	XGBoost
2	10,10	6,65	6,73	6,54	6,62	6,95	6,60
4	11,47	7,87	7,80	7,76	7,90	8,24	7,88
7	12,24	8,55	8,48	8,38	8,49	8,95	8,46
8	12,98	8,67	8,61	8,79	8,70	9,09	8,69
10	13,11	7,29	7,41	7,24	7,23	7,63	7,18
Média	11,98	7,81	7,81	7,74	7,79	8,17	7,76
Bloco	Carbono de copa (t.ha ⁻¹)						
	Censo	STEP	ANN	kNN	RF	SVR	XGBoost
2	4,65	3,06	3,10	3,02	3,05	3,20	3,04
4	5,28	3,63	3,59	3,57	3,64	3,80	3,63
7	5,64	3,94	3,94	3,86	3,91	4,12	3,90
8	5,98	4,00	4,02	4,05	4,01	4,19	4,00
10	6,04	3,36	3,36	3,34	3,33	3,52	3,31
Média	5,52	3,60	3,60	3,57	3,59	3,77	3,58

FONTE: A autora (2026).

LEGENDA: STEP: Stepwise; ANN: Artificial Neural Networks; kNN: k-Nearest Neighbor; RF: Random Forest; SVR: Support Vector Regression; XGBoost: Extreme Gradient Boosting.

Por fim, os resultados indicaram diferenças estatisticamente significativas entre as estimativas de biomassa e carbono acima do solo obtidas em nível individual quando comparadas com os valores do censo florestal.

4.4 DISCUSSÃO

Este estudo objetivou detectar indivíduos de *Eucalyptus* spp. e, posteriormente, quantificar, a nível individual, sua biomassa e carbono acima do solo por compartimento a partir de diferentes técnicas de modelagem.

Em relação a vetorização manual das 7.613 copas identificadas (TABELA 17), utilizada como referência para a validação de algoritmos, pode-se destacar fatores de influência como a morfologia e a estrutura das copas. Por tratar-se de uma área experimental com 25 genótipos implantados, ficou evidente a variação na estrutura, formato e tamanho das copas, além da influência do adensamento dos indivíduos. Sendo assim, copas grandes e bem definidas foram facilmente detectadas, enquanto copas irregulares ou sobrepostas dificultaram seu delineamento. Além da variabilidade morfológica das copas, fatores relacionados ao ortomosaico também influenciaram esse processo. A presença de sombras projetadas pelas copas e borrões (arrastamento) causados pelo vento e variações na iluminação ou movimento do sensor durante o levantamento dificultaram a delimitação das copas, podendo aumentar a chance de erros ou inconsistências na vetorização manual das copas.

Diante disso, fica evidente a necessidade de métodos de detecção automatizados capazes de lidar com a variabilidade estrutural entre genótipos e a complexidade do dossel. Nesse contexto, têm-se o algoritmo *Local Maxima Filter* (LMF), por tratar-se de um algoritmo com baixo custo computacional e ampla aplicação em estudos de inventário florestal (AZIZI; MIRAKI, 2024; MA *et al.*, 2022; YU *et al.*, 2022; YAN *et al.*, 2024b).

Na presente pesquisa, o LMF teve uma baixa taxa de detecção, de aproximadamente 54%. Tal resultado está diretamente relacionado com a sobreposição de copas e com os tamanhos do raio de busca, pois ao aumentar o tamanho da janela, aumenta-se a taxa de omissão; ao diminuir esse raio, ruídos ou subdivisões da copa podem ser identificados como árvore, aumentando a taxa de comissão, ou seja, árvores identificadas incorretamente. As condições da floresta

interferem na sensibilidade do algoritmo, ou seja, na detecção de valores extremos dentro de um intervalo especificado para determinar as localizações de árvores individuais (YAN *et al.*, 2024b).

Ademais, a aplicação de filtros de suavização, como gaussiano e média, não resultou em melhorias significativas na detecção de copas utilizando o algoritmo LMF, assim como a incorporação da nuvem de pontos integrada com diferentes resoluções de CHM. Isso se deve ao processo de suavização, especialmente do filtro gaussiano, que reduz pequenas variações topográficas ou pontos isolados na nuvem de dados, produzindo uma superfície do dossel contínua, facilitando, assim, a identificação correta de máximos locais correspondentes às copas das árvores (DALPONTE; COOMES, 2016).

Diante disso, a melhor combinação de parâmetros do algoritmo LMF foi o filtro gaussiano na resolução de 50 cm, que resultou na detecção de 4.148 copas de *Eucalyptus* spp. Tal resultado indica que apesar das limitações do algoritmo diante da variabilidade estrutural das copas dos genótipos, sua aplicabilidade ainda é consistente com outros estudos desenvolvidos em florestas homogêneas, assim como em Ma *et al.* (2022) e Yan *et al.* (2024b).

Apesar do desempenho do LMF, abordagens baseadas em aprendizado profundo, como o SAM, oferecem maior capacidade de generalização e precisão na segmentação de copas, superando muitas das restrições observadas nos métodos tradicionais, conforme evidenciado na TABELA 24.

Nessa pesquisa, o SAM detectou 6.816 copas de *Eucalyptus* spp. com base em caixas delimitadores formadas a partir da vetorização manual das copas, sem a necessidade de ajustes no modelo. O SAM identificou os padrões de copas nos genótipos com diferentes condições de adensamento e copas com diferentes tamanhos, destacando a superioridade de modelos de aprendizado profundo em identificar diferentes padrões nos conjuntos de dados.

Outro ponto de destaque é o modelo utilizado no algoritmo SAM. O modelo ViT-H, é uma arquitetura de *Vision Transformer* projetada para dividir a imagem em pequenos blocos, processá-los individualmente e integrá-los em uma única camada para representação da imagem segmentada (DOSOVITSKIY *et al.*, 2020).

Apesar do seu desempenho, deve-se destacar as limitações do algoritmo SAM. A primeira refere-se ao tipo de segmentação, pois o SAM realiza segmentação semântica (OSCO *et al.*, 2023), ou seja, os *pixels* pertencentes a uma mesma classe

são classificados como uma copa. Em caso de sobreposição e/ou fragmentação das copas, a segmentação pode resultar em fusões ou em omissões de objetos dentro da mesma classe, evidenciando a importância da utilização de imagens de entrada de alta qualidade (OSCO *et al.*, 2023). Além disso, deve-se destacar o número de imagens utilizadas no treinamento e validação, visto que essa pesquisa foi conduzida com 124 parcelas, número extremamente inferior aos testes tradicionais conduzidos com milhares de imagens para o treinamento do SAM.

O *Detectron2* apresentou resultados similares ao algoritmo SAM, tendo uma taxa de detecção superior, de 94%, fato explicado pela eficiência da segmentação por instância. Embora tenha identificado mais árvores, em alguns genótipos ocorreram confusões entre copas sobrepostas, resultando em fusão parcial ou superestimação da área de algumas árvores, evidenciando os desafios na segmentação de povoamentos heterogêneos, como os genótipos de *Eucalyptus* spp. em questão. Essa limitação também foi destacada nas pesquisas de Ball *et al.* (2023) e Zhao *et al.* (2023), ambas com foco na delimitação individual de copas em florestas tropicais.

Embora a comunidade científica internacional tenha demonstrado grande interesse pela aplicação do SAM e do *Detectron2* no setor florestal, especialmente na detecção individual, pesquisas nacionais sobre esse tema são escassas no Brasil, evidenciando a importância da realização de estudos introduzindo esse algoritmo no contexto do manejo de florestas plantadas, como as do gênero *Eucalyptus* spp.

No âmbito internacional, Zhang *et al.* (2024) analisaram as limitações do SAM na segmentação de diferentes espécies arbóreas. Os resultados mostraram que o desempenho do SAM diminuiu à medida que os objetos apresentaram maior semelhança com árvores e menor separabilidade de textura em relação ao fundo, resultando em falhas na distinção de objetos. Os autores também reforçam a necessidade de outras pesquisas em outros tipos de floresta para a validação dos parâmetros do algoritmo.

Além do SAM, outros métodos de aprendizado profundo vêm sendo estudados, como o Mask R-CNN (*Region-based Convolutional Neural Network*). Com esse modelo, Ding *et al.* (2025) realizaram a detecção individual das copas e para a estimativa da idade de *Eucalyptus* spp. localizados na China com precisão variando entre 48,9% a 80,6% de acordo com os estágios do plantio.

Além dos métodos de aprendizado profundo, como o SAM e o *Detectron2*, pode-se citar o HDBSCAN (*Hierarchical Density-Based Spatial Clustering of Applications with Noise*) é um algoritmo de agrupamento (*clustering*) não supervisionado, usado para identificar grupos (*clusters*) de pontos em um conjunto de dados espacial. Esse método teve uma acurácia de 91,1% e um F1-score de 0,916 na detecção de *Eucalyptus urophylla* na China (ZHOU; LI; LI, 2025).

A partir da detecção das copas de *Eucalyptus* spp., a modelagem da biomassa aérea e do carbono aéreo a nível individual, resultou em estimativas com erros abaixo de 7% e R^2_{ajustado} acima de 0,90 nos compartimentos total e fuste. Para a copa, os métodos apresentaram erros oscilando entre 4,32% a 23,03% e R^2_{ajustado} entre 0,622 a 0,960 (TABELA 25).

A validação das medidas de concordância (TABELA 26) e o gráfico de Bland-Altman (FIGURA 24), indicam que o algoritmo XGBoost demonstrou a maior capacidade preditiva da biomassa e do carbono acima do solo por compartimento, estimando, em média: 84,49 t.ha⁻¹ e 38,93 t.ha⁻¹ de biomassa e carbono total individual, 76,39 t.ha⁻¹ e 35,20 t.ha⁻¹ de biomassa e carbono no fuste e 7,76 t.ha⁻¹ e 3,58 t.ha⁻¹ de biomassa e carbono no compartimento copa, respectivamente (TABELA 28).

Em todos os compartimentos analisados, após o XGBoost, RF foi o algoritmo com maior destaque seguido pelas ANN. A superioridade do XGBoost deve-se a maior sensibilidade as relações complexas existentes entre as variáveis e a maior capacidade computacional exigida para o ajuste desse modelo, pelo ajuste de hiperparâmetros, como o número de árvores, profundidade máxima e taxa de aprendizado, conforme destacado por Chen e Guestrin (2016).

O RF permanece como um algoritmo robusto para a estimativa da biomassa e do carbono acima do solo individual, apresentando desempenho apenas ligeiramente inferior ao XGBoost. Contudo, foi observado a presença de *overfitting* em todos os compartimentos analisados, caracterizado por uma performance superior no conjunto de treinamento em relação ao de validação. Mesmo assim, o modelo demonstra elevado potencial em razão de sua capacidade de capturar interações entre múltiplas métricas derivadas dos dados UAV-LiDAR e do uso da amostragem *bootstrap*, característica fundamental do método (BREIMAN, 2001).

De acordo com a literatura disponível, as pesquisas sobre a estimativa da biomassa e do carbono acima do solo em *Eucalyptus* spp. a nível individual são

incipientes, revelando a necessidade da condução de pesquisas com essa abordagem. A grande maioria dos estudos concentra-se principalmente a nível de área, como pode-se destacar a pesquisa de Pertille *et al.* (2025). Nessa pesquisa, a biomassa aérea e o carbono aéreo por compartimento de *Eucalyptus* spp. foram estimados a nível de área, com R^2_{ajustado} de 0,959 para o compartimento total e fuste com o modelo RF e com R^2_{ajustado} de 0,765 e 0,707 no compartimento copa com XGBoost, respectivamente.

Ainda com essa abordagem, Ye *et al.* (2025) estimaram a biomassa aérea acima do solo de *Eucalyptus globoidea* e *Eucalyptus bosistoana* com um modelo construído com XGBoost com R^2 de 0,903. Já Pinedo *et al.* (2025) estimaram a biomassa acima do solo em *Eucalyptus globulus* no Peru, utilizando dados LiDAR adquiridos com um DJI Zenmuse L1, cujo modelo do RF teve um R^2 de 0,76 no conjunto de treinamento e de 0,66 no conjunto de teste.

Diante dos resultados de detecção e de modelagem apresentados, deve-se destacar as limitações dessa pesquisa. A primeira está relacionada com a ausência de dados georreferenciados combinado com o adensamento das copas, que dificultou o processo de identificação e numeração das copas vetorizadas manualmente, que, por sua vez, foram a base da modelagem da biomassa e do carbono acima do solo a nível individual. Além disso, outro fator limitante foi a fonte de dados utilizada na vetorização manual. Por tratar-se de um ortomosaico, apenas as copas dominantes foram identificadas afetando a qualidade da detecção das copas. Dessa forma, ficou evidente que as estimativas individuais de biomassa e carbono acima do solo são sensíveis aos erros de altura e posição das árvores, bem como da delimitação precisa das respectivas copas.

Ademais, a aquisição dos dados UAV-LiDAR com o sensor Zenmuse L1 é outro fator de atenção, pois o tipo de sensor afeta diretamente a densidade de pontos, que nessa pesquisa, foi de média densidade (~390 pontos.m²). A combinação do sensor com o número adensado de indivíduos por genótipo pode ter influenciado na penetração do sensor *laser* afetando a geração dos modelos digitais e consequentemente, na extração das métricas UAV-LiDAR e nas estimativas das variáveis analisadas.

Por fim, recomenda-se que sejam conduzidas pesquisas nesse âmbito utilizando diversas espécies de *Eucalyptus* spp. em outros biomas brasileiros, com amostragem estratificada e aquisição sazonal de dados LiDAR em diferentes

plataformas combinados com a realização do censo florestal e da amostragem destrutiva da biomassa. Além disso, sugere-se aplicar diferentes algoritmos de aprendizado profundo para a detecção das copas dos indivíduos com maior precisão, para garantir a correta estimativa de biomassa aérea e carbono aéreo a nível de Indivíduo, visando o monitoramento do estoque de carbono dessas áreas.

4.5 CONCLUSÃO

Os resultados evidenciam o potencial de integração entre técnicas avançadas de detecção de copas e métodos de aprendizado de máquina para estimar o estoque de biomassa aérea e carbono aéreo em genótipos de *Eucalyptus* spp. por indivíduo. Dentre os métodos de detecção, o algoritmo Detectron2 apresentou a maior taxa de detecção de copas de *Eucalyptus* spp. Quanto a modelagem, o XGBoost foi mais eficaz na predição da biomassa e do carbono acima do solo em todos os compartimentos. Além disso, também foi observada a existência de diferenças significativas entre as estimativas de biomassa e carbono acima do solo em nível individual e aquelas obtidas pelo censo florestal, reforçando a influência da abordagem adotada.

Dessa forma, pode-se destacar que informações nessa escala atuam como suporte técnico para o planejamento e a gestão sustentável de plantios de *Eucalyptus* spp. Portanto, recomenda-se o aperfeiçoamento dessa abordagem em outras condições edafoclimáticas abrangendo diferentes genótipos de *Eucalyptus* spp. para a geração de dados robustos e aplicáveis em ações voltadas à adaptação e mitigação das mudanças climáticas.

5 ANÁLISE COMPARATIVA DAS ABORDAGENS A NÍVEL DE ÁREA E POR ÁRVORE INDIVIDUAL NA ESTIMATIVA DE BIOMASSA E CARBONO ACIMA DO SOLO EM *Eucalyptus* spp.

5.1 INTRODUÇÃO

A estimativa precisa da biomassa e do carbono acima do solo em plantios florestais é fundamental para o manejo sustentável e o monitoramento do papel das florestas na mitigação das mudanças climáticas (IPCC, 2023). Dessa forma, o avanço das tecnologias de Sensoriamento Remoto, especialmente os dados UAV-LiDAR, têm permitido a aplicação de diferentes abordagens metodológicas em estudos florestais, destacando-se as análises em nível de área e em nível de indivíduo (CAMPBELL *et al.*, 2023; DUBROVIN *et al.*, 2024; LIN *et al.*, 2024; PERTILLE *et al.*, 2025; PINEDO *et al.*, 2025; YE *et al.*, 2025).

As abordagens em nível de área baseiam-se na obtenção de métricas estruturais representativas (ROUSSEL *et al.*, 2020) do povoamento, oferecendo maior robustez operacional e consistência espacial. Em nível de árvore individual, a variabilidade estrutural dos indivíduos é analisada pela detecção e segmentação de árvores individuais (OSCO *et al.*, 2023; RAKSHITHA *et al.*, 2024). Apesar do grande uso dessas abordagens em pesquisas florestais, é válido destacar que elas possuem diferenças importantes quanto à escala de análise e à capacidade de representar a heterogeneidade do povoamento, influenciando, assim, nas estimativas de biomassa e carbono acima do solo em *Eucalyptus* spp.

Nesse contexto, este capítulo teve como objetivo avaliar o desempenho estatístico das estimativas de biomassa e carbono acima do solo de *Eucalyptus* spp. derivadas das abordagens em nível de área e em nível de indivíduo, tendo como referência o censo florestal.

5.2 MATERIAL E MÉTODOS

Os dados utilizados neste capítulo correspondem às estimativas de biomassa e carbono acima do solo obtidas a partir das abordagens em nível de área e de indivíduo. Na primeira abordagem, as estimativas de biomassa e carbono acima do solo foram realizadas a partir de métricas UAV-LiDAR a nível de parcela. Para tanto,

as métricas UAV-LiDAR foram selecionadas pela Análise de Componentes Principais para a construção de modelos preditivos de biomassa e carbono acima do solo por compartimento por meio de diversos algoritmos de ML. Por fim, as estimativas foram comparadas com o censo florestal. A abordagem a nível individual baseou-se na detecção das copas e na modelagem da biomassa e do carbono acima do solo a nível de indivíduo. A primeira etapa consistiu na aplicação de diferentes algoritmos de *Deep Learning* para a detecção das copas dos genótipos de *Eucalyptus* spp. Em seguida, as métricas UAV-LiDAR foram extraídas por indivíduo, selecionadas por Análise de Componentes Principais e aplicadas nos mesmos métodos de modelagem empregados a nível de área. A última etapa consistiu na verificação da existência de diferenças significativas entre os valores de biomassa e carbono acima do solo a nível individual e os valores do censo florestal.

Por fim, para avaliar se as estimativas de biomassa e carbono acima do solo em cada abordagem possuem diferenças significativas, a normalidade das diferenças entre as estimativas de cada abordagem foi verificada pelo teste de Shapiro-Wilk (SHAPIRO WILK, 1985), aplicado para cada compartimento. Em caso de distribuição normal, as diferenças entre as estimativas de cada abordagem serão avaliadas pelo Teste T pareado. Em caso contrário, será aplicado o teste de Wilcoxon. Todos os testes estatísticos foram aplicados a 95% de confiança no *software* R (R CORE TEAM, 2022).

5.3 RESULTADOS

A análise comparativa entre as estimativas de biomassa e carbono acima do solo obtidas a partir da abordagem a nível de área e da abordagem a nível individual reforçou as diferenças, limitações e representação das condições dos genótipos de *Eucalyptus* spp. em cada abordagem.

De acordo com a TABELA 29, nota-se que a primeira abordagem, baseada em área, apresentou os maiores valores de biomassa e carbono acima do solo em todos os compartimentos quando comparada com o nível individual. Ao comparar diretamente as duas abordagens, os compartimentos total e fuste apresentaram a menor variação, com aproximadamente 23,8% e 24,0%, respectivamente. No compartimento copa, a diferença foi, em média, 27,7% para a biomassa e o carbono acima do solo. Em média, para a variável biomassa considerando os três

compartimentos, as estimativas a nível de área e indivíduo tiveram uma diferença média de 25,1%; já para o carbono, essa diferença foi ligeiramente superior, de 25,2%.

TABELA 29 – COMPARATIVO DA BIOMASSA ACIMA DO SOLO (t.ha⁻¹) E DO CARBONO ACIMA DO SOLO (t.ha⁻¹) POR COMPARTIMENTO EM *Eucalyptus* spp. COM DIFERENTES ABORDAGENS: ÁREA X ÁRVORE INDIVIDUAL

Compartimento	Censo (t.ha ⁻¹)	Área (t.ha ⁻¹)	Indivíduo (t.ha ⁻¹)	Diferença (%)		
				Área	Indivíduo	Área x Indivíduo
Biomassa total	111,22	110,97	84,49	0,2%	24,0%	23,8%
Carbono total	51,25	51,16	38,93	0,2%	24,0%	23,9%
Biomassa de fuste	100,01	100,46	76,39	-0,5%	23,6%	23,9%
Carbono de fuste	46,09	46,34	35,20	-0,6%	23,6%	24,0%
Biomassa de copa	10,79	10,72	7,76	0,6%	28,0%	27,6%
Carbono de copa	4,97	4,96	3,58	0,2%	28,0%	27,9%

FONTE: A autora (2026).

De acordo com a TABELA 29, as estimativas obtidas pela abordagem a nível de área foram mais próximas aos valores do censo florestal, com diferenças percentuais inferiores a 1% em todos os compartimentos avaliados, tanto para a biomassa quanto para o carbono acima do solo. Em contrapartida, a abordagem a nível individual apresentou subestimativas em relação ao censo florestal, variando entre 24,0% e 23,6% nos compartimentos total e fuste e diferenças superiores a 28% no compartimento copa.

A análise estatística entre as estimativas de biomassa e carbono acima do solo produzidas em cada compartimento e em cada abordagem (área x indivíduo) revelou diferenças significativas em todos os compartimentos (TABELA 30). De acordo com o teste de Shapiro–Wilk, as diferenças entre as abordagens não seguem distribuição normal em nenhum compartimento. Com base nisso, aplicou-se o teste de Wilcoxon, cujos valores abaixo de 0,05 comprovam que as diferenças entre a abordagem a nível de área e a nível individual são estatisticamente significativas.

TABELA 30 – TESTES ESTATÍSTICOS APLICADOS ÀS ESTIMATIVAS DE BIOMASSA (t.ha⁻¹) E CARBONO ACIMA DO SOLO (t.ha⁻¹) POR COMPARTIMENTO EM *Eucalyptus* spp. E POR ABORDAGEM: ÁREA X INDIVÍDUO

Compartmento	Shapiro-Wilk (p-value)	Wilcoxon (p-value)
Biomassa total	0,9583	2,20 x 10 ⁻¹⁶
Carbono total	0,9161	2,20 x 10 ⁻¹⁶
Biomassa de fuste	0,0066	2,20 x 10 ⁻¹⁶
Carbono de fuste	0,9600	2,20 x 10 ⁻¹⁶
Biomassa de copa	0,9188	2,20 x 10 ⁻¹⁶
Carbono de copa	0,0230	2,20 x 10 ⁻¹⁶

FONTE: A autora (2026).

5.4 DISCUSSÃO

As discrepâncias entre as abordagens, destacadas pelas medidas de concordância indicam que a escala de análise foi o principal fator responsável pelas discrepâncias observadas. Na abordagem a nível de área, que apresentou os maiores valores de biomassa e carbono acima do solo, o somatório das árvores contribuiu para minimizar a variabilidade existente em cada parcela. Na abordagem por árvore individual, por sua vez, fatores como o adensamento dos indivíduos, os erros de segmentação e detecção das copas além da incerteza da localização das árvores resultaram em um menor número de indivíduos detectados e consequentemente, em um menor estoque de biomassa e carbono acima do solo nos diferentes compartimentos analisados nos genótipos de *Eucalyptus* spp.

Ademais, foi possível notar a maior suscetibilidade da propagação de erros ao longo das etapas metodológicas aplicada na abordagem por árvore individual, uma vez que incertezas iniciais na detecção e segmentação das copas impactam diretamente a estimativa das variáveis dendrométricas (D e H) por dados UAV-LiDAR, especialmente em genótipos com maior adensamento dos indivíduos.

Além disso, outro fator de influência é a resolução espacial do ortomosaico utilizado, cujo GSD (*Ground Sample Distance*) foi de 14 cm. Tal resolução espacial pode limitar a identificação e a definição dos contornos das copas dos genótipos, especialmente em copas menores ou parcialmente sombreadas, comprometendo sua segmentação. Nesse sentido, o uso de ortomosaicos com maior resolução espacial (menor GSD) poderia proporcionar maior detalhamento das copas, reduzindo as incertezas no delineamento das copas por interpretação visual, auxiliando na redução dos erros ao longo das etapas da pesquisa e na geração de estimativas mais consistentes e próximas dos valores do censo florestal.

5.5 CONCLUSÃO

Os resultados obtidos revelaram que as estimativas de biomassa e carbono acima do solo de *Eucalyptus* spp. pelas abordagens em nível de área e por árvore individual diferiram estatisticamente, ou seja, tais metodologias não são equivalentes do ponto de vista quantitativo. Dessa forma, recomenda-se que as abordagens sejam utilizadas e interpretadas de forma complementar, visto que a escolha da abordagem mais adequada está relacionada com o objetivo da análise, a escala de interesse e o equilíbrio entre o detalhamento estrutural e a acurácia na estimativa dos estoques de biomassa e carbono acima do solo.

6 CONSIDERAÇÕES FINAIS

Essa pesquisa teve como objetivo avaliar a performance da abordagem a nível de área e a nível de indivíduo na estimativa da biomassa e do carbono acima do solo em genótipos de *Eucalyptus* spp. em relação aos valores obtidos pelo censo florestal. Os resultados evidenciam que ambas as abordagens possuem elevado potencial para a estimativa da biomassa e do carbono acima do solo, porém, possuem comportamentos distintos em função da escala de análise adotada e pelas características dos genótipos avaliados.

Conforme explorado anteriormente, a diferença de escala em cada abordagem foi crucial para as estimativas geradas. Em suma, a nível de área, o somatório da biomassa e do carbono nos diferentes compartimentos contribuiu para minimizar as variações individuais de biomassa e carbono das árvores, que foram consideradas em um único valor por parcela. A nível de indivíduo, o adensamento dos indivíduos combinado com a sensibilidade dos modelos aos erros de segmentação das copas impactou diretamente na acurácia das estimativas de biomassa e carbono individual. Além disso, os erros ou incertezas na delimitação da parcela podem afetar o número de árvores contido em cada parcela e consequentemente, as estimativas de biomassa e carbono por hectare.

Diante disso, recomenda-se que pesquisas futuras sejam realizadas integrando plataformas de aquisição de dados LiDAR, em diferentes genótipos de *Eucalyptus* spp. com idades e sítios diferentes as dessa pesquisa. Ademais, também sugere-se utilizar parcelas georreferenciadas bem como diversos modelos de *Machine Learning* e *Deep Learning* para a modelagem da biomassa e do carbono e para a detecção de copas de *Eucalyptus* spp. Além disso, no que se refere a modelagem da biomassa, recomenda-se a utilização do ajuste simultâneos dos compartimentos devido a sua capacidade de relacionar as relações alométricas entre os compartimentos.

Ademais, os resultados obtidos destacam a elevada aplicabilidade dos algoritmos Detectron2 e do *Segment Anything Model* (SAM) para a detecção e segmentação de indivíduos de *Eucalyptus* spp. a partir de dados de alta resolução espacial. Ambos os métodos demonstraram grande potencial para automatizar a extração de informações em nível individual, reforçando seu uso como ferramentas estratégicas em inventários florestais de precisão. Porém, é de suma importância

destacar que seu desempenho está fortemente relacionado com a resolução espacial dos dados de entrada, com a variação estrutural do dossel e com o adensamento dos indivíduos.

Os resultados obtidos nessa pesquisa reforçam a eficiência da integração entre dados UAV-LiDAR com algoritmos de *Machine Learning* e *Deep Learning* para a estimativa de biomassa e carbono acima do solo em *Eucalyptus* spp. A comparação entre as abordagens testadas permitiu identificar as potencialidades e limitações de cada escala de análise, indicando que a abordagem deve ser adotada considerando as características do plantio analisado e os dados UAV-LiDAR obtidos, visto que esses fatores afetam consideravelmente a precisão das estimativas das variáveis de interesse.

Por fim, essa pesquisa demonstra que apesar das limitações encontradas, as estimativas de biomassa e carbono acima do solo a partir das abordagens testadas foram consistentes e que podem ser utilizadas de forma complementar, especialmente em plantios com alta variabilidade, como os genótipos avaliados.

6.1 RECOMENDAÇÕES PARA TRABALHOS FUTUROS

À luz dos resultados alcançados, observa-se a necessidade de estudos para o entendimento do comportamento das estimativas de biomassa e carbono acima do solo de *Eucalyptus* spp. em diferentes contextos de análise. Em função disso, recomenda-se avaliar as seguintes frentes de pesquisa:

- Monitoramento temporal com sazonalidade de voos UAV-LiDAR: realização de voos UAV-LiDAR anuais e/ou em diferentes épocas do ano, para o acompanhamento da dinâmica da biomassa e do estoque de carbono ao longo do tempo.
- Plantios com maior adensamento: recomenda-se especial atenção às etapas de detecção e segmentação das copas, uma vez que a proximidade entre os indivíduos dificulta a separação das árvores e pode resultar na omissão de indivíduos. Esses erros iniciais impactam diretamente a estimativa do número de árvores e, conseqüentemente, os valores de biomassa e carbono acima do solo.
- Integração de dados LiDAR de diferentes plataformas: investigar a integração de dados LiDAR provenientes de plataformas terrestres (*Terrestrial Laser Scanning*) e móveis (*Mobile Laser Scanning*). Essa integração pode fornecer

informações complementares sobre o dossel e o sub-bosque, contribuindo para estimativas mais completas e robustas da biomassa e do carbono acima do solo.

- Aplicação das abordagens em diferentes condições de sítio: Recomenda-se que as abordagens em nível de área e em nível individual sejam testadas em outras áreas, abrangendo diferentes idades, condições de solo, sítio e genótipos de *Eucalyptus* spp., de modo a avaliar seu desempenho em contextos distintos daquele analisado neste estudo.

REFERÊNCIAS

- ABRAHAM, S.; RAISEE, M.; GHORBANIASL, G.; CONTINO, F.; LACOR, C. A robust and efficient *Stepwise* regression method for building sparse polynomial chaos expansions. **Journal of Computational Physics**, v. 332, p. 461-474, 2017. DOI. <https://doi.org/10.1016/j.jcp.2016.12.015>
- ADAM, J.M. *et al.* Deep learning-based semantic segmentation of urban-scale 3D meshes in remote sensing: A survey. **International Journal of Applied Earth Observation and Geoinformation**, v. 121, p. 103365, 2023. DOI. <https://doi.org/10.1016/j.jag.2023.103365>
- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. de M.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013. DOI. 10.1127/0941-2948/2013/0507
- AMERICAN SOCIETY FOR PHOTOGRAMMETRY & REMOTE SENSING (ASPRS). **LAS specification**. Version 1.4-R6, 2011. 18 p. Disponível em <https://www.asprs.org/>. Acesso em 30 abr. 2022.
- ANANDITA, K.; SINHA, A. K.; JEGANATHAN, C. Machine Learning Approach to Biomass Estimation: Integrating Satellite and Ground Data in Sal Forests of Jharkhand. **Journal of the Indian Society of Remote Sensing**, p. 1-17, 2024. DOI. <https://doi.org/10.1007/s12524-024-02061-3>
- AREVALO, L. A; ALEGRE, C. J; VILCAHUAMAN L. J. M. **Metodologia para estimar o estoque de carbono em diferentes sistemas de uso da terra**. Colombo - PR: Embrapa Florestas, 2002.
- AZIZI, Z.; MIRAKI, M. Individual urban trees detection based on point clouds derived from UAV-RGB imagery and *Local Maxima Filter* algorithm, a case study of Fateh Garden, Iran. **Environment, Development and Sustainability**, v. 26, n. 1, p. 2331-2344, 2024. DOI. <https://doi.org/10.1007/s10668-022-02820-7>
- BAI, Y.; PANG, Y.; KONG, D. Integrating remote sensing and 3-PG model to simulate the biomass and carbon stock of *Larix olgensis* plantation. **Forest Ecosystems**, p. 100213, 2024. DOI. <https://doi.org/10.1016/j.fecs.2024.100213>
- BALAZS, A.; LISKI, E.; TUOMINEN, S.; KANGAS, A. Comparison of neural networks and *k-Nearest Neighbors* methods in forest stand variable estimation using airborne laser data. **ISPRS Open Journal of Photogrammetry and Remote Sensing**, v. 4, p. 100012, 2022. DOI. <https://doi.org/10.1016/j.ophoto.2022.100012>
- BALL, J. G. C. *et al.* Accurate delineation of individual tree crowns in tropical forests from aerial RGB imagery using Mask R-CNN. **Remote Sensing in Ecology and Conservation**, v. 9, n. 5, p. 641-655, 2023. DOI. <https://doi.org/10.1002/rse2.332>

BALTSAVIAS, E. P. A comparison between photogrammetry and laser scanning. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, n. 2-3, p. 83-94, 1999. DOI. [https://doi.org/10.1016/S0924-2716\(99\)00014-3](https://doi.org/10.1016/S0924-2716(99)00014-3)

BASÍLIO, J. J. N. *et al.* Fine Root Density Dynamics and Carbon Stock of *Eucalyptus* spp.: Interplay of Age, Genotype, and Edaphoclimatic Conditions. **Plants**, v. 13, n. 11, p. 1503, 2024. DOI. <https://doi.org/10.3390/plants13111503>

BEHLING, M.; KOEHLER, H. S.; BEHLING, A. Compatibility between the stem volume and taper equations volume for black wattle trees. **Floresta**, v. 50, n. 3, e1518, 2020. DOI. <http://dx.doi.org/10.5380/rf.v50i3.63881>

BEHLING, A. PÉLLICO NETTO, S.; SANQUETTA, C. R.; CORTE, A. P. D.; SIMON, A. A.; RODRIGUES, A. L.; CARON, B. O. Additive and non-additive biomass equations for black wattle. **Floresta e Ambiente**, v. 26, n. 4, e20170439, 2019. DOI. <https://doi.org/10.1590/2179-8087.043917>

BLAND, J. M.; ALTMAN, D.G. Statistical methods for assessing agreement between two methods of clinical measurement. **The Lancet**, v. 327, n. 8476, p. 307-310, 1986. DOI. [https://doi.org/10.1016/S0140-6736\(86\)90837-8](https://doi.org/10.1016/S0140-6736(86)90837-8)

BORGOGNO MONDINO, E.; FISSORE, V.; FALKOWSKI, M.J.; PALIK, B. How far can we trust forestry estimates from low-density LiDAR acquisitions? The Cutfoot Sioux experimental forest (MN, USA) case study. **International Journal of Remote Sensing**, v. 41, n. 12, p. 4551-4569, 2020. DOI. <https://doi.org/10.1080/01431161.2020.1723173>

BORSAH, A. A.; NAZEER, M.; WONG, M. S. LIDAR-based forest biomass remote sensing: A review of metrics, methods, and assessment criteria for the selection of allometric equations. **Forests**, v. 14, n. 10, p. 2095, 2023. DOI. <http://dx.doi.org/10.3390/f14102095>

BRASIL. **Lei nº 15.042, de 11 de dezembro de 2024**. Institui o Sistema Brasileiro de Comércio de Emissões de Gases de Efeito Estufa (SBCE); e altera as Leis nºs 12.187, de 29 de dezembro de 2009, 12.651, de 25 de maio de 2012 (Código Florestal), 6.385, de 7 de dezembro de 1976 (Lei da Comissão de Valores Mobiliários), e 6.015, de 31 de dezembro de 1973 (Lei de Registros Públicos). Diário Oficial da República Federativa do Brasil. Brasília, DF, 2024.

BRASIL. **Lei nº 12.651 de 25 de maio de 2012**. Institui o Código Florestal. Diário Oficial da República Federativa do Brasil. Brasília, DF, 2012.

BRASIL. Lei nº 12.187, de 29 de dezembro de 2009. Institui a Política Nacional sobre Mudança do Clima - PNMC e dá outras providências. Brasília, DF: **Diário Oficial da União**, 2009.

BRASIL. **Lei nº 5.106 de 02 de setembro de 1966**. Dispõe sobre os incentivos fiscais concedidos a empreendimentos florestais. Diário Oficial da união, Brasília, 03 de set. de 1966.

BRASIL. **Lei nº 4.771 de 15 de setembro de 1965**. Código Florestal. Diário Oficial da República Federativa do Brasil, Poder Legislativo, Brasília, DF, 16 de set. Seção 1. p. 9529-9531.

BRASIL. **Decreto Federal nº 23.793**, de 23 de janeiro de 1934. Decreta o Código Florestal. Brasília, DF, 1934.

BREIMAN, L. *Random Forests*. **Machine learning**, v. 45, n. 1, p. 5-32, 2001. DOI. <https://doi.org/10.1023/A:1010933404324>

BUCKERIDGE, M.S.; CAVALARI, A.A.; SILVA, G.B. Parede Celular. In: Kerbauy, G.B. (ed.) **Fisiologia Vegetal**. 2. ed. Rio de Janeiro: Guanabara Koogan, 2008. P. 165–181.

CAI, J.; XU, K.; ZHU, Y.; HU, F.; LI, L. Prediction and analysis of net ecosystem carbon exchange based on gradient boosting regression and *Random Forest*. **Applied Energy**, v. 262, p. 114566, 2020. DOI. <https://doi.org/10.1016/j.apenergy.2020.114566>

CAMPBELL, M. J.; EASTBURN, J.F.; MISTICK, K.A.; SMITH, A.M.; STOVALL, A.E.L. Mapping individual tree and plot-level biomass using airborne and mobile lidar in piñon-juniper woodlands. **International Journal of Applied Earth Observation and Geoinformation**, v. 118, p. 103232, 2023. DOI. <https://doi.org/10.1016/j.jag.2023.103232>

CASTILHO, A. F. de A. N. A extrafiscalidade no Brasil. **Jurídica Luso-Brasileira**, v. 2, n. 4, p. 135–159, 2016.

CHEN, T.; HE, T.; BENESTY, M.; KHOTILOVICH, V.; TANG, Y.; CHO, H.; CHEN, K. (2024). xgboost: Extreme Gradient Boosting. R package version 1.7.x.

CHEN, Q. *et al.* A point cloud filtering approach to generating DTMs for steep mountainous areas and adjacent residential areas. **Remote Sensing**, v. 8, n. 1, p. 71, 2016. DOI. <https://doi.org/10.3390/rs8010071>

CHEN, T.; GUESTRIN, C. XGBoost: A scalable tree boosting system. In: **Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining**. 2016. p. 785-794.

CHERKASSKY, V.; MA, Y. Practical selection of SVM parameters and noise estimation for SVM regression. **Neural Networks**, v. 17, n. 1, p. 113-126, 2004. DOI. [https://doi.org/10.1016/S0893-6080\(03\)00169-2](https://doi.org/10.1016/S0893-6080(03)00169-2)

CORTE, A. P. *et al.* **Aplicações do lidar para o inventário florestal - Enfoque unidade de área**. Ponta Grossa: Editora Atena. 2022. 118p.

COSENZA, D. N. *et al.* Comparison of linear regression, k-nearest neighbour and *Random Forest* methods in airborne laser-scanning-based prediction of growing stock. **Forestry: An International Journal of Forest Research**, v. 94, n. 2, p. 311-323, 2021. DOI. <https://doi.org/10.1093/forestry/cpaa034>

COUTINHO, V. M.; OLIVEIRA, T. W. G. de.; FIORENTIN, L. D.; SANQUETTA, M. N. I.; SANQUETTA, C. R.; CORTE, A. P. D. How to estimate black wattle aboveground biomass from heteroscedastic data? **Floresta**, v, 51, n. 1, p. 28-39, 2021. DOI. <http://dx.doi.org/10.5380/rf.v51i1.65236>

CUNHA, F. L.; NIERI, E.M.; DIAS, M.G.; MELO, L.A.de.; VENTURIN, N. Uso de adubos de liberação lenta no crescimento inicial de clones de eucalipto. **Ciência Florestal**, v. 33, n. 2, p. e69118, 2023. DOI. <https://doi.org/10.5902/1980509869118>

CUNHA NETO, E. M.; SANTANA, G. M.; ARAUJO, E. C. G.; VERAS, H. F. P.; MARCOS, D. P.; FRIEDRICH, F.; SANQUETTA, C. R. Carbon stock and biomass estimate by additive models applied to *Ilex paraguariensis*. **Pesquisa Agropecuária Tropical**, v. 52, n. e72966, p. p. 1-10, 2022. DOI. <https://doi.org/10.1590/1983-40632022v5272966>

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. DOI. <https://doi.org/10.1111/2041-210X.12575>

DATTA, D. *blandr: a Bland-Altman Method Comparison package for R*. DOI. 10.5281/zenodo.824514

DING, J. *et al.* Research on eucalyptus individual tree segmentation and age estimation utilizing improved Mask R-CNN algorithm based on UAV stereo images. **Industrial Crops and Products**, v. 230, p. 121073, 2025.

DJI. **Zenmuse L1**. Disponível em: <https://enterprise.dji.com/pt-br/zenmuse-l1>. Acesso em: 20 mai. 2023.

DOMINGUES, G. F. *et al.* Artificial Neural Networks on integrated multispectral and SAR data for high-performance prediction of *Eucalyptus* biomass. **Computers and Electronics in Agriculture**, v. 168, p. 105089, 2020. DOI. <https://doi.org/10.1016/j.compag.2019.105089>

DONG, P.; CHEN, Q. **LiDAR Remote Sensing and Applications**. Boca Raton, FL: Taylor & Francis, 2018. 210p.

DONG, W.; MITCHARD, E.T.A.; YU, H.; HANCOCK, S.; RYAN, C. M. Forest aboveground biomass estimation using GEDI and earth observation data through attention-based deep learning. **arXiv preprint arXiv**, v. 2311.03067, 2023.

DOSOVITSKIY, A. *et al.* An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. **arXiv:2010.11929**, p.1-22, 2020. DOI. <https://doi.org/10.48550/arXiv.2010.11929>

DUBAYAH, R. O.; DRAKE, J. B. Lidar remote sensing for forestry. **Journal of forestry**, v. 98, n. 6, p. 44-46, 2000. DOI. <https://doi.org/10.1093/jof/98.6.44>

DUBROVIN, I.; FORTIN, C.; KEDROV, A. An open dataset for individual tree detection in UAV LiDAR point clouds and RGB orthophotos in dense mixed forests. **Scientific Reports**, v. 14, n. 1, p. 21938, 2024. DOI. <https://doi.org/10.1038/s41598-024-72669-5>

DUVEILLER, G.; FASBENDER, D.; MERONI, M. Revisiting the concept of a symmetric index of agreement for continuous datasets. **Scientific reports**, v. 6, n. 1, p. 19401, 2016. DOI. <https://doi.org/10.1038/srep19401>

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA – EMBRAPA. **Sistema brasileiro de classificação de solos**. 2. ed. Brasília, DF: Embrapa Produção de Informação; Rio de Janeiro: Embrapa Solos, 2006. 306 p.

ESPERON-RODRIGUEZ, M. *et al.* Assessing climate risk to support urban forests in a changing climate. **Plants, People, Planet**, v. 4, n. 3, p. 201-213, 2022. DOI. <https://doi.org/10.1002/ppp3.10240>

FAN, G. *et al.* Satellite Image Fusion Airborne LiDAR Point-Clouds-Driven Machine Learning Modeling to Predict the Carbon Stock of Typical Subtropical Plantation in China. **Forests**, v. 15, n. 5, p. 751, 2024. DOI. <https://doi.org/10.3390/f15050751>

FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS – FAO. **Global Forest Resources Assessment (FRA) – 2020**. 2020. Disponível em: <https://www.fao.org/3/ca9825en/ca9825en.pdf>. Acesso em: 19 ago. 2023.

FRIEDLINGSTEIN, P. *et al.* Global carbon budget 2023. **Earth System Science Data**, p. 1-117, 2023.

FRIEDLINGSTEIN, P. *et al.* Global carbon budget 2021. **Earth System Science Data**, v. 14, n. 4, p. 1917-2005, 2022. DOI. <https://doi.org/10.5194/essd-2021-386>

FU, C.; LU, L.; PIRABI, M. Advancing green finance: a review of sustainable development. **Digital Economy and Sustainable Development**, v. 1, n. 1, p. 20, 2024. DOI. <https://doi.org/10.1007/s44265-023-00026-x>

FU, L.; ZHAO, Y.; XU, Z.; WU, B. Spatial and temporal dynamics of forest aboveground carbon stocks in response to climate and environmental changes. **Journal of Soils and Sediments**, v. 15, n. 2, p. 249-259, 2015. DOI. <http://dx.doi.org/10.1007/s11368-014-1050-x>

GAO, L.; ZHANG, X. Above-ground biomass estimation of plantation with complex forest stand structure using multiple features from airborne laser scanning point cloud data. **Forests**, v. 12, n. 12, p. 1713, 2021. DOI. <https://doi.org/10.3390/f12121713>

GIBBS, D. A.; ROSE, M.; GRASSI, G.; MELO, J.; ROSSI, S.; HEINRICH, V.; HARRIS, N.L. Revised and updated geospatial monitoring of twenty-first century forest carbon fluxes. **Earth System Science Data Discussions**, v. 2024, p. 1-42, 2024. DOI. <https://doi.org/10.5194/essd-2024-397>

GIONGO, M.; KOEHLER, H. S.; MACHADO, S. do. A.; KIRCHNER, F. F.; MARCHETTI, M. LiDAR: princípios e aplicações florestais. **Pesquisa Florestal Brasileira**, v. 30, n. 63, p. 231-244, 2010. DOI. <https://doi.org/10.4336/2010.pfb.30.63.231>

GONÇALVES, A. C. Modelling Biomass. In: **Forest Bioenergy: From Wood Production to Energy Use**. Cham: Springer International Publishing, 2024. p. 121-146.

GORGENS, E. B.; SILVA, A. G. P. da.; RODRIGUES, L. C. E. **Lidar: aplicações florestais**. Curitiba: Editora CRV, 2014. 132 p.

GULEV, S. K. *et al.* **Climate Change 2021: The Physical Science Basis**. Cambridge University Press, Cambridge, NY. p. 287-422.

GUO, Q. *et al.* **LiDAR Remote Sensing of Forest Ecosystems: Applications and Prospects**. In: Li, B., Shi, X., Zhu, AX., Wang, C., Lin, H. (eds). *New Thinking in GIScience*. Springer, Singapore. 2022.

HARRIS, N. L. *et al.* Global maps of twenty-first century forest carbon fluxes. **Nature Climate Change**, v. 11, n. 3, p. 234-240, 2021. DOI. <https://doi.org/10.1038/s41558-020-00976-6>

HIGA, R. C. V. *et al.* Protocolo de medição e estimativa de biomassa e carbono florestal. **Colombo: Embrapa Florestas**, v. 1, 2014.

HU, H. *et al.* An adaptive surface filter for airborne laser scanning point clouds by means of regularization and bending energy. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 92, p. 98-111, 2014. DOI. <https://doi.org/10.1016/j.isprsjprs.2014.02.014>

HUANG, S. *et al.* **Method Comparison and Method Calibration Applicable to Forest Measurements and Model Predictions**. Alberta Agriculture and Forestry, 2019. 132 p.

HUANG, R.; YAO, W.; XU, Z.; CAO, L.; SHEN, X. Information fusion approach for biomass estimation in a plateau mountainous forest using a synergistic system comprising UAS-based digital camera and LiDAR. **Computers and Electronics in Agriculture**, v. 202, p. 107420, 2022. DOI. <https://doi.org/10.1016/j.compag.2022.107420>

INDÚSTRIA BRASILEIRA DE ÁRVORES – IBÁ. **Relatório Anual IBÁ 2025**. São Paulo, 2024. Disponível em: <https://iba.org/wp-content/uploads/2025/10/relatorioAnual2025.pdf>. Acesso em: 8 out. 2025.

INSTITUTO DE PESQUISAS FLORESTAIS – IPEF. 19. **EUCFLUX – Fluxos de Carbono e Água em Eucalyptus**. Disponível em: <https://www.ipef.br/eucflux2/>. Acesso em: 25 jul. 2025.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE – IPCC. **Climate Change 2023: Synthesis Report**. Disponível em: https://www.ipcc.ch/report/ar6/syr/downloads/report/IPCC_AR6_SYR_FullVolume.pdf. Acesso em: 22 dez. 2023.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE – IPCC. **Climate Change 2021: The Physical Science Basis**. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Disponível em: <https://www.ipcc.ch/report/ar6/wg1/#FullReport>. Acesso em: 30 jul. 2022.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE – IPCC. **Climate Change 2013: The physical science basis: Working group I contribution to the fifth assessment report of the Intergovernmental Panel on Climate Change**. 2014. Disponível em: <https://www.ipcc.ch/report/ar5/wg1/>. Acesso em: 29 abr. 2022.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE – IPCC. **Contribución del Grupo de Trabajo III al Cuarto Informe de Evaluación del Grupo Intergubernamental de Expertos sobre Cambio Climático**. Technical summary. 2007. Disponível em: <http://www.ipcc.ch>. Acesso em: 29 abr. 2022.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE – IPCC. **2006 IPCC Guidelines for National Greenhouse Gases Inventories**. 2006. Disponível em: <https://www.ipcc-nggip.iges.or.jp/public/2006gl/>. Acesso em: 18 abr. 2022.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE – IPCC. **Climate change 2002: Synthesis report, contribution of working group I, II and III to the third assessment report of the IPCC** [Watson, R. T. and the Core Writing Team (eds.)]. Cambridge; New York: Cambridge University Press, 2001. 397 p.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres**. Tradução da 2ª ed. EPIPHANIO, J. C. N. (org.). São José dos Campos: Parêntese Editora, 672 p., 2009.

JIANG, X.; LI, D.; LI, G.; LU, D. Eucalyptus carbon stock estimation in subtropical regions with the modeling strategy of sample plots–airborne LiDAR–Landsat time series data. **Forest Ecosystems**, v. 10, p. 100149, 2023. DOI. <https://doi.org/10.1016/j.fecs.2023.100149>

KUÇAK, R.A.; BÜYÜKSALIH, I. Comparison of CSF Ground Filtering Method by Using Airborne LiDAR Data. **Advanced LiDAR**, v. 3, n. 2, p. 47-52, 2023. Disponível em: <https://publish.mersin.edu.tr/index.php/lidar/article/view/1058>. Acesso em: 02 jul. 2024.

KUHN, M. Building Predictive Models in R Using the caret Package. **Journal of Statistical Software**, v. 28, n. 5, p. 1–26, 2008. DOI. <https://doi.org/10.18637/jss.v028.i05>

LAWRENCE, I.; LIN, K. A concordance correlation coefficient to evaluate reproducibility. **Biometrics**, p. 255-268, 1989. DOI. <https://doi.org/10.2307/2532051>

- LI, Y.; LI, M.; LI, C.; LIU, Z. Forest aboveground biomass estimation using Landsat 8 and Sentinel-1A data with machine learning algorithms. **Scientific reports**, 2020, v. 10, n. 1, p. 9952, 2020. DOI. <https://doi.org/10.1038/s41598-020-67024-3>
- LI, Y.; WANG, R.; SHI, W.; YU, Q.; LI, X.; CHEN, X. Research on Accurate Estimation Method of *Eucalyptus* Biomass Based on Airborne LiDAR Data and Aerial Images. **Sustainability**, v. 14, n. 17, p. 10576, 2022. DOI. <https://doi.org/10.3390/su141710576>
- LIMA, M. D. R.; BARROS JUNIOR, U. O.; ASSIS, M. R.; MELO, I. C. N. A.; FIGUEIREDO, I. C. R.; PROTÁSIO, T. P.; TRUGILHO, P. F. Variabilidade das densidades básica e energética e estoque de carbono na madeira no fuste de clones de *Eucalyptus*. **Scientia Forestalis**, v. 48, n. 128, p. e3302, 2020. DOI. <https://doi.org/10.18671/sifor.v48n128.04>
- LIN, Y.; LI, H.; JING, L.; DING, H.; TIAN, S. Individual Tree Crown Delineation Using Airborne LiDAR Data and Aerial Imagery in the Taiga–Tundra Ecotone. **Remote Sensing**, v. 16, n. 21, p. 3920, 2024. DOI. <https://doi.org/10.3390/rs16213920>
- LIU, X.; WANG, R.; SHI, W.; WANG, X.; YANG, Y. Research on Estimation Model of Carbon Stock Based on Airborne LiDAR and Feature Screening. **Sustainability**, v. 16, n. 10, p. 4133, 2024. DOI. <https://doi.org/10.3390/su16104133>
- LIU, Y. *et al.* Individual Tree Aboveground Biomass Estimation Based on UAV Stereo Images in a *Eucalyptus* Plantation. **Forests**, v. 14, n. 9, p. 1748, 2023. DOI. <https://doi.org/10.3390/f14091748>
- LU, D. *et al.* A survey of remote sensing-based aboveground biomass estimation methods in forest ecosystems. **International Journal of Digital Earth**, v. 9, n. 1, p. 63–105, 2016. DOI. <https://doi.org/10.1080/17538947.2014.990526>
- MA, T.; *et al.* Development of forest aboveground biomass estimation, its problems and future solutions: A review. **Ecological Indicators**, v. 159, p. 111653, 2024. DOI. <https://doi.org/10.1016/j.ecolind.2024.111653>
- MA, K. *et al.* Performance and sensitivity of individual tree segmentation methods for UAV-LiDAR in multiple forest types. **Remote Sensing**, v. 14, n. 2, p. 298, 2022. DOI. <https://doi.org/10.3390/rs14020298>
- MARCHESAN, J. *et al.* Aboveground biomass estimation in a tropical forest with selective logging using *Random Forest* and LiDAR data. **Floresta**, v. 50, n. 4, 2020. DOI. 10.5380/rf.v50 i4. 66589
- MARTINI, A. J. Horto Florestal (atual FEENA) completa 100 anos. **Arquivo**. Rio Claro, v. 3, p. 13-16, 2009.
- McROBERTS, R.E.; NÆSSET, E.; GOBAKKEN, T. Optimizing the *k*-Nearest Neighbors technique for estimating forest aboveground biomass using airborne laser scanning data. **Remote Sensing of Environment**, v. 163, p. 13–22, 2015. DOI. <https://doi.org/10.1016/j.rse.2015.02.026>

MIELKE, P.W., Jr. **Meteorological applications of permutation techniques based on distance functions**. Handbook of Statistics, v. 4 (Krishnaiah P.R. and Sen, P.K., editors), pp. 813–830, Elsevier, Amsterdam, The Netherlands. 1984.

MOHAN, M. *et al.* Individual tree detection using UAV-lidar and UAV-SfM data: A tutorial for beginners. **Open Geosciences**, v. 13, n. 1, p. 1028-1039, 2021. DOI. <https://doi.org/10.1515/geo-2020-0290>

MORAES, A. P. P.; KOHLE, S.V.; VIEIRA, T.S.; LACERDA, F.da.C.B.; GOULART, S.L.; OLIVEIRA, X.M. de. Estimativa do estoque volumétrico e acúmulo de biomassa e carbono em uma floresta ombrófila densa na Floresta Nacional de Carajás. **Biodiversidade Brasileira**, v. 15, n. 1, p. 13-24, 2025. DOI. <https://doi.org/10.37002/biodiversidadebrasileira.v15i1.2655>

NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION – NOAA. **National Centers for Environmental information, Climate at a Glance: Global Time Series**. 2025. Disponível em: <https://www.ncei.noaa.gov/access/monitoring/climate-at-a-glance/global/time-series>. Acesso em: 17 jan. 2025.

NGUYEN, A.; SAHA, S. Machine Learning and Multi-source Remote Sensing in Forest Carbon Stock Estimation: A Review. **arXiv preprint arXiv**: v. 2411.17624, 2024.

NISHIWAKI, A. A. M. *et al.* Uso do LiDAR na Estimativa de Atributos Florestais: Uma Revisão. **Revista Brasileira de Geografia Física**, v.16, n. 1, p. 505-527, 2023.

OEHMCKE, S. *et al.* Deep learning based 3D point cloud regression for estimating forest biomass. **Proceedings of the 30th International Conference on Advances in Geographic Information Systems**, n. 38, p. 1-4, 2022. DOI. <https://doi.org/10.1145/3557915.3561471>

OLLILA, A. The greenhouse effect definition. **Physical Science International Journal**, v. 23, n. 2, p. 1-5, 2019. DOI. 10.9734/PSIJ/2019/v23i230149

OLEMBERG, D.; LUPI, A. M. Economic analysis of *Eucalyptus* biomass cultivation for energy in Argentina. **Cleaner and Circular Bioeconomy**, n. 8, p. 100085, 2024. DOI. <https://doi.org/10.1016/j.clcb.2024.100085>

OSCO, L.P. *et al.* The Segment Anything Model (SAM) for remote sensing applications: From zero to one shot. **International Journal of Applied Earth Observation and Geoinformation**, v. 124, p. 103540, 2023. DOI. <https://doi.org/10.1016/j.jag.2023.103540>

PACKALEN, P.; STRUNK, J.; MALTAMO, M.; MYLLYMÄKI, M. Circular or square plots in ALS-based forest inventories—does it matter?. **Forestry**, v. 96, n. 1, p. 49-61, 2023. DOI. <https://doi.org/10.1093/forestry/cpac032>

PERTILLE, C. T. *et al.* Biomass and Carbon of Eucalyptus spp. Genotypes Estimated With UAV-LIDAR Using Area-Based Approach and Machine Learning.

International Journal of Forestry Research, v. 2025, n. 1, p. 5516907, 2025. DOI. <https://doi.org/10.1155/ijfr/5516907>

PINEDO, L. E. *et al.* Estimation of height and aerial biomass in *Eucalyptus globulus* plantations using UAV-LiDAR. **Trees, Forests and People**, p. 100763, 2024. DOI. <https://doi.org/10.1016/j.tfp.2024.100763>

POLEY, L. G.; McDERMID, G. J. A systematic review of the factors influencing the estimation of vegetation aboveground biomass using unmanned aerial systems. **Remote Sensing**, v. 12, n. 7, p. 1052, 2020. DOI. <https://doi.org/10.3390/rs12071052>

PSISTAKI, K.; TSANTOPOULOS, G.; PASCHALIDOU, A. K. An Overview of the role of forests in climate change mitigation. **Sustainability**, v. 16, n. 14, p. 6089, 2024. DOI. <https://doi.org/10.3390/su16146089>

PUSSINEN, A.; KARJALAINEN, T.; MÄKIPÄÄ, R.; VALSTA, L.; KELLOMÄKI, R. Forest carbon sequestration and harvests in Scots pine stand under different climate and nitrogen deposition scenarios. **Forest Ecology and Management**, v. 158, n. 1-3, p. 103-115, 2002. DOI. [https://doi.org/10.1016/S0378-1127\(00\)00675-7](https://doi.org/10.1016/S0378-1127(00)00675-7)

R CORE TEAM. **R: A language and environment for statistical computing**. 2025 R Foundation for Statistical Computing, Vienna, Austria. Disponível em: <https://www.R-project.org>. Acesso em 04 jun. 2025.

RAKSHITHA, R. *et al.* Crack SAM: enhancing crack detection utilizing foundation models and Detectron2 architecture. **Journal of Infrastructure Preservation and Resilience**, v. 5, n. 1, p. 11, 2024. DOI. <https://doi.org/10.1186/s43065-024-00103-1>

RATUCHNE, L.C.; KOEHLER, H. S.; WATZLAWICK, L. F.; SANQUETTA, C. R.; SCHAMNE, P. A. Estado da arte na quantificação de biomassa em raízes de formações florestais. **Floresta e Ambiente**, v. 23, n. 3, p.450-462, 2016. DOI. <http://dx.doi.org/10.1590/2179-8087.131515>

RÉJOU-MÉCHAIN, M.; TANGUY, A.; PIPONIOT, C.; CHAVE, J.; HÉRAULT, B. Biomass: An R package for estimating above-ground biomass and its uncertainty in tropical forests. **Methods in Ecology and Evolution**, v. 8, n. 9, p.1163–1167, set. 2017. DOI. <https://doi.org/10.1111/2041-210X.12753>

RIBEIRO, F. P. *et al.* Individual Carbon Modeling in *Eucalyptus* Stands in the Cerrado Region. **Forests**, v. 15, n. 8, p. 1332, 2024. DOI. <https://doi.org/10.3390/f15081332>

ROBINSON, W. S. The statistical measurement of agreement. **American Sociological Review**, v. 22, n. 1, p. 17-25, 1957. DOI. <https://doi.org/10.2307/2088760>

RODRIGUES, G. S. de S. C.; ROSS, J.L.S.; TEIXEIRA, G.; SANTIAGO, O.R.P.L.; FRANCO, C. **Eucalipto no Brasil**: Expansão geográfica e impactos ambientais. Uberlândia: Composer, 2021. 178 p.

ROMERO, F. M. B.; JACOVINE, L. A. G.; RIBEIRO, S. C.; et al. Allometric Equations for Volume, Biomass, and Carbon in Commercial Stems Harvested in a Managed Forest in the Southwestern Amazon: A Case Study. **Forests**, v. 11, n. 8, p. 874, 2020. DOI. <https://doi.org/10.3390/f11080874>

ROUBUSTE, R. R.; VALCORTE, G.; BIANCHINI, N.H.; SOUZA, K.M.O.de. Mudanças climáticas e o mercado de carbono. **Iheringia, Série Botânica**, v. 77, e2022014, 2022. DOI. <https://doi.org/10.21826/2446-82312022v77e2022014>

ROUSSEL, J-R. *et al.* lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. **Remote Sensing of Environment**, v. 251, p. 112061, 2020. DOI. <https://doi.org/10.1016/j.rse.2020.112061>

RUIZ-VILLANUEVA, V.; PIÉGAY, H.; GURNELL, A. M.; MARSTON, R. A.; STOFFEL, M. Recent advances quantifying the large wood dynamics in river basins: New methods and remaining challenges. **Reviews of Geophysics**, v. 54, n. 3, p. 611-652, 2016. DOI. <https://doi.org/10.1002/2015RG000514>

SALUNKHE, O.; KHARE, P. K.; KUMARI, R.; KHAN, M. L. A systematic review on the aboveground biomass and carbon stocks of Indian forest ecosystems. **Ecological Processes**, v. 7, n. 1, p. 1-12, 2018. DOI. <https://doi.org/10.1186/s13717-018-0130-z>

SANQUETTA, C. R.; ROSÁRIO, P. H. C. K. do; CORTE, A. P. D.; SANQUETTA, C. M. I.; MAAS, G. C. B. Teores de carbono em diferentes tipos de papeis. **Enciclopédia Biosfera**, v.16, n. 29; p.1434-1440, 2019.

SANQUETTA, C. R.; ZILLOTTO, M. A. B.; CORTE, A. P. D. **Carbono: desenvolvimento tecnológico, aplicação e mercado global**. Curitiba: UFPR, 2006.

SANQUETTA, C. R. **Metodologia básica de determinação de carbono pela biomassa: atividades e ferramentas**. Sistema Integrado de Gestão Ambiental do Estado de São Paulo, SP: UFPR, 2004.

SANQUETTA, C. R. **Métodos de determinação de biomassa florestal**. In: SANQUETTA, C.R., WATZLAWICK, L.F., BALBINOT, R. As florestas e o carbono. Curitiba: Imprensa Universitária da UFPR. 2002.

SANTOS, K. F. dos.; SCHUMACHER, M.V.; LUDVICHAK, A.A.; ARAÚJO, E.F.de. Biomass and stock of nutrients in different genotypes of eucalypts in Southern Brazil. **Journal of Experimental Agriculture International**, 34, n. 4, p. 1-12, 2019.

SBARDELLA, M. **Capacidade de brotação e crescimento de espécies de *Eucalyptus* spp. em sistema de alto fuste e talhadia**. Dissertação (Mestrado em Ciência Florestal) – Faculdade de Ciências Agronômicas da UNESP, Universidade Estadual Paulista Júlio de Mesquita Filho, Botucatu, 2021. 74 p.

SCHÄFER, J. *et al.* Assessing the potential of synthetic and ex situ airborne laser scanning and ground plot data to train forest biomass models. **Forestry: An**

International Journal of Forest Research, p. cpad061, 2023. DOI.
<https://doi.org/10.1093/forestry/cpad061>

SCHMID, S.; THÜRIG, E.; KAUFMANN, E.; LISCHKE, H.; BUGMANN, H. Effect of forest management on future carbon pools and fluxes: a model comparison. **Forest Ecology and Management**, v. 237, p. 65-82, 2006. DOI.
<https://doi.org/10.1016/j.foreco.2006.09.028>

SEDJO, R. A. **Forest carbon sequestration**: some issues for forest investments. Discussion Paper, p. 1-34. Washington: Resources for the Future, ago. 2001.

SHAN, J.; TOTH, C. K. **Topographic laser ranging and scanning**: principles and processing. 2. ed. Boca Raton, FL: 13:978-1-4987-7227-3, 2018. v. 31.

SHAPIRO, S.S.; WILK, M. B. An analysis of variance test for normality (complete samples). **Biometrika**, London, v. 3/4, n. 52, p. 591-611, dez. 1965.

SHI, X.; WANG, T.; LU, S.; CHEN, K.; HE, D.; XU, Z. Evaluation of China's forest carbon sink service value. **Environmental Science and Pollution Research**, v. 29, p. 44668–44677, 2022. DOI. <https://doi.org/10.1007/s11356-022-18958-w>

SILVA, E. D. G. da.; ALVES, A. R.; HOLANDA, A.C.de.; BEZERRA, R.M.; MAGALHÃES, A.S. Biomassa e nutrientes na parte aérea de espécies arbóreas da Caatinga, Rio Grande do Norte. **Nativa**, v. 10, n. 1, p. 131-137, 2022. DOI.
<https://doi.org/10.31413/nativa.v10i1.13093>

SILVA, C. A.; VALBUENA, R.; PINAGÉ, E. R. *et al.* ForestGapR: an R package for forest gap analysis from canopy height models. **Methods in Ecology and Evolution**, v. 10, n. 8, p. 1347–1356, 2019.

SILVA, C.A.; KLAUBERG, C.; CARVALHO, S. de. P.C.C; PICCOLO, M. de. C.; RODRIGUEZ, L.C.E. Estoque de carbono na biomassa aérea florestal em plantações comerciais de *Eucalyptus* spp. **Scientia Forestalis**, v. 43, n. 105, p. 135-146, 2015.

SILVEIRA, P.; KOEHLER, H. S.; SANQUETTA, C. R.; ARCE, J. A. O Estado Da Arte Na Estimativa De Biomassa E Carbono Em Formações Florestais. **Floresta**, Curitiba, v. 38, n. 1, p. 185-206, 2008. DOI. <http://dx.doi.org/10.5380/rf.v38i1.11038>

SISTEMA DE ESTIMATIVA DE EMISSÕES DE GASES DE EFEITO ESTUFA – SEEG. **Análise das emissões brasileiras de Gases do Efeito Estufa e suas implicações para as metas climáticas do Brasil 1970 – 2023**. 2024. Disponível em: <https://seeg.eco.br/wp-content/uploads/2024/11/SEEG-RELATORIO-ANALITICO-12.pdf>. Acesso em: 18 dez. 2025.

SPARKS, A.M.; CORRAO, M.V.; SMITH, A.M.S. Cross-comparison of individual tree detection methods using low and high pulse density airborne laser scanning data. **Remote Sensing**, v. 14, n. 14, p. 3480, 2022. DOI.
<https://doi.org/10.3390/rs14143480>

SPARKS, A.M.; SMITH, A.M.S. Accuracy of a lidar-based individual tree detection and attribute measurement algorithm developed to inform forest products supply chain and resource management. **Forests**, v. 13, n. 1, p. 3, 2022. DOI. <https://doi.org/10.3390/f13010003>

STAPE, J. L. *et al.* The Brazil Eucalyptus Potential Productivity Project: Influence of water, nutrients and stand uniformity on wood production. **Forest Ecology and Management**, v. 259, n. 9, p. 1684-1694, 2010. DOI. <https://doi.org/10.1016/j.foreco.2010.01.012>

TORRE-TOJAL, L.; BASTARRIKA, A.; BOYANO, A.; LOPEZ-GUEDE, J.M.; GRAÑA, M. Above-ground biomass estimation from LiDAR data using *Random Forest* algorithms. **Journal of Computational Science**, v. 58, p. 101517, 2022. DOI. <https://doi.org/10.1016/j.jocs.2021.101517>

UNITED STATES FOREST SERVICE – USFS. **First Order Lidar Metrics: A supporting document for LiDAR deliverables**. U.S. Department of Agriculture, Forest Service, Pacific Northwest Research Station. 2014.

VENABLES, W. N.; RIPLEY, B. D. **Modern Applied Statistics**. Springer, New York: ISBN 0-387-95457-0. 2002.

WANG, C.; YANG, X.; XI, X.; NIE, S. DONG, P. Chapter 2: LiDAR Remote Sensing Principles. In: **Introduction to LiDAR Remote Sensing**. Taylor & Francis, 2024.

WHITE, J. C. *et al.* A best practices guide for generating forest inventory attributes from airborne laser scanning data using an area-based approach. **Canadian Forest Service**, Information Report FI-X-010. 2017.

XU, W. *et al.* Progress and Limitations in Forest Carbon Stock Estimation Using Remote Sensing Technologies: A Comprehensive Review. **Forests**, v. 16, n. 3, p. 449, 2025. DOI. <https://doi.org/10.3390/f16030449>

YAN, Y.; LEI, J.; HUANG, Y. Forest Aboveground Biomass Estimation Based on Unmanned Aerial Vehicle–Light Detection and Ranging and Machine Learning. **Sensors**, v. 24, n. 21, p. 7071, 2024a. DOI. <https://doi.org/10.3390/s24217071>

YAN, Y.; LEI, J.; JIN, J.; SHI, S.; HUANG, Y. Unmanned aerial vehicle–light detection and ranging-based individual tree segmentation in Eucalyptus spp. *Forests: Performance and sensitivity*. **Forests**, v. 15, n. 1, p. 209, 2024b. DOI. <https://doi.org/10.3390/f15010209>

YAO, Y.; PIAO, S.; WANG, T. Future biomass carbon sequestration capacity of Chinese forests. **Science Bulletin**, v. 63, n. 17, p. 1108-1117, 2018. DOI. <https://doi.org/10.1016/j.scib.2018.07.015>

YE, N. *et al.* Estimating individual tree DBH and biomass of durable Eucalyptus using UAV LiDAR. **Ecological Informatics**, p. 103169, 2025. DOI. <https://doi.org/10.1016/j.ecoinf.2025.103169>

YU, K. *et al.* Comparison of classical methods and mask R-CNN for automatic tree detection and mapping using UAV imagery. **Remote Sensing**, v. 14, n. 2, p. 295, 2022. DOI. <https://doi.org/10.3390/rs14020295>

ZHAO, H.; MORGENROTH, K.; PEARSE, G.; SCHINDLER, J. A systematic review of individual tree crown detection and delineation with convolutional neural networks (CNN). **Current Forestry Reports**, v. 9, n. 3, p. 149-170, 2023. DOI. <https://doi.org/10.1007/s40725-023-00184-3>

ZHAO, J.; LIU, D.; ZHU, Y.; PENG, H.; XIE, H. A review of forest carbon cycle models on spatiotemporal scales. **Journal of Cleaner Production**, v. 339, p. 130692, 2022. DOI. <https://doi.org/10.1016/j.jclepro.2022.130692>

ZHANG, Y.; KONZ, N.; KRAMER, K.; MAZUROWSKI, M.A. Quantifying the Limits of Segmentation Foundation Models: Modeling Challenges in Segmenting Tree-Like and Low-Contrast Objects. **ArXiv**, p. 2412.04243, 2024. DOI. <https://doi.org/10.48550/arXiv.2412.04243>


ZHANG, Y.; LIU, J. Estimating forest aboveground biomass using temporal features extracted from multiple satellite data products and ensemble machine learning algorithm. **Geocarto International**, v. 38, n. 1, p. 2153930, 2023. <https://doi.org/10.1080/10106049.2022.2153930>


ZHANG, Y.; MA, J.; LIANG, S.; LI, X.; LIU, J. A stacking ensemble algorithm for improving the biases of forest aboveground biomass estimations from multiple remotely sensed datasets. **GIScience & Remote Sensing**, v. 59, n. 1, p. 234–249, 2022. DOI. <https://doi.org/10.1080/15481603.2021.2023842>

ZHOU, M.; LI, C.; LI, Z. Extraction of individual tree attributes using ultra-high-density point clouds acquired by low-cost UAV-LiDAR in Eucalyptus plantations. **Annals of Forest Science**, v. 82, n. 1, p. 20, 2025. DOI. <https://doi.org/10.1186/s13595-025-01291-w>

ANEXO 1

ANEXO 1 – ABORDAGEM A NÍVEL DE ÁREA: ESPACIALIZAÇÃO DA BIOMASSA ACIMA DO SOLO ($t \cdot ha^{-1}$) (A-E) E DO CARBONO ACIMA DO SOLO ($t \cdot ha^{-1}$) (F-J) NOS BLOCOS 2, 4, 7, 8 E 10 COM ML





Em que: ANN: Artificial Neural Networks; kNN: *k*-Nearest Neighbor; RF: Random Forest; SVR: Support Vector Regression; XGBoost: Extreme Gradient Boosting.