

**Universidade do Estado de Santa Catarina – UDESC**  
**Centro de Ciências Agroveterinárias – CAV**  
**Programa de Pós-Graduação em Engenharia Florestal – PPGEF**

**Ada Kauara Cantini Barbosa**

**Estimativa da biomassa acima do solo em um fragmento de Floresta Ombrófila Mista  
Alto-Montana usando dados Lidar aerotransportado**

**Lages/SC 2024**

**Ada Kauara Cantini Barbosa**

**Estimativa da biomassa acima do solo em um fragmento de Floresta Ombrófila Mista  
Alto-Montana usando dados Lidar aerotransportado**

Dissertação apresentada ao programa de Pós-Graduação em Engenharia Florestal, do Centro de Ciências Agroveterinárias da Universidade do Estado de Santa Catarina, como requisito parcial para obtenção do título de Mestre em Engenharia Florestal.

Orientador: Dr. Marcos Benedito Schimalski

**Lages/SC 2024**

**Ada Kauara Cantini Barbosa**

**Estimativa da biomassa acima do solo em um fragmento de Floresta Ombrófila Mista  
Alto-Montana usando dados Lidar aerotransportado**

Dissertação apresentada ao programa de Pós-Graduação em Engenharia Florestal, do Centro de Ciências Agroveterinárias da Universidade do Estado de Santa Catarina, como requisito parcial para obtenção do título de Mestre em Engenharia Florestal.

**BANCA EXAMINADORA**

**Orientador:**\_\_\_\_\_

Profº: Dr. Marcos Benedito Schimalski

Universidade do Estado de Santa Catarina – UDESC

**Membro:**\_\_\_\_\_

Dr. (a) Camile Sothe

Planet Labs

**Membro:**\_\_\_\_\_

Profº: Dr. Marcos Felipe Nicoletti

Universidade do Estado de Santa Catarina – UDESC

**Lages, 28 de novembro de 2024**

Dedico a minha família, aos amigos e aos colegas por todo apoio nesta caminhada.

## AGRADECIMENTOS

Gostaria de agradecer a Deus por estar presente na minha vida diariamente, ao meu noivo Adam por estar comigo todos esses anos, me apoiando nas minhas loucuras, a minha filha/prima Alice que me ensino o que é paciência, pois lidar como uma pessoa parecida com você não é fácil, a minha filhotinha Ada Louise que me ensino o que é amor, é dela que tiro forças para não desistir e continuar a lutar todos os dias, ao meu *dog* Rebeca que me faz companhia quando estou lidando com as coisa dissertação.

Gostaria de agradecer ao meu orientador Prof<sup>o</sup> Dr. Schimalski por compartilhar um pouco do seu vasto conhecimento em Sensoriamento Remoto e Geoprocessamento, pela paciência de explicar e reexplicar muitas vezes o mesmo assunto, pois ainda me considero leiga frente a tanto conhecimento. Obrigada por me mostrar uma nova paixão além dos tubos de ensaios do laboratório.

Gostaria de agradecer a UDESC pela bolsa PROMOP (programa de monitoria de pós-graduação). Agradecer novamente a UDESC e Sec. de Est. da Agricultura, da Pesca e do Desenvolvimento Rural – SC, pela bolsa de Pesquisa disponibilizada pelo projeto: Inventário florestal para espacializar os maciços florestais comerciais do Estado.

Gostaria de agradecer a todos os bolsistas de iniciação científica do laboratório de Geoprocessamento pela troca de conhecimento. Aos meus colegas de mestrado pela troca de conhecimento e ajuda nos momentos de dificuldade. A todos os Professores que contribuíram durante a minha caminhada dentro do Programa de Pós-Graduação em Engenharia Florestal do CAV.

## RESUMO

A Floresta Mata Atlântica é um bioma fragmentado devido a urbanização, industrialização e as práticas agrícolas. Faz necessário reconhecer o papel fundamental das florestas na regulação do clima global, especialmente em relação à absorção e retenção de carbono, que tem impacto direto nas mudanças climáticas. As metodologias tradicionais para estimativa de biomassa, variável que é diretamente relacionada a quantidade de carbono florestal, são tornam onerosas quando aplicadas a grandes áreas. Uma alternativa para tais estimativas é o uso de dados remotamente situados, que estão se tornando cada vez mais populares. Neste estudo, analisa-se a aplicação do Lidar aerotransportado, que devido à capacidade do *laser* emitido pelo sensor de penetrar no dossel florestal, possibilita a obtenção de informações sobre a estrutura vertical da floresta e do relevo. A área de estudo é a RPPN (Reserva Particular do Patrimônio Natural) Complexo Serra da Farofa, onde foram instaladas de forma aleatória 7 parcelas de 200 m<sup>2</sup> cada, contemplando diferentes locais e altitudes da fazenda em 2019. Nessas parcelas, foi realizado um inventário florestal e realizou-se o sobrevoo com o sensor Lidar no mesmo ano. Foram gerados catorze polígonos retangulares, sendo sete de 200m<sup>2</sup> e sete de 800m<sup>2</sup> para recortar a nuvem de pontos Lidar, referente a localização da parcelas na área de estudos. Foram gerados os modelos digitais: DTM, DSM, CHM e nDSM. O nDSM foi usado para extração das métricas de altura dos dados Lidar. Foi testada a correlação de Pearson para as métricas obtida do Lidar com biomassa acima do solo fornecida pelo inventário florestal. As métricas **zpcum5** e **zentropy** para parcela de 200m<sup>2</sup> apresentou uma correlação de 0,82 e 0,74 respectivamente, para a parcela de 800m<sup>2</sup> o **zpcum3** apresentou uma correlação de 0,93. Utilizou-se a regressão *Stepwise*, com três abordagens *Forward*, *Backward* e o *Both* (bidirecional), para selecionar as variáveis mais significativas no modelo. O modelo *Both* forneceu para o polígono de 200m<sup>2</sup> um modelo de regressão linear múltipla com um R<sup>2</sup> de 0,996, RMSE de 12,73 t/ha. Para o polígono de parcela de 800m<sup>2</sup> o modelo fornecido foi de regressão simples com um R<sup>2</sup> de 0,934, RMSE de 51,4 t/ha. Esses resultados destacam a eficiência das métricas extraídas do Lidar na previsão da biomassa acima do solo e contribuem para o aprimoramento de estudos de monitoramento florestal.

**Palavras chaves:** regressão linear; ALS; floresta nativa.

## ABSTRACT

The Atlantic Forest is a fragmented biome due to urbanization, industrialization, and agricultural practices. It is necessary to recognize the fundamental role of forests in regulating the global climate, especially concerning carbon absorption and retention, which has a direct impact on climate change. Traditional methodologies for biomass estimation, a variable directly related to the amount of forest carbon, become costly when applied to large areas. An alternative for such estimations is the use of remotely situated data, which is becoming increasingly popular. In this study, the application of airborne Lidar was analyzed, which, due to the ability of the laser emitted by the sensor to penetrate the forest canopy, enables the acquisition of information about the vertical structure of the forest and the terrain. The study area is the RPPN (Private Natural Heritage Reserve) Complex Serra da Farofa, where seven 200 m<sup>2</sup> plots were randomly installed, covering different locations and altitudes of the farm in 2019. In these plots, a forest inventory was carried out, and a flight with the Lidar sensor was performed in the same year. Fourteen rectangular polygons were generated, seven of 200m<sup>2</sup> and seven of 800m<sup>2</sup>, to cut the Lidar point cloud, referring to the location of the plots in the study area. The digital models DTM, DSM, CHM, and nDSM were generated. The nDSM was used to extract the height metrics from the Lidar data. Pearson correlation was tested for the metrics obtained from Lidar with above-ground biomass provided by the forest inventory. The metrics zpcum5 and zentropy for the 200m<sup>2</sup> plot showed a correlation of 0.82 and 0.74, respectively, while for the 800m<sup>2</sup> plot, the zpcum3 showed a correlation of 0.93. Stepwise regression was used, with three approaches: Forward, Backward, and Both (bidirectional), to select the most significant variables in the model. The Both model was chosen for presenting a p-value of 0.0078 for the 200m<sup>2</sup> plot and 0.0202 for the 800m<sup>2</sup> plot. The 200m<sup>2</sup> plot obtained a multiple linear regression model with an R<sup>2</sup> of 0.996 and an RMSE of 12.73 t/ha. For the 800m<sup>2</sup> plot, the provided model was a simple regression with an R<sup>2</sup> of 0.934 and an RMSE of 51.4 t/ha. These results highlight the efficiency of the metrics extracted from Lidar in predicting above-ground biomass and contribute to the improvement of forest monitoring studies.

**Keywords:** linear regression; ALS; native forest.

## LISTA DE ILUSTRAÇÕES

Figura 1. Representação dos reservatórios de biomassa florestal. Em que A- biomassa acima do solo; B- biomassa abaixo do solo; C- serapilheira; D- necromassa.....	17
Figura 2. Uma representação da nuvem de pontos do Lidar. Em que A- nuvem de pontos da nuvem do Lidar; B- árvores isoladas. ....	20
Figura 3. O processo de varredura a laser aerotransportado. ....	21
Figura 4. Digital Terrain Model (tile aleatório da área de estudos).....	23
Figura 5. Digital Surface Model (tile aleatório da área de estudos). ....	24
Figura 6. Canopy Height Model (tile aleatório da área de estudos). ....	25
Figura 7. Localização da RPPN Complexo Serra da Farofa. Em que A- América do Sul; B- Santa Catarina; C- municípios que contemplam a RPPN; D- área de estudo. ....	26
Figura 8. Localização das parcelas de inventario florestal e recobrimento aéreo na área de estudo. ....	27
Figura 9. Representação dos polígonos de 200m <sup>2</sup> e 800m <sup>2</sup> .....	30
Figura 10. Orientação dos polígonos em N-S e L-O. Em que: A- orientação N-S; B- orientação L-O.....	30
Figura 11. Representação do polígono de 200m <sup>2</sup> , referente a parcela 1. Em que: A- Google Earth; B- Nuvem de pontos; C- DTM; D- DSM; E- CHM.....	31
Figura 12. CHM da área de estudo. ....	36
Figura 13. Resultado do melhor modelo para estimar AGB para os polígonos de 200m <sup>2</sup> , regressão linear múltipla usando as métricas Lidar zpcum5 e zentropy. ....	39
Figura 14. Resultado do melhor modelo para estimar AGB para os polígonos de 800m <sup>2</sup> , regressão linear simples usando a métrica Lidar zpcum3. ....	40
Figura 15. Comparativo da AGB obtido pelo inventário florestal, com os modelos de regressão gerado RLM e RLS (t/ha). Em que: RLM- regressão linear múltipla; RLS- regressão linear simples.....	41
Figura 16. Gráficos de resíduos da AGB observada versus AGB estimada. Em que: A- regressão linear múltipla; B- regressão linear simples. ....	41
Figura 17. Espacialização AGB (t/ha). Em que A- usou-se regressão linear múltipla especificada na Figura 13; B- usou-se a regressão linear simples especificada na Figura 14. ....	42
Figura 18. Representação do polígono de 200m <sup>2</sup> , referente a parcela 2. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.....	57

Figura 19. Representação do polígono de 200m <sup>2</sup> , referente a parcela 3. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.....	57
Figura 20. Representação do polígono de 200m <sup>2</sup> , referente a parcela 5. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.....	58
Figura 21. Representação do polígono de 200m <sup>2</sup> , referente a parcela 6. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.....	58
Figura 22. Representação do polígono de 200m <sup>2</sup> , referente a parcela 7. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.....	59
Figura 23. Representação do polígono de 200m <sup>2</sup> , referente a parcela 8. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.....	59
Figura 24. Representação do polígono de 800m <sup>2</sup> , referente a parcela 1. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.....	60
Figura 25. Representação do polígono de 800m <sup>2</sup> , referente a parcela 2. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.....	60
Figura 26. Representação do polígono de 800m <sup>2</sup> , referente a parcela 3. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.....	61
Figura 27. Representação do polígono de 800m <sup>2</sup> , referente a parcela 5. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.....	61
Figura 28. Representação do polígono de 800m <sup>2</sup> , referente a parcela 6. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.....	62
Figura 29. Representação do polígono de 800m <sup>2</sup> , referente a parcela 7. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.....	62
Figura 30. Representação do polígono de 800m <sup>2</sup> , referente a parcela 7. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.....	63
Figura 31. Métricas usados nas regressões. Em que A- zentropy; B- zpcum3; C- zpcum5 ....	64
Figura 32. Modelo para regressão linear múltipla. ....	65
Figura 33. Modelo de regressão simples. ....	66

## LISTA DE TABELAS

Tabela 1. Aplicações florestais para dados Lidar. ....	21
Tabela 2. Características do recobrimento aéreo e do equipamento Lidar utilizado. ....	27
Tabela 3. Modelos ajustados para volume e altura, para a área de estudo. ....	28
Tabela 4. Modelos ajustados para o cálculo da AGB. ....	29
Tabela 5. Métrica extraídas do nDSM. ....	31
Tabela 6. Parâmetros de Correlação de Pearson (r). ....	32
Tabela 7. Comparativos das alturas das árvores obtidas pelos modelos hipsométricos e das métricas derivada do Lidar (m). ....	35
Tabela 8. Métricas Lidar do polígono de 200m <sup>2</sup> . ....	37
Tabela 9. Métricas Lidar do polígono de 800m <sup>2</sup> . ....	38
Tabela 10. Validação dos modelos de regressão (t/ha). ....	42
Tabela 11. Teste de Shapiro-Wilk ....	67
Tabela 12. Resultado do Summary ....	67
Tabela 13. Teste de Durbin-Watson. ....	67
Tabela 14. Teste de Breusch-Pagan. ....	68
Tabela 15. Multicolinearidade da egressão linear múltipla. ....	68

## LISTA DE ABREVIATURAS E SIGLAS

AGB - *Above Ground Biomass*

ALS - *Airborne Laser Scanner*

ANOVA - Análise de variância

BIAS – “viés”

CHM - *Canopy Height Model*

DAP - Diâmetro à Altura do Peito

DSM – *Digital Surface Model*

DTM - *Digital Terrain Model*

GNSS - *Global Navigation Satellite System*

Lidar - *Light Detection and Ranging*

nDSM - *nomalized Digital Surface Models*

REDD+ - *Reducing Emissions from Deforestation and Forest Degradation*

RLM – Regressão linear simples

RLS – Regressão linear múltipla

RMSE – Raiz do erro médio quadrático

RPPN - Reserva Particular do Patrimônio Natural

R<sup>2</sup> - Coeficiente de determinação

## SUMÁRIO

1. INTRODUÇÃO .....	14
2. HIPÓTESE .....	16
3. OBEJTIVO .....	16
3.1 Objetivo geral.....	16
3.2 Objetivos específicos.....	16
4. REVISÃO DE LITERATURA.....	16
4.1 Biomassa.....	16
4.2 Estimativa da biomassa .....	18
4.3 Lidar .....	19
4.4 Modelos digitais .....	22
4.4.1 <i>Digital Terrain Model</i> .....	23
4.4.2 <i>Digital Surface Model</i> .....	23
4.4.3 <i>Canopy Height Model</i> .....	24
5. METODOLOGIA .....	25
5.1 Área de estudo.....	25
5.2 Obtenção dos dados.....	26
5.2.1 Inventário Florestal.....	26
5.2.2 Lidar .....	27
5.3 Processamento dos dados .....	28
5.3.1 Inventário Florestal.....	28
5.3.2 Dados Lidar .....	29
5.3.3 Modelos para estimativa de biomassa .....	32
5.3.4 Avaliação estatísticas.....	33
6. RESULTADOS .....	35
7. DISCUSSÃO .....	43

8. CONCLUSÕES .....	46
9. REFERÊNCIA BIBLIOGRÁFICA .....	47
10. APÊNDICES .....	57

## 1. INTRODUÇÃO

As florestas desempenham um papel crucial na regulação do estoque de carbono, pois retêm uma quantidade significativa desse elemento em seus componentes aéreos e no solo (PAN *et al.*, 2011). Nesse contexto, as degradações florestais acarretam problemas ambientais, sociais e econômicos, especialmente em países em desenvolvimento (SIMULA; MANSUR, 2011). Entre os biomas brasileiros, a Mata Atlântica foi o que mais sofreu com a supressão da vegetação, devido à intensa urbanização, industrialização e atividades agrícolas em sua área de ocorrência (SCARANO; CEOTTO, 2015).

A vegetação florestal é responsável por sequestrar o dióxido de carbono (CO<sub>2</sub>) por meio da fotossíntese, armazenando-o em sua biomassa. Assim, atua como sumidouro de carbono, desempenhando papel relevante no ciclo desse elemento (AHMAD *et al.*, 2024). A biomassa florestal é um indicador tanto para avaliar o funcionamento dos ecossistemas terrestres quanto para analisar os sumidouros de carbono florestal (GAO E ZHANG, 2021). A vegetação florestal também pode se tornar fonte de carbono, ou seja, liberar mais dióxido de carbono para a atmosfera do que consegue sequestrar, quando destruída ou afetada por fenômenos naturais como incêndios (IPCC, 2021). Uma estimativa precisa da biomassa florestal é fundamental para calcular o armazenamento de carbono nas florestas, subsidiando a gestão sustentável dos recursos florestais (SCHWAAB *et al.*, 2020).

A biomassa compreende toda matéria de origem biológica (matéria orgânica), viva ou morta, de origem animal ou vegetal (CARDOSO; PARRON; FRANCISCON, 2015). Nos ecossistemas florestais, ela pode ser classificada em quatro reservatórios principais: biomassa acima do solo (*Above Ground Biomass* - AGB), biomassa abaixo do solo, serapilheira e a necromassa (BIRDSEY, 2006). A AGB inclui troncos, galhos, sementes, folhas, arbustos, gramíneas e vegetação rasteira (CARDOSO; PARRON; FRANCISCON, 2015).

Neste contexto, a avaliação e o mapeamento da AGB são indispensáveis para estimar o armazenamento de carbono, contabilizar os potenciais bioenergéticos e os riscos associados na destruição da AGB, já que áreas que armazenam mais AGB poderão ter impacto no aquecimento global caso sejam destruídas. Além disso, essas análises permitem monitorar as respostas dos ecossistemas às mudanças climáticas e distúrbios globais (NI-MEISTER *et al.* 2010; JIMÉNEZ *et al.*, 2017; ZENG *et al.*, 2022). As estimativas e mapeamentos também contribuem para a formulação de políticas públicas como o REDD+ (*Reducing Emissions from Deforestation and Forest Degradation* - Redução de Emissões por Desmatamento e

Degradação Florestal), que promovem a conservação florestal e a redução das emissões de carbono (FRY, 2008).

Diversos estudos abordaram a biomassa e o carbono estocado em diferentes biomas brasileiros. Na Mata Atlântica, destacam-se os trabalhos de Caldeira *et al.* (2004) e Santos *et al.* (2006); no Cerrado, de Delitti *et al.* (2001), Rezende *et al.* (2006) e Sallis *et al.* (2006); e na Amazônia, de Chambers *et al.* (2001) e Higuchi *et al.* (2004)

A AGB pode ser estimada por métodos alométricos que utilizam variáveis como o diâmetro à altura do peito (DAP) e a altura total ou comercial dos indivíduos (FONTOURA *et al.*, 2017). Métodos diretos, com amostragem destrutiva do indivíduo, demandam o corte, separação e pesagem de toda a biomassa, sendo precisos, mas custosos e prejudiciais a vegetação nativa ou comercial (FONTOURA *et al.*, 2017). Apesar de sua elevada precisão, a metodologia tradicional apresenta alta complexidade para estimativa da AGB (AHMAD *et al.*, 2023), demandando alternativas inovadoras.

A utilização de dados obtidos por sensoriamento remoto tem se mostrado promissora para estimar biomassa e carbono, especialmente em grandes áreas, onde medições de campo são caras e inviáveis (JIMÉNEZ *et al.*, 2017). Com o avanço tecnológico, o sensoriamento remoto superou limitações dos métodos tradicionais, como a baixa escala, abordagens destrutivas e falta de continuidade espacial. (BEAUDOIN *et al.*, 2016).

No sensoriamento remoto, é possível empregar dados de sensores passivos, como imagens ópticas, e de sensores ativos, como o Radar (*Radio Detection and Ranging*) e o LiDAR (*Light Detection and Ranging*), para estimar a AGB. Sensores passivos, no entanto, enfrentam limitações em áreas florestais densas, pois a radiação eletromagnética é absorvida ou refletida pela camada superior do dossel, dificultando a coleta de informações da estrutura vertical da vegetação (GAO; ZHANG, 2021). Já os sensores ativos, como o Radar, dependendo do comprimento de onda, conseguem penetrar o dossel, coletando informações tridimensionais da vegetação, embora possam ser influenciados pela topografia e saturação do sinal (LAY *et al.*, 2019).

O Lidar por sua vez, fornece informações detalhadas da estrutura vertical da floresta, incluindo altura das árvores e densidade do dossel, ao medir o tempo de retorno de pulsos de laser emitidos sobre a vegetação e refletidos para o sensor a partir das folhas, galhos e solo. Essa tecnologia permite criar modelos tridimensionais precisos da vegetação (LIU *et al.*, 2017; PILLODAR *et al.*, 2017).

Diante disso, o presente estudo concentra-se na aplicação do Lidar como uma ferramenta não invasiva para estimar a AGB em um fragmento de Floresta Ombrófila Mista Alto Montana. Essa formação florestal é sensível às mudanças climáticas, devido a sua especificidade, adaptadas a condições de altitude, temperatura e padrões de chuvas, tornando-as vulneráveis a perturbações climáticas. A capacidade do Lidar de fornecer dados precisos da estrutura vertical propõe não apenas aperfeiçoar a estimativa da AGB, mas também contribuir para o manejo sustentável deste ecossistema.

## **2. HIPÓTESE**

- Os dados obtidos por Lidar aerotransportado para a estimativa da AGB em um fragmento florestal apresentam correlação significativa com os dados de campo.
- A espacialização da biomassa florestal permitirá uma representação espacial detalhada da distribuição da biomassa no fragmento florestal estudado.

## **3. OBEJTIVO**

### **3.1 Objetivo geral**

Estimar a AGB utilizando dados Lidar aerotransportado e diferentes modelos de regressão linear em um fragmento da Floresta Ombrófila Mista Alto-Montana, considerando dois tamanhos de polígonos retangulares de 200 m<sup>2</sup> e 800 m<sup>2</sup>.

### **3.2 Objetivos específicos**

- Extrair o *Canopy Height Model* (CHM);
- Extrair métricas derivadas dos dados Lidar;
- Verificar correlação entre as diferentes métricas Lidar e AGB;
- Desenvolver modelos para a estimação da biomassa;
- Determinar o melhor modelo para o cálculo da biomassa para a área de estudo com base nos dados de inventário florestal;
- Espacializar a biomassa florestal usando o modelo escolhido.

## **4. REVISÃO DE LITERATURA**

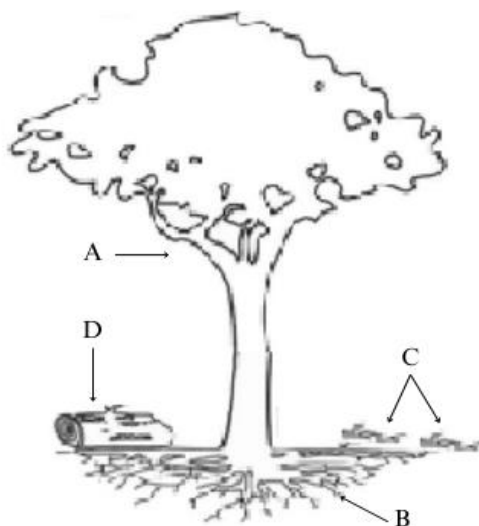
### **4.1 Biomassa**

A biomassa florestal representa um importante indicador da saúde e funcionalidade dos ecossistemas terrestres, sendo composta por diferentes compartimentos que desempenham papéis cruciais nos ciclos biogeoquímicos e no armazenamento de carbono (HIGA *et al.*, 2014).

Segundo Watzlawick *et al.* (2021), o conceito de biomassa florestal pode englobar tanto a totalidade da biomassa presente no ecossistema florestal quanto suas frações específicas, como a fitomassa arbórea, que se refere apenas à porção arbórea da vegetação. Essa distinção permite análises mais direcionadas sobre as interações ecológicas e os serviços ambientais das florestas.

A compreensão detalhada dessas frações é fundamental para o desenvolvimento de modelos precisos de estimativa de biomassa e para a elaboração de estratégias de manejo sustentável e mitigação de impactos climáticos (HIGA *et al.*, 2014). A Figura 1, adaptada de Malhi *et al.* (2009), ilustra a distribuição da biomassa florestal nos diferentes compartimentos, destacando suas interconexões e relevância.

Figura 1. Representação dos reservatórios de biomassa florestal. Em que A- biomassa acima do solo; B- biomassa abaixo do solo; C- serapilheira; D- necromassa.



Fonte: adapto de Malhi *et al.* (2009).

A AGB inclui componentes como troncos, galhos, sementes, folhas, arbustos, gramíneas e a vegetação rasteira, sendo frequentemente utilizada para estimativas de carbono armazenado em florestas. Por outro lado, a biomassa abaixo do solo abrange o sistema radicular como todo, exceto as raízes muito finas com o diâmetro inferior a 2mm (CARDOSO; PARRON; FRANCISCON, 2015). A serapilheira é composta por galhos com o diâmetro inferior a 2 cm, folhas, flores e frutos. Sendo que este material pode variar quanto a sua diversidade e quantidade de acordo com época do ano (CARDOSO; PARRON; FRANCISCON, 2015).

A necromassa consiste em todo material lenhoso de diversos tamanhos e tipos, como por exemplo: toras, nós, galhos grandes, raízes grossas e pedaços grandes de madeira (NEWTON, 2007), ou seja, é aquele material que não faz parte da serapilheira, porém está caído

no chão da floresta, contemplando também material pendurado em árvores ou árvores mortas que ainda estão em pé, com o diâmetro maior que 2cm (CARDOSO; PARRON; FRANCISCON, 2015).

## 4.2 Estimativa da biomassa

A quantificação da biomassa florestal é essencial para subsidiar decisões dos gestores relacionadas ao uso sustentável das áreas florestais (HE *et al.*, 2013). Essas estimativas são fundamentais para a formulação de políticas públicas que visam mitigar as emissões de carbono provenientes da supressão e degradação florestal. Além disso, contribuem para a conservação, o manejo sustentável das florestas e o aumento dos estoques de carbono florestal (CAMPBELL, 2009).

A AGB é uma variável ecológica de grande relevância, sendo sua estimativa essencial para reduzir incertezas nas projeções do balanço de carbono florestal e compreender possíveis variações no sistema climático (SRINIVASAN *et al.*, 2014). Aproximadamente metade da biomassa florestal é composta de carbono, despertando interesse científico na compreensão do ciclo do carbono (HOUGHTON *et al.*, 2009; ZOLKOS *et al.*, 2013).

A AGB pode ser estimada por meio de métodos diretos ou indiretos. Os métodos indiretos utilizam relações quantitativas ou modelos matemáticos, como razões ou regressões, mas ainda demandam medições de variáveis em campo, como o diâmetro à altura do peito e altura das árvores. Já os métodos diretos consistem na coleta e análise direta do material, como a pesagem integral de um tronco para determinar a biomassa (WATZLAWICK *et al.*, 2021). Embora as medições convencionais em campo forneçam resultados precisos, apresentam limitações em termos de cobertura espacial (ENE *et al.*, 2013; WU *et al.*, 2016).

O uso do sensoriamento remoto é uma alternativa viável para mapeamento da biomassa e do estoque de carbono florestal de maneira rápida e econômica (GIBBS *et al.*, 2007). Sensores como o Lidar destacam-se por sua capacidade de penetrar no dossel da floresta (LEFSKY *et al.*, 2002) e fornecer medidas diretas da vegetação, como a altura do dossel (POPESCU *et al.*, 2011), fortemente correlacionada à AGB. Contudo, a calibração e a validação com medições de inventário de campo permanecem indispensáveis para garantir a confiabilidade das estimativas (GOETZ; DUBAYAH, 2011).

A simplicidade e a clareza dos modelos lineares são vantagens dessa metodologia (GARCIA-GUTIERREZ *et al.*, 2014), especialmente quando a relação entre AGB e métricas extraídas de dados Lidar é quase linear (MUAYA *et al.*, 2015). Por outro lado, metodologias

não-paramétricas apresentam uma alternativa eficiente para modelagem e predição, dispensando em suposições sobre a distribuição dos dados (PACKALÉN; MALTAMO, 2007).

A mensuração direta da biomassa das árvores é mais trabalhosa e custosa em comparação com outras variáveis dendrométricas, como diâmetro à altura do peito (DAP) e a altura. Por isso, os modelos frequentemente utilizados empregam correlação com essas medidas, permitindo a estimativa da biomassa a partir de variáveis obtidas em inventários florestais tradicionais. Essa abordagem facilita inventários de biomassa em larga escala, reduzindo custos operacionais (BEHLING, 2016).

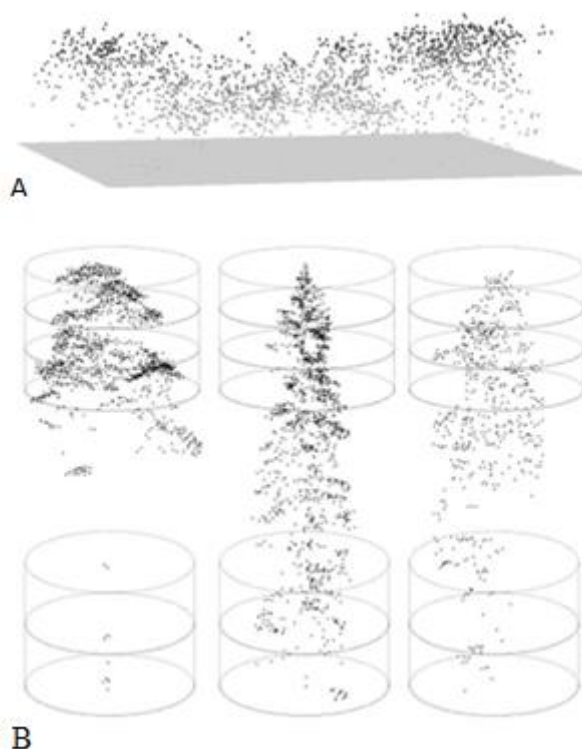
### 4.3 Lidar

O Lidar é um sensor ativo, pois não depende de fontes externas de energia, como a luz solar. O sensor emite sua própria radiação eletromagnética, utilizando feixes de *laser* no comprimento de onda do infravermelho próximo para medir a distância do sensor e o alvo (GIONGO *et al.*, 2010; MELIN; SHAPIRO; GLOVER-KAPFER, 2017).

Os feixes de *laser* possuem características como monocromaticidade, alta intensidade, direção e coerência (BAGNATO, 2001). A coerência é particularmente relevante, pois indica que todos os raios de luz possuem o mesmo comprimento de onda e estão perfeitamente alinhados. Essa propriedade permite a concentração de energia em pontos específicos, proporcionando alta precisão e maior alcance do *laser* (BRANDALIZE; PHILIPS, 2002).

Após a emissão do pulso, ele é direcionado por espelhos de varredura composto por um conjunto de lentes e espelhos ópticos, que direcionam os pulsos em direção aos alvos/objetos no terreno e posteriormente, recebem os sinais de retorno que são direcionados ao receptor (GIONGO *et al.*, 2010). Os sinais de retorno, refletidos pelos objetos, são captados pelo receptor. A intensidade do pulso retornado indica a natureza do alvo, sendo maior quando superfícies sólidas são atingidas (MELIN; SHAPIRO; GLOVER-KAPFER, 2017). Cada pulso pode gerar múltiplos retornos, registrando diferentes camadas da paisagem, o que resulta em uma nuvem de pontos tridimensional que detalha o terreno, os objetos e a cobertura vegetal (MELIN; SHAPIRO; GLOVER-KAPFER, 2017). Na Figura 2 demonstra a nuvem de pontos lidar e a algumas árvores individuais.

Figura 2. Uma representação da nuvem de pontos do Lidar. Em que A- nuvem de pontos da nuvem do Lidar; B- árvores isoladas.

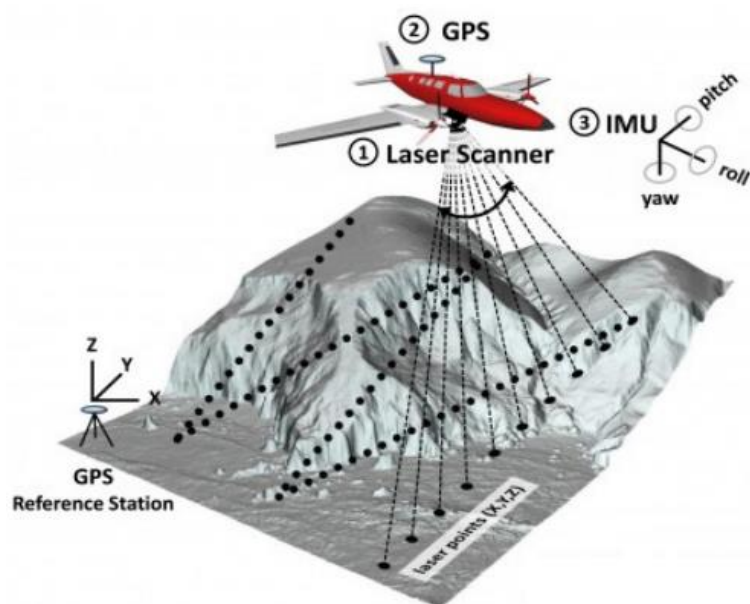


Fonte: Melin, Shapiro e Glover-Kapfer (2017).

O Lidar pode ser operado a partir de plataformas orbitais, terrestre ou aerotransportada (GIONGO *et al.*, 2010). Embora os princípios ópticos e mecânicos sejam semelhantes, as tecnologias para determinar a posição e a orientação e do sensor variam de acordo com a aplicação (POPESCU *et al.*, 2011).

Segundo GIONGO *et al.* (2010), os sistemas Lidar aerotransportado (*Airborne Laser Scanner - ALS*) são compostos por um sensor *laser* que essencialmente registra o tempo entre o sinal emitido e o recebido de um determinado ponto na superfície terrestre, um Sistema Inercial de Navegação (INS – *Inertial Navigation System*) e um receptor GNSS (*Global Navigation Satellite System*) em uma plataforma aerotransportada. Em terra, é necessário um receptor GNSS que possibilite o cálculo da correção diferencial do receptor instalado na plataforma (Figura 3).

Figura 3. O processo de varredura a laser aerotransportado.



Fonte: Melin, Shapiro e Glover-Kapfer (2017).

Para cada pulso refletido, são registrados a localização e a orientação do ponto de reflexão e o tempo de percurso entre o aparelho emissor e a superfície, o que possibilita que a distância e a posição tridimensional de cada ponto sejam calculadas (WAGNER *et al.*, 2004). A distância (D) pode ser obtida pela seguinte equação (BALTSAVIAS, 1999):

$$D = c \cdot t / 2$$

Em que: c = velocidade da luz no vácuo  $\approx 300.000$  km/s; t = tempo de emissão e de recepção de um pulso (ns).

O pulso do laser possui a capacidade de penetrar em pequenas aberturas do dossel da floresta, permitindo a obtenção de informações do relevo, sub-bosque e do dossel da floresta (JENSEN, 2009). Os múltiplos retornos dos pulsos laser possibilitam a identificação e mensuração de diferentes camadas da estrutura vertical da paisagem, resultando na estrutura tridimensional (REUTEBUCH *et al.*, 2005). As informações obtidas da nuvem de pontos Lidar podem ser usadas para diversas aplicações na área florestal e alguns exemplos são apresentados na Tabela 1.

Tabela 1. Aplicações florestais para dados Lidar.

PARÂMETROS FLORESTAIS	FORMA DE OBTENÇÃO DE DADOS ALS	EXEMPLO DE APLICAÇÃO DE LITERATURA
Altura do dossel	Medida direta	Næsset (1997)

Volume de copa	Medida direta	Coops et al. (2007)
Diâmetro de copa	Medida direta	Roberts et al. (2005)
Nº de indivíduos	Medida direta	Hirata et al. (2009)
Volume	Modelagem	Ioki et al. (2010)
Biomassa	Modelagem	Damelin e Medvedev (2004)
Carbono	Modelagem	Balzter et al (2007)
Área basal	Modelagem	Silva et al (2017)
Diâmetro à altura do peito	Modelagem	Ibanez et al (2016)
Cobertura de copa	Fusão com outros sensores	Andersen et al (2005)
Identificação de espécie	Fusão com outros sensores	Kim (2007)

Fonte: Giongo *et al.* (2010) e adaptado por Rex (2019).

Em um estudo realizado por Jiménez *et al.* (2017) obtiveram variáveis dendrométricas e de biomassa para um povoamento comercial (*Pinus pinaster*, *Pinus radiata* e *Eucalyptus spp.*) usando dados Lidar de baixa densidade em combinação com as imagens da plataforma orbital Landsat ETM+, demonstrando que é possível determinar a distribuição espacial das variáveis dendrométricas e da biomassa acima do solo em áreas extensas. Silva *et al.* (2017) apresentou resultados satisfatórios na predição da AGB em plantações de *Pinus taeda* L. por meio de dados Lidar aerotransportado.

Oehmcke *et al.* (2024) empregaram redes de *deep learning* para prever a biomassa acima do solo, o volume de madeira e os estoques de carbono nas florestas de forma eficiente e direta a partir de nuvens de pontos Lidar aerotransportadas. Três arquiteturas de redes neurais conceitualmente diferentes foram modificadas para realizar regressão e foram avaliadas usando um conjunto de dados exclusivo combinando medições de campo e dados Lidar.

#### 4.4 Modelos digitais

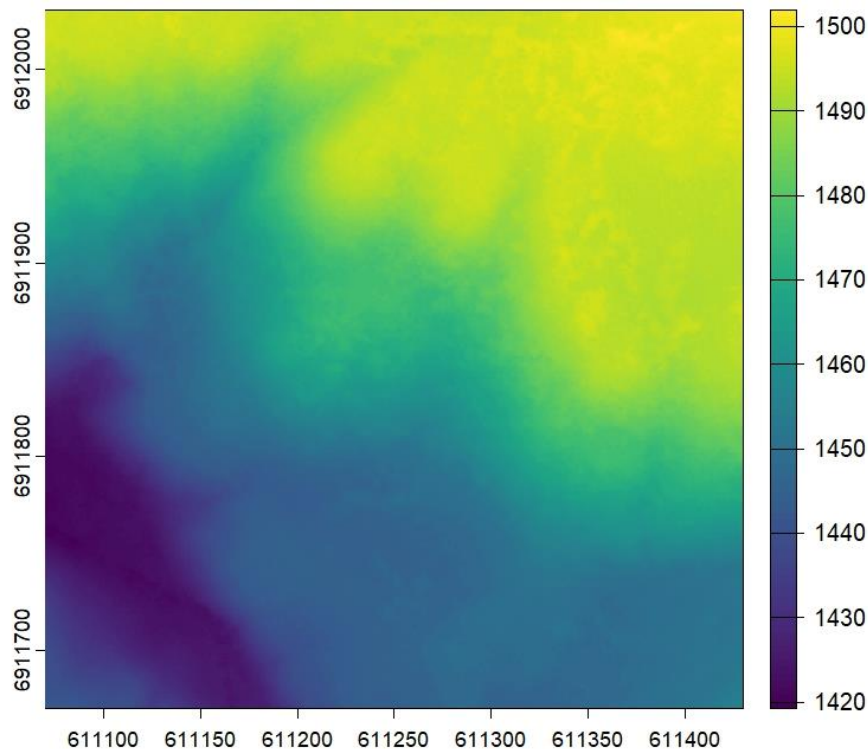
Além da aplicação do setor florestal, a tecnologia Lidar é utilizada para desenvolvimento do modelo digital de terreno (DTM), modelo digital de superfície (DSM) e modelo digital normalizado (nDSM). Com esses modelos é possível extrair informações como

a declividade do terreno, informações sobre árvores isoladas, quantificação de biomassa e carbono, análise de extratos florestais, modelagem 3D de copas, dentre outros (PEREIRA, 2014).

#### 4.4.1 *Digital Terrain Model*

O *Digital Terrain Model* (DTM) ou Modelo Digital de Terreno (Figura 4) é uma representação digital tridimensional da superfície da Terra. Descreve a elevação do terreno de forma precisa e pode incluir características como montanhas, vales, rios e outros relevos naturais. Utilizado em Cartografia, Planejamento Urbano, Engenharia Civil, estudos ambientais, entre outros campos (LILLESAND; KIEFER; CHIPMAN, 2015).

Figura 4. *Digital Terrain Model* (tile aleatório da área de estudos).

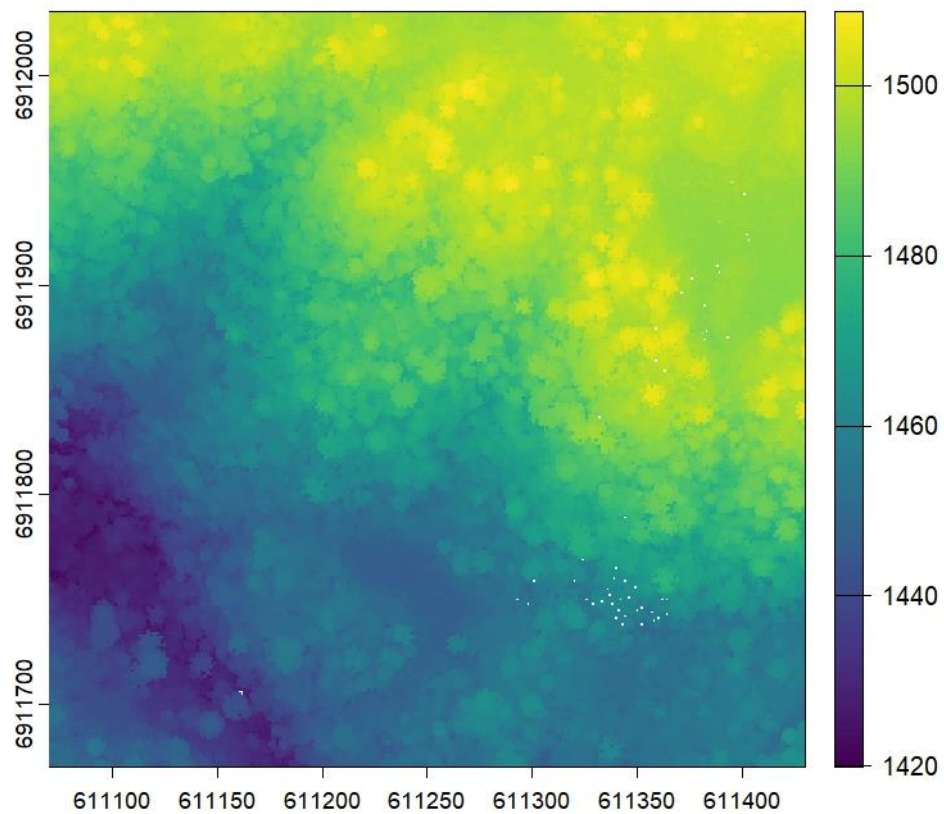


Fonte: Autor (2024).

#### 4.4.2 *Digital Surface Model*

O *Digital Surface Model* (DSM) ou Modelo Digital de Superfície (Figura 5) apresenta informações de toda elevação das feições e do relevo da paisagem, servindo como uma representação visual das feições na superfície terrestre, como árvores, construções, entre outros objetos do terreno (Jensen, 2009).

Figura 5. *Digital Surface Model* (tile aleatório da área de estudos).

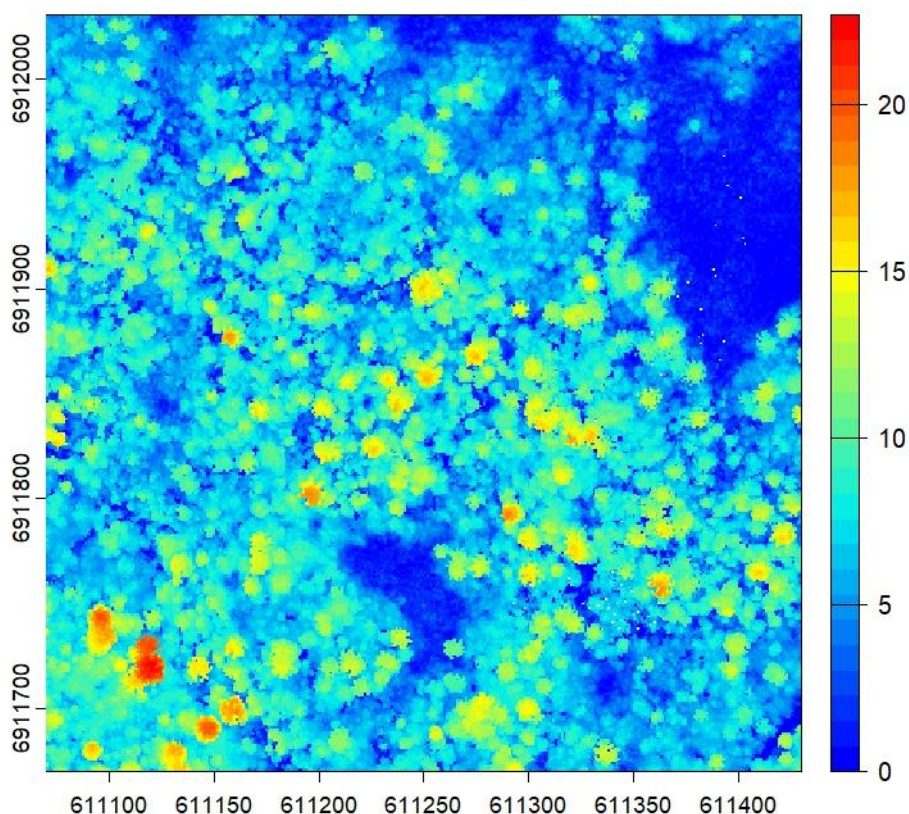


Fonte: Autor (2024).

#### 4.4.3 *Canopy Height Model*

O *Canopy Height Model* (CHM) ou Modelo Digital do Dossel (Figura 6) é semelhante ao DSM, sendo uma representação digital que descreve a altura vertical das copas das árvores e outras estruturas do dossel vegetal. Frequentemente derivado de dados remotamente situados como o Lidar ou Aerofotogrametria, informações utilizadas em estudos de ecologia florestal, manejo de recursos naturais e modelagem ambiental (POPESCU, 2007).

Figura 6. *Canopy Height Model* (tile aleatório da área de estudos).



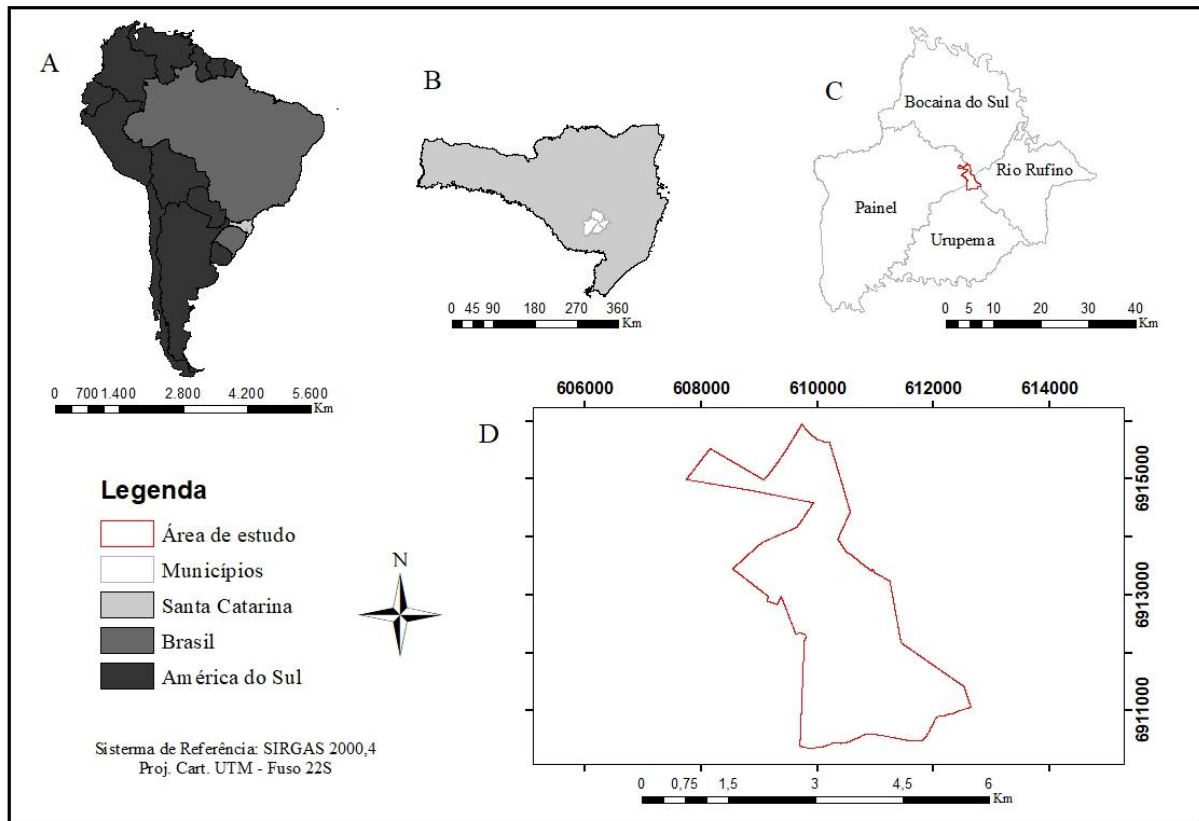
Fonte: Autor (2024).

## 5. METODOLOGIA

### 5.1 Área de estudo

A área de estudo é a RPPN (Reserva Particular do Patrimônio Natural) Complexo Serra da Farofa pertence a empresa Klabin S.A. Está localizada entre os municípios de Bocaina do Sul, Paineira, Urupema e Rio Rufino no estado de Santa Catarina (Figura 7). Com quase cinco mil hectares de área remanescente da Mata Atlântica, caracterizada pela vegetação da Floresta Ombrófila Mista, Matas Nebulares e Campos de Altitude. Além disso, a reserva abriga as nascentes dos rios Caveiras e Canoas. Nessa reserva foram registradas mais de 570 espécies de flora e 360 de fauna (KLABIN S.A., 2024). O clima da região pela classificação de Köppen é Cfb (clima temperado, sem estação seca e verão fresco), a precipitação varia de 1.100 a 2.000 mm anual e acontecem geadas severas e frequentes. Na Fazenda das Nascentes as altitudes superam 1700 m, contribuindo para a singularidade e importância da região (KLABIN S.A., 2020).

Figura 7. Localização da RPPN Complexo Serra da Farofa. Em que A- América do Sul; B- Santa Catarina; C- municípios que contemplam a RPPN; D- área de estudo.



Fonte: Autor (2024).

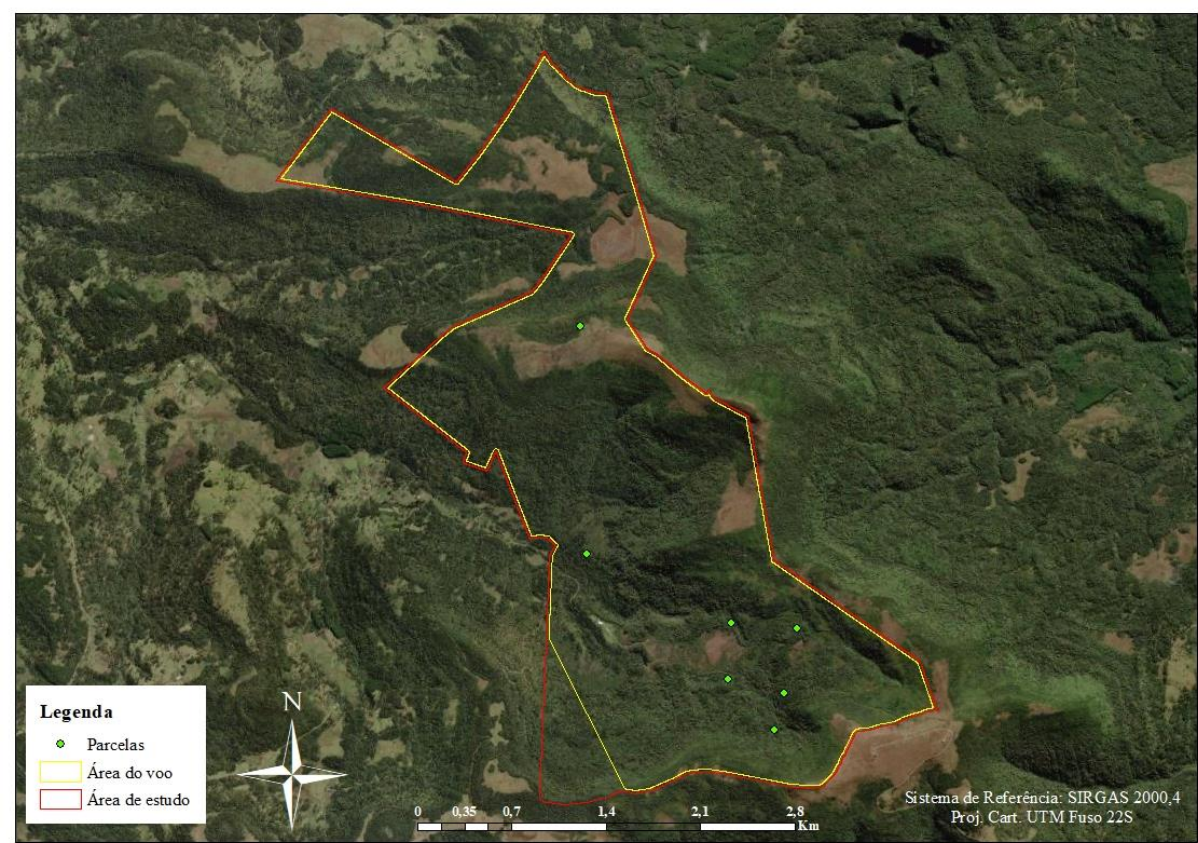
## 5.2 Obtenção dos dados

### 5.2.1 Inventário Florestal

Os dados de inventário florestal foram obtidos a partir da mensuração de 7 parcelas permanentes na reserva sendo que cada parcela tem uma área 200m<sup>2</sup> (10m x 20m), resultando em uma área amostral de 1400m<sup>2</sup> (Figura 8). Estas parcelas foram instaladas no ano de 2019, com o objetivo de realizar o monitoramento temporal sendo que as parcelas foram implantadas de forma aleatória, abrangendo diferentes locais e altitudes. As árvores remanescentes foram

identificadas e mensuradas as variáveis dendrométricas para quantificação de biomassa e carbono existentes na aérea, através do método não destrutivo (Souza e Nicoletti, 2023).

Figura 8. Localização das parcelas de inventario florestal e recobrimento aéreo na área de estudo.



Fonte: Autor (2024).

5.2.2 Lidar

O recobrimento aéreo foi realizado pela empresa SAI – Serviços Aéreos Industriais em outubro de 2019 (ZIEGELMAIER NETO, 2022). Na tabela 2 são apresentadas as características do sensor Lidar e do recobrimento aéreo.

Tabela 2. Características do recobrimento aéreo e do equipamento Lidar utilizado.

Aparelho Lidar	Optech ALTM Gemini
Comprimento de onda	1064 nm
Data de aquisição	08/10/2019
Altitude de voo	800 m
Velocidade média de voo	184 km/h

Ângulo de escaneamento	+/- 10°
Repetição do Laser Scanner	70 kHz
Frequência de escaneamento	70 Hz
Número de retornos	1-4
Intensidade	12 bits
Densidade média de pontos	15.38 pontos/m²

Fonte: Ziegelmaier, Neto (2022).

### 5.3 Processamento dos dados

#### 5.3.1 Inventário Florestal

Modelos específicos foram aplicados para *Araucaria angustifolia* (Bertol.) Kuntze, devido às suas características únicas, enquanto outros modelos consideraram as particularidades de crescimento de outras espécies, visando maior precisão nas estimativas. Esta abordagem diferenciada é crucial para obter resultados precisos no inventário florestal e na gestão sustentável das florestas (Souza e Nicoletti, 2023).

Para os dados de inventário, foram utilizados modelos de volume e altura ajustados por Souza e Nicoletti (2023) para a área de estudo. Os pesquisadores observaram que os dados apresentavam muita diferença nas alturas, já que foram coletadas por métodos diferentes, por este motivo foram usados os modelos hipsométricos, apresentados na Tabela 3.

Tabela 3. Modelos ajustados para volume e altura, para a área de estudo.

Modelo	Autores	Espécies	Equação	R <sup>2</sup> ajust.	Syx(%)	FM
1 Volumétrico	Netto	A. <i>angustifolia</i>	$v=0,03840414+0,52239325+ei$	-	-	-
2 Volumétrico	Vibrans et al	Outras espécies	$\ln (v/1000) =17,96+0,96*\ln c$ $+0,76*\ln h +ei$	0,94		
3 Hipsométrico	Douglas et al	A. <i>angustifolia</i>	$\ln h =1,87943351+0,28822365*\ln d$ $+ei$	0,59	12,3	1,0271
4 Hipsométrico	Douglas et al	Outras espécies	$\ln h =1,45232149+0,39383646*\ln d$ $+ei$	0,478	10,5	1,0271

Em que:  $\ln$  = logaritmo natural;  $h$  = altura total da árvore(m), para equação 3 e 4 é necessária a altura comercial que, segundo dados coletados é de 82 % da altura para *A. angustifolia* e 75% da altura para as outras espécies;  $c$  = circunferências na altura do peito;  $d$  = diâmetro à altura do peito (cm) e para a equação 3 em (m);  $v$  = volume individual; FM = fator Meyer,  $\epsilon_i$  = erro aleatório não informado. Fonte: De Souza e Nicoletti (2023).

A biomassa foi estimada pelos modelos apresentados na Tabela 4, ajustados por De Souza e Nicoletti, (2023), para área de estudo.

Tabela 4. Modelos ajustados para o cálculo da AGB.

Autores	Espécies	Equação	R <sup>2</sup> ajust.	Syx(%)	FM	n
S. Hall	<i>A. angustifolia</i>	$\ln b = -3,3252 + 1,57874 * \ln d + 1,24179 * \ln(h)$	0,61	134,9	1,2198	227
Vibrans	Outras espécies	$\ln b/1000 = -12,236 + 0,80307 * \ln c^2 + 1,16862 * \ln(h)$	0,83	55,1	1,097	15

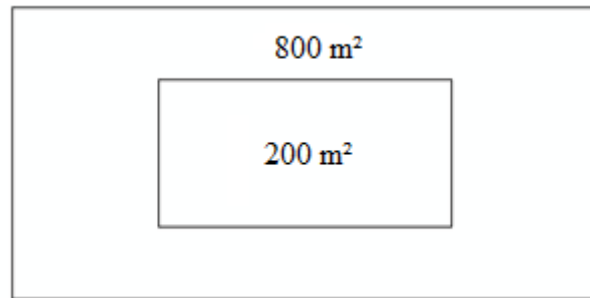
Em que:  $\ln$  = logaritmo natural;  $h$  = altura da árvore (m);  $c$  = circunferência na altura do peito;  $d$  = DAP (cm);  $v$  = volume individual (m<sup>3</sup>); FM: fator de Meyer. Fonte: De Souza e Nicoletti (2023).

### 5.3.2 Dados Lidar

O ajuste do tamanho, rotação e posicionamento das parcelas é crucial para corrigir erros relacionados ao posicionamento em campo, muitas vezes causados por limitações na precisão do GPS e pela complexidade do terreno ou vegetação (HERNÁNDEZ-STEFAONI *et al.*, 2018). Essas discrepâncias podem gerar inconsistências na correspondência entre as parcelas amostradas e os dados Lidar, afetando a confiabilidade das métricas extraídas (LI *et al.*, 2022). Ao realizar esses ajustes, busca-se alinhar de forma mais precisa os dados de inventário florestal com os dados remotos, garantindo maior acurácia nas estimativas florestais, como biomassa e estrutura vertical (LAURIN *et al.*, 2014).

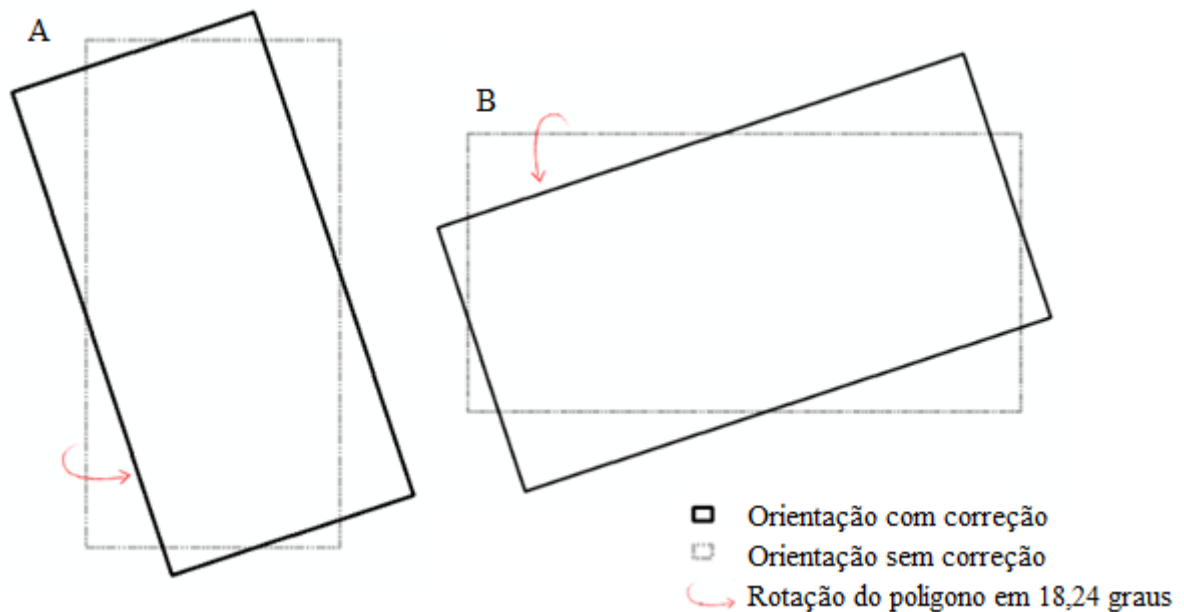
Para isso foram criados sete polígonos retangulares no tamanho de 200m<sup>2</sup> (10m x 20m) e sete polígonos retangulares no tamanho de 800m<sup>2</sup> (20m x 40m) (Figura 9). Foram calculadas a convergência meridiana e a declinação magnética para as parcelas, posteriormente para ajustar a parcelas representadas na projeção cartográfica UTM (Universal Transversa de Mercator). A orientação das parcelas em campo foi feita empregando a bússola eletrônica do receptor de sinais GNSS. Na Figura 10 são apresentadas as posições das parcelas para as direções cardeais Norte-Sul (N-S) e Leste-Oeste (L-O). É exemplificado a correção da convergência meridiana e da declinação magnética.

Figura 9. Representação dos polígonos de 200m<sup>2</sup> e 800m<sup>2</sup>.



Fonte: Autor (2024).

Figura 10. Orientação dos polígonos em N-S e L-O. Em que: A- orientação N-S; B- orientação L-O.



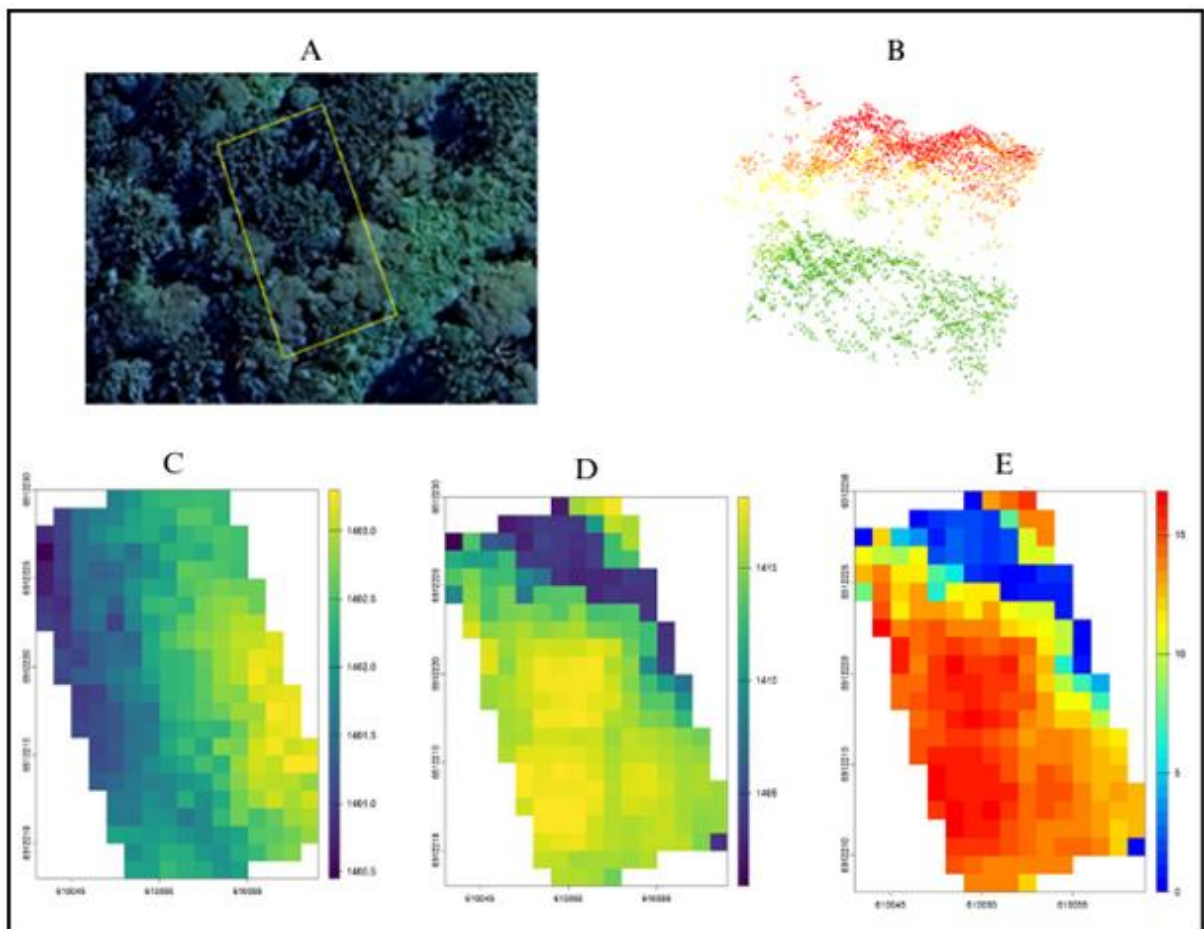
Fonte: Autor (2024).

Após os ajustes das direções, foi utilizado o comando *LasClip*, do *plugin LAStools* no aplicativo ArcGIS 10.8 para recortar a nuvem de pontos Lidar referente a cada parcela. O processamento dos recortes das parcelas ocorreu no aplicativo RStudio 4.4.1 com o pacote *lidR*. O pacote é projetado para manipulação, visualização e análise de dados de escaneamento ALS (Airborne Laser Scanner). Sendo utilizado para a extração de métricas florestais e geomorfológicas a partir de nuvens de pontos Lidar (ROUSSEL *et al.*, 2020).

O *script* do processamento Lidar, está disponível no trabalho da Corte *et al.* (2022). Inicialmente foram gerados os DTM, DSM, CHM e nDSM por parcelas (Figura 11, as demais parcelas estão no apêndice). O DTM foi extraído pelo algoritmo proposto por Zhang *et al.* (2016), usando uma técnica de filtragem por simulação de tecido (*Cloth simulation filtering* -

CSF), ou seja, simula um tecido que é "ajustado" sobre uma nuvem de pontos invertida. Nesse processo, a nuvem de pontos é virada de cabeça para baixo e o tecido é projetado sobre a superfície invertida. Os pontos de contato com o solo são identificados a partir das interações entre os nós do tecido e da superfície. A simulação do tecido é feita com uma grade composta por partículas com massa interligadas, o que define sua posição tridimensional e forma.

Figura 11. Representação do polígono de 200m<sup>2</sup>, referente a parcela 1. Em que: A- Google Earth; B- Nuvem de pontos; C- DTM; D- DSM; E- CHM.



Fonte: Autor (2024).

A extração das métricas ocorreu a nível da nuvem de pontos, levando em consideração todos os pontos disponíveis pelas funções “cloud\_metrics ()” e “stdmetrics\_z ()” resultando 36 métricas (ROUSSEL *et al*, 2020). As métricas extraídas são observadas na Tabela 5.

Tabela 5. Métrica extraídas do nDSM.

Siglas	Significados
Zmax	Altura máxima
Zmean	Altura média

<b>Zsd</b>	Desvio padrão da Distribuição da altura
<b>Zskew</b>	Assimetria da distribuição de altura
<b>Zkurt</b>	Curtose da distribuição de altura
<b>Zentropy</b>	Entropia da distribuição de altura
<b>pzabovemean</b>	Porcentagem de retornos acima de zmean
<b>pzabove2</b>	Porcentagem da altura superior a 2 metros em relação ao solo
<b>zq</b>	$x$ -ésimo percentil (quantil) da distribuição de altura
<b>zpcum</b>	Porcentagem acumulada de retorno na $i$ -ésima camada

Fonte: Autor (2024), adaptado de Roussel *et al.* (2020).

### 5.3.3 Modelos para estimativa de biomassa

Das parcelas foram selecionadas aleatoriamente 30% para a validação e 70% das para o treinamento. Foi realizado o teste de correlação entre as métricas obtidas do Lidar e os dados de campo (biomassa). Foram selecionadas as métricas para a modelagem que apresentaram correlação acima de 0,5. Na Tabela 6 podemos observar os parâmetros de correlação.

Tabela 6. Parâmetros de Correlação de Pearson (r).

<b>Coefficiente de correlação</b>	<b>Correlação</b>
$r = 1$	Perfeita positiva
$0,8 \leq r < 1$	Forte positiva
$0,5 \leq r < 0,8$	Moderada positiva
$0,1 \leq r < 0,5$	Fraca positiva
$r = 0$	Ínfima positiva
$0 < r < -0,1$	Nula
$-0,1 \leq r < -0,5$	Ínfima negativa
$-0,5 \leq r < -0,8$	Moderada negativa
$-0,8 \leq r < -1$	Forte negativa
$r = -1$	Perfeita negativa

Fonte: Santos (2007) citado por Corte *et al.* (2022).

Em seguida utilizou-se a regressão Stepwise, um método automatizado empregado nas fases exploratórias para a construção de modelos de biomassa. Esse processo apresenta três abordagens (Corte *et al.*, 2022):

- *Forward*, o processo inicia com um modelo nulo, ou seja, sem variáveis, e a adição de variáveis independentes é testada uma a uma. A inclusão de uma variável no modelo é baseada em critérios como a redução do p-value ou o aumento no valor do  $R^2$ , garantindo que apenas as variáveis mais relevantes sejam mantidas.

- *Backward* começa com um modelo que inclui todas as variáveis independentes disponíveis. A remoção das variáveis ocorre gradualmente, também uma a uma, com base na sua importância para o modelo, sendo eliminadas aquelas que apresentam maior p-value ou contribuem menos para a explicação do modelo, observando-se o impacto na soma dos quadrados dos resíduos.
- *Both* (bidirecional) que combina ambas as técnicas, testando simultaneamente a adição e a remoção de variáveis para otimizar a seleção do conjunto de preditores.

Este procedimento ocorreu com auxílio do pacote “olsrr” (Hebbali, 2020), que possui um conjunto de ferramentas para construção de modelos de regressão utilizando-se do critério dos Mínimos Quadrados Ordinários. Um método de estimação empregado na regressão linear com o intuito de determinar os coeficientes que minimizam a soma dos quadrados dos resíduos, os quais representam as diferenças entre os valores observados e os valores ajustados pelo modelo. Essencialmente, visa ajustar uma linha reta que melhor represente a relação entre as variáveis explicativas (independentes) e a variável resposta (dependente).

Foram aplicadas as seguintes funções: “ols\_step\_forward\_p” para o método forward, “ols\_step\_backward\_p” para backward e “ols\_step\_both\_p” para o método bidirecional. A seleção do modelo foi baseada no valor de p (ou p-valor) obtido pela ANOVA (análise de variância), sendo considerado significativo quando o p-valor foi inferior a 0,05. (Corte *et al.*, 2022).

Antes de espacializar a biomassa foram gerados nove recortes (*tiles*) da nuvem Lidar referente a área de estudo, para facilitar o processamento computacional. Esses recortes foram normalizados, e posteriormente extraídas as métricas e salvas em formato tiff com uma resolução espacial de 1m x 1m. No ArcGIS 10.8 a ferramenta *Mosaic To New Raster* foi usada para unir os nove recortes referente as métricas utilizadas na modelagem. A ferramenta *Raster Calculator* utilizada para calcular a biomassa.

#### 5.3.4 Avaliação estatísticas

O coeficiente de correlação de Pearson ( $r$ ), mede a força e a direção da relação linear entre duas variáveis. O valor de  $r$  varia de -1 a 1, (Tabela X) onde:

- **1** indica uma correlação positiva perfeita,
- **-1** indica uma correlação negativa perfeita,

- 0 indica ausência de correlação linear.

Sendo representado pela equação a seguir:

$$r = \frac{\sum (xi - x)(yi - y)}{\sqrt{\sum (xi - x)^2 (yi - y)^2}}$$

- Em que:
- xi e yi são os valores das duas variáveis.
- x é a média dos valores da variável x.
- y é a média dos valores da variável y.

O coeficiente de determinação ( $R^2$ ) quantifica a proporção da variabilidade dos valores observados que é explicada pelo modelo. Este coeficiente varia de 0 a 1, sendo que valores próximos de 1 indicam que o modelo possui uma alta capacidade de explicação da variabilidade dos dados observados. Representado pela equação a seguir:

$$R^2 = 1 - \frac{\sum (yi - \hat{y}i)^2}{\sum (yi - \bar{y})^2}$$

Em que:

- yi são os valores observados.
- $\hat{y}i$  são os valores previstos pelo modelo.
- $\bar{y}$  é a média dos valores observados.

A Raiz do Erro Médio Quadrático (RMSE) representa a diferença entre os valores observados e os valores previstos por um modelo, expressando a magnitude média desses erros. Valores menores de RMSE indicam um melhor ajuste do modelo aos dados observados. Representado pela equação a seguir:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (yi - \hat{y}i)^2}{n}}$$

Em que:

- yi são os valores observados.
- $\hat{y}i$  são os valores estimados pelo modelo.
- n é número de observações.

O BIAS mede a tendência do modelo em superestimar ou subestimar os valores observados. Valores positivos indicam superestimação, enquanto valores negativos indicam subestimação. Representado pela equação a seguir:

$$BIAS = \frac{\sum_1^n 1 = (\hat{y}_i - y_i)}{n}$$

Em que:

- $y_i$  são os valores observados.
- $\hat{y}_i$  são os valores estimados pelo modelo.
- $n$  é número de observações.

## 6. RESULTADOS

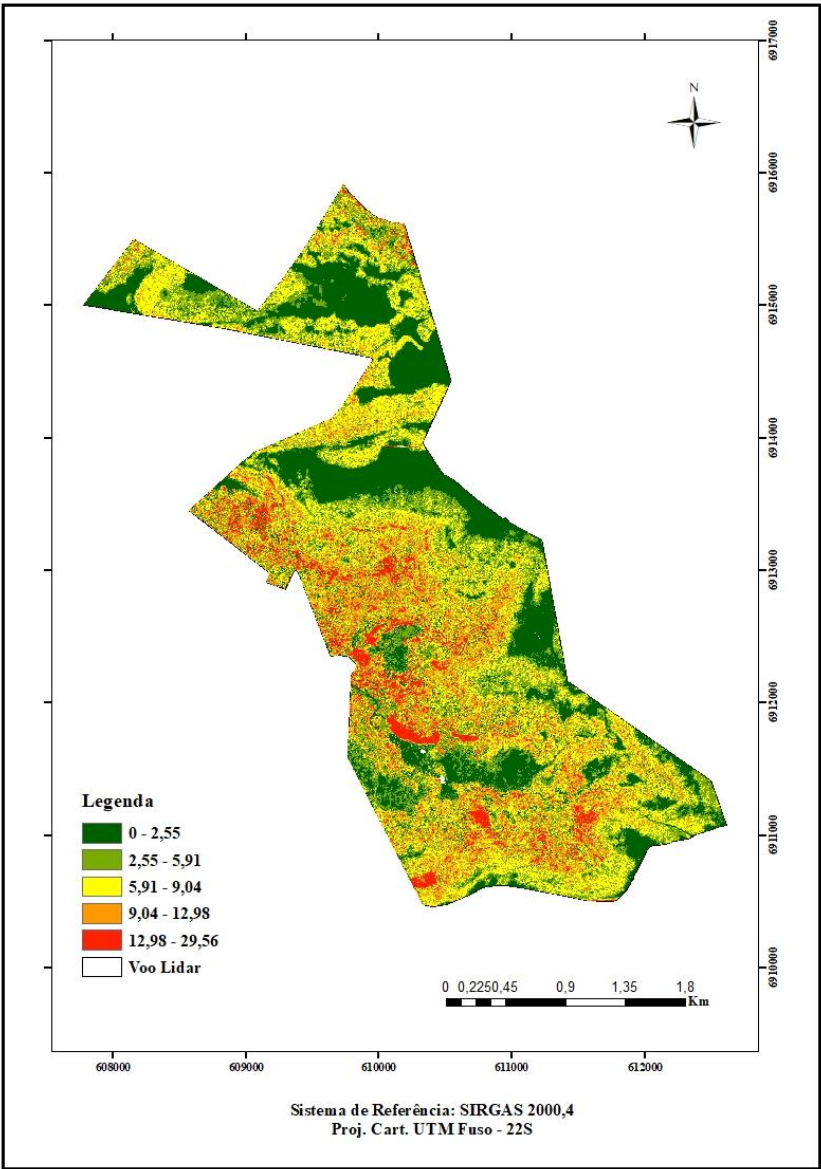
O CHM da área de estudo (Figura 12) apresentou valores no intervalo de 0 m a 29,56 m, enquanto o inventário florestal com base na alturas obtidas pelos modelos hipsométricos, identificou altura máxima de 23,18 m. Ambas as alturas identificadas estão coerentes com valores encontrados em literatura para a altura máxima de Floresta Ombrófila Mista, 27m conforme evidenciado em trabalho de TRAUTEN MÜLLER (2019). Na Tabela 7 é possível comparar as alturas máximas e média obtidas pelas observações de campo e pelo Lidar em cada parcela.

Tabela 7. Comparativos das alturas das árvores obtidas pelos modelos hipsométricos e das métricas derivada do Lidar (m).

Parcelas	Inventário Florestal			Polígono 200 m <sup>2</sup>			Polígono 800 m <sup>2</sup>		
	máx (m)	méd (m)	DP (m)	máx (m)	méd (m)	DP (m)	máx (m)	méd (m)	DP (m)
1	21,81	13,20	4,35	16,85	8,26	6,08	18,50	8,41	6,01
2	20,96	11,84	3,30	15,24	8,29	4,24	15,24	7,54	3,95
3	17,68	12,42	2,57	14,32	7,21	3,16	21,44	7,78	3,71
5	15,50	11,29	2,32	8,96	5,89	2,32	8,94	5,00	2,41
6	19,37	12,89	3,25	16,10	8,46	5,13	22,63	8,94	5,14
7	22,82	15,33	4,35	16,88	6,94	4,36	18,10	6,97	4,45
8	23,18	15,35	3,87	17,13	8,95	4,14	18,83	7,22	4,29

Em que: máx = máximo; méd = média; DP = desvio padrão. Fonte: Autor (2024).

Figura 12. CHM da área de estudo.



Fonte: Autor (2024)

Nas Tabelas 8 e 9 apresentam-se as métricas derivadas do Lida. As métricas **zpcum5** e **zentropy** para os recortes com áreas 200m<sup>2</sup> (Tabela 8) apresentaram uma correlação de Person de 0,82 e 0,74 respectivamente, forte e moderada em relação AGB obtida pelo inventário florestal.

Tabela 8. Métricas Lidar do polígono de 200m².

Métricas	Parcelas						
	1	2	3	5	6	7	8
<b>Zmax</b>	16,85	15,24	14,32	8,96	16,10	16,88	17,13
<b>Zmean</b>	8,26	8,29	7,21	5,89	8,46	6,94	8,95
<b>Zsd</b>	6,08	4,24	3,16	2,32	5,13	4,36	4,14
<b>Zskew</b>	-0,31	-0,76	-0,85	-1,27	-0,59	-0,20	-0,64
<b>Zkurt</b>	1,37	2,54	3,67	3,64	1,81	2,06	2,72
<b>Zentropy</b>	0,84	0,89	0,80	0,86	0,87	0,88	0,91
<b>pzabovemean</b>	57,56	62,85	57,50	67,32	62,58	57,98	57,70
<b>pzabov2</b>	68,08	83,66	88,21	90,71	77,83	77,00	89,20
<b>zq5</b>	0,00	0,00	0,00	0,00	0,00	0,00	0,38
<b>zq10</b>	0,00	0,37	0,57	2,24	0,00	0,00	1,65
<b>zq15</b>	0,00	1,43	5,45	3,21	0,43	0,67	4,30
<b>zq20</b>	0,45	4,24	5,95	4,07	1,54	1,35	5,56
<b>zq25</b>	0,82	6,80	6,22	4,86	3,42	3,17	6,88
<b>zq30</b>	1,45	7,69	6,49	5,59	5,70	5,29	7,74
<b>zq35</b>	3,98	8,16	6,78	6,11	7,11	6,21	8,20
<b>zq40</b>	6,73	8,43	7,07	6,35	9,22	6,79	8,69
<b>zq45</b>	9,92	8,83	7,33	6,56	9,93	7,18	9,25
<b>zq50</b>	10,99	9,22	7,59	6,74	10,34	7,48	9,78
<b>zq55</b>	11,84	9,66	7,85	6,90	10,80	7,79	10,28
<b>zq60</b>	12,35	10,08	8,08	7,06	11,43	8,19	10,66
<b>zq65</b>	12,83	10,50	8,26	7,20	12,05	8,62	11,09
<b>zq70</b>	13,33	10,90	8,48	7,37	12,49	9,35	11,50
<b>zq75</b>	13,66	11,20	8,92	7,52	12,82	10,46	11,86
<b>zq80</b>	14,01	11,61	9,47	7,66	13,09	11,32	12,32
<b>zq85</b>	14,44	12,16	10,13	7,85	13,38	11,85	12,84
<b>zq90</b>	15,01	13,10	11,02	8,02	13,72	12,28	13,29
<b>zq95</b>	15,57	14,01	11,83	8,22	14,23	12,94	14,90
<b>zpcum1</b>	18,23	7,51	3,37	1,33	7,39	11,87	6,13
<b>zpcum2</b>	21,59	10,23	3,83	2,86	12,58	15,97	9,88
<b>zpcum3</b>	25,10	13,42	4,29	6,40	16,04	20,13	14,55
<b>zpcum4</b>	28,75	15,98	9,77	11,96	22,64	32,09	21,43
<b>zpcum5</b>	31,95	22,95	36,04	17,17	26,89	58,07	35,98
<b>zpcum6</b>	35,21	44,44	68,93	24,25	33,30	70,03	52,91
<b>zpcum7</b>	46,02	63,60	82,91	33,97	51,94	82,62	75,66
<b>zpcum8</b>	66,71	83,98	92,76	61,41	72,01	95,59	91,53
<b>zpcum9</b>	89,93	92,17	98,74	90,21	96,41	98,16	95,94

Em que: zmax - altura máxima; zmean - altura média; zsd - desvio padrão da distribuição de altura; zskew - assimetria da distribuição de altura; zkurt - curtose da distribuição de altura; zentropy - entropia da distribuição de altura; pzabovemean - porcentagem de retornos acima de zmean; pzabov2 - porcentagem da altura superior a 2

metros em relação ao solo; zq –  $x^{-ésimo}$  percentil (quantil) da distribuição de altura; zpcum - porcentagem acumulada de retorno na  $i^{-ésima}$  camada. Fonte: Autor (2024).

Para os recortes das nuvens de ponto com área de 800m<sup>2</sup> (Tabela 9) as métricas **zpcum3** apresento uma correlação 0,93 forte em relação a AGB fornecida pelo inventário florestal.

Tabela 9. Métricas Lidar do polígono de 800m<sup>2</sup>.

Métricas	Parcelas						
	1	2	3	5	6	7	8
<b>Zmax</b>	18,50	15,24	21,44	8,94	22,63	18,10	18,83
<b>Zmean</b>	8,41	7,54	7,78	5,00	8,94	6,97	7,22
<b>Zsd</b>	6,01	3,95	3,71	2,41	5,14	4,45	4,29
<b>Zskew</b>	-0,23	-0,62	0,21	-0,87	-0,36	0,16	0,01
<b>Zkurt</b>	1,51	2,46	4,78	2,68	2,08	2,09	2,25
<b>Zentropy</b>	0,89	0,89	0,76	0,91	0,88	0,93	0,92
<b>pzabovezmean</b>	55,49	62,74	51,55	60,78	59,29	49,08	53,11
<b>pzabove2</b>	71,33	83,62	89,64	84,55	84,64	83,81	83,71
<b>zq5</b>	0,00	0,00	0,00	0,00	0,00	0,00	0,00
<b>zq10</b>	0,00	0,37	1,36	0,19	0,63	0,67	0,88
<b>zq15</b>	0,23	1,34	5,54	1,86	1,90	1,76	1,76
<b>zq20</b>	0,66	3,90	6,17	3,02	3,19	2,71	2,93
<b>zq25</b>	1,22	5,46	6,51	3,83	4,38	3,43	3,91
<b>zq30</b>	2,59	6,54	6,82	4,35	5,74	4,04	4,74
<b>zq35</b>	5,53	7,31	7,11	4,68	7,20	4,71	5,32
<b>zq40</b>	7,28	7,77	7,39	5,07	8,75	5,40	5,79
<b>zq45</b>	8,53	8,18	7,64	5,40	9,79	6,11	6,89
<b>zq50</b>	9,77	8,48	7,86	5,68	10,50	6,83	7,83
<b>zq55</b>	10,98	8,76	8,08	5,96	11,15	7,50	8,50
<b>zq60</b>	11,67	9,06	8,26	6,20	11,69	8,13	8,95
<b>zq65</b>	12,49	9,35	8,51	6,40	12,20	8,85	9,36
<b>zq70</b>	13,27	9,71	8,81	6,62	12,61	9,79	9,85
<b>zq75</b>	13,93	10,24	9,21	6,84	12,95	10,65	10,32
<b>zq80</b>	14,53	10,77	9,81	7,07	13,30	11,35	10,78
<b>zq85</b>	15,07	11,26	10,37	7,30	13,73	11,95	11,50
<b>zq90</b>	15,54	12,06	11,26	7,53	14,32	12,64	12,54
<b>zq95</b>	16,18	13,01	15,07	7,84	15,41	14,80	14,02
<b>zpcum1</b>	16,54	7,80	3,82	2,64	8,57	8,01	10,66
<b>zpcum2</b>	20,88	10,79	5,20	5,39	18,89	20,30	19,53
<b>zpcum3</b>	24,47	14,75	18,15	9,27	27,72	35,03	34,76
<b>zpcum4</b>	30,85	21,36	63,48	14,62	35,81	48,94	45,51
<b>zpcum5</b>	39,45	32,54	86,47	24,04	52,33	63,36	63,53
<b>zpcum6</b>	48,54	57,98	92,90	38,40	81,84	74,53	82,98
<b>zpcum7</b>	62,39	77,08	94,57	57,21	96,07	89,25	92,17
<b>zpcum8</b>	79,65	89,95	97,66	80,16	98,80	93,94	96,77

**zpcum9**      96,65      96,85      98,79      96,88      99,13      99,11      98,86

Em que: zmax - altura máxima; zmean - altura média; zsd - desvio padrão da distribuição de altura; zskew - assimetria da distribuição de altura; zkurt - curtose da distribuição de altura; zentropy - entropia da distribuição de altura; pzabovemean - porcentagem de retornos acima de zmean; pzabov2 - porcentagem da altura superior a 2 metros em relação ao solo; zq - x<sup>-ésimo</sup> percentil (quantil) da distribuição de altura; zpcum - porcentagem acumulada de retorno na i<sup>-ésima</sup> camada. Fonte: Autor (2024).

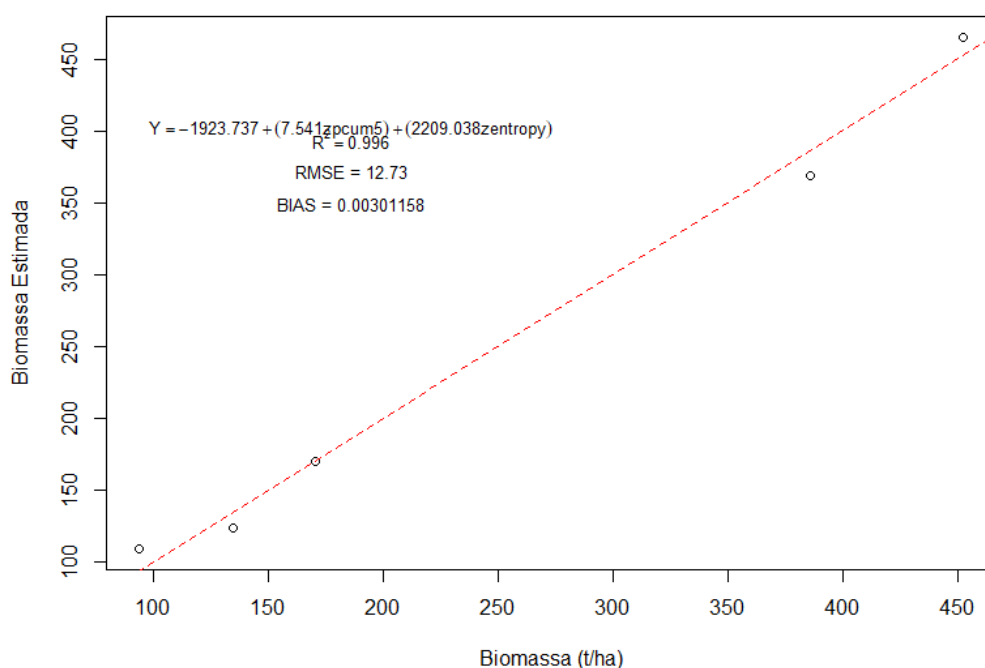
O modelo com menor *p*-valor obtido para o polígono de 200m<sup>2</sup>, pelo o método *Stepwise*, foi o Both, apresentando um *p*-valor de  $0.0078 < 0,05$  na ANOVA, inferindo que a relação entre as métricas zpcum5 e zentropy com a AGB é significativa. O modelo obtido na regressão linear múltipla (RLM):

$$Y = -1923,737 + (7,541 * zpcum5) + (2209,038 * zentropy)$$

Em que: Y= AGB (t/ha); zpcum5= porcentagem acumulada de retorno na camada 50/100; zentropy= entropia da distribuição de altura.

Para esse modelo o valor de R<sup>2</sup> foi 0,996, RMSE de 12,73 t/ha e o BIAS de 0,00301158. As métricas zpcum5 e zentropy são preditores significativos para AGB explicando 99,6% da variabilidade nos dados. O BIAS baixo indica que o modelo está bem ajustado sem tendência significativa (Figura 13).

Figura 13. Resultado do melhor modelo para estimar AGB para os polígonos de 200m<sup>2</sup>, regressão linear múltipla usando as métricas Lidar zpcum5 e zentropy.



Fonte: Autor (2024).

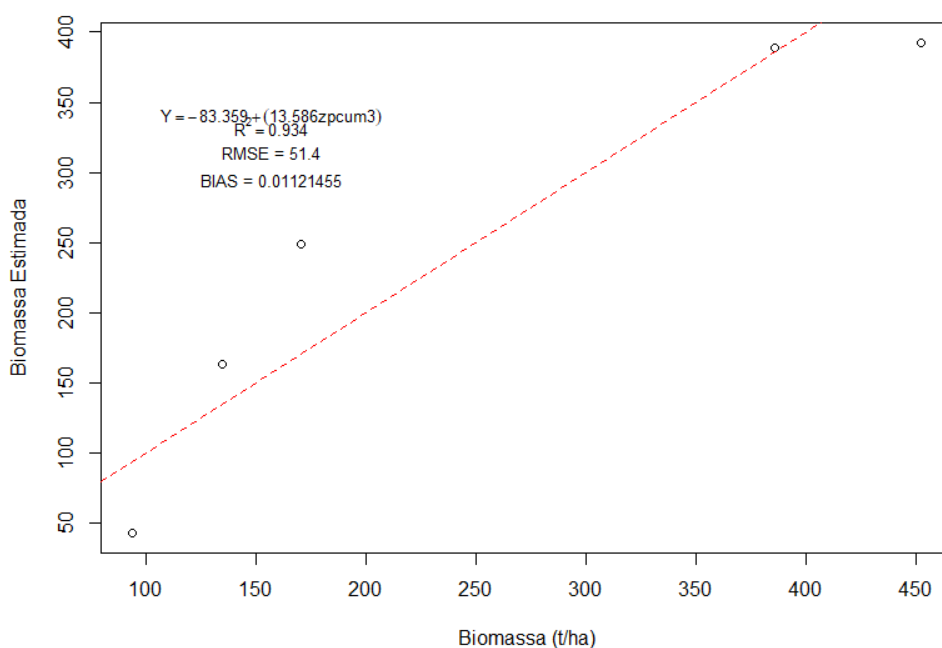
O modelo obtido para o polígono de 800m<sup>2</sup>, pelo método Stepwise, foi o Both, apresentando um *p*-valor de  $0.0202 < 0,05$  na ANOVA, infere que a relação entre a métrica zpcum3 e a AGB é significativa. O modelo obtido por regressão linear simples (RLS):

$$Y = -83,359 + (13,586 * zpecum3)$$

Em que: Y= AGB (t/ha); zpcum3= porcentagem acumulada de retorno na i-ésima camada.

Para essa regressão o valor de R<sup>2</sup> de 0,934, RMSE de 51,4 t/ha e o BIAS de 0,01121455. A métrica zpcum3 é um preditor significativo para AGB, explicando 93,4% da variabilidade nos dados. O BIAS baixo indica que o modelo está bem ajustado sem tendência significativa (Figura 14).

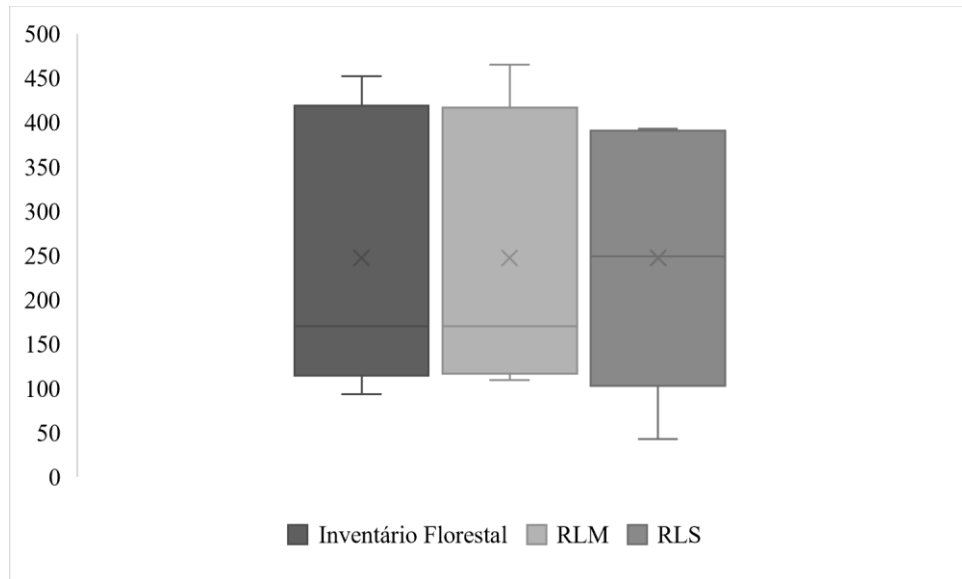
Figura 14. Resultado do melhor modelo para estimar AGB para os polígonos de 800m<sup>2</sup>, regressão linear simples usando a métrica Lidar zpcum3.



Fonte: Autor (2024)

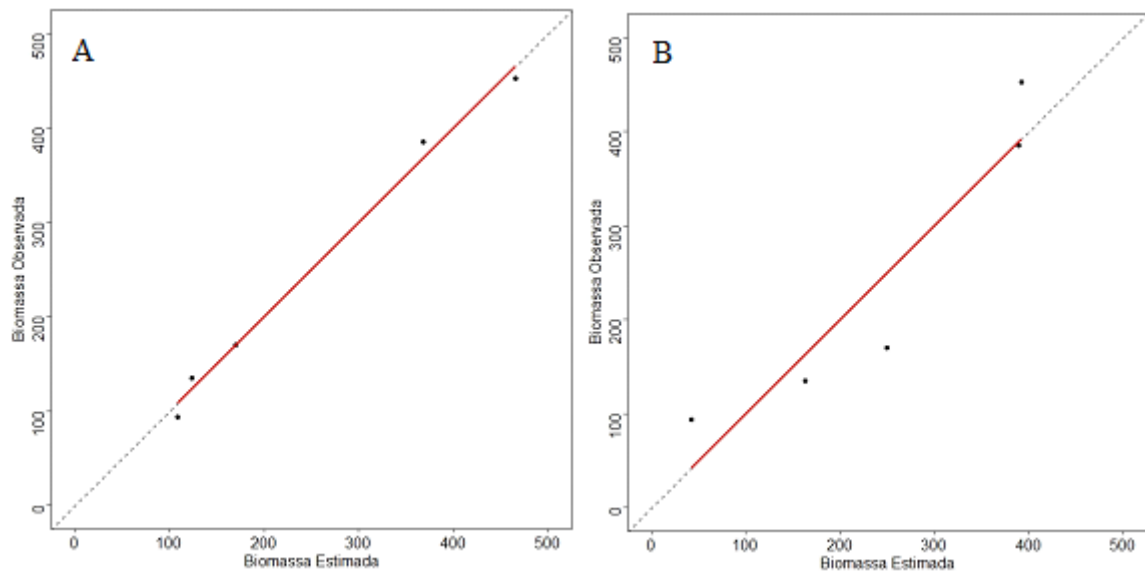
Nas Figura 15 compara-se a AGB estimada e a calculada pelo inventário florestal e na Figura 16 observamos o gráfico de resíduos. O modelo RLM apresentou uma modelagem mais precisa.

Figura 15. Comparativo da AGB obtido pelo inventário florestal, com os modelos de regressão gerado RLM e RLS (t/ha). Em que: RLM- regressão linear múltipla; RLS- regressão linear simples.



Fonte: Autor (2024)

Figura 16. Gráficos de resíduos da AGB observada versus AGB estimada. Em que: A- regressão linear múltipla; B- regressão linear simples.



Fonte: Autor (2024).

Na Tabela 10 é mostrado o resultado para a validação dos modelos de regressão. O RLM apresentou um RMSE de 58,49t/ha, indicando que o modelo apresenta um bom ajuste para estimativa da AGB. O BIAS demonstra a tendência de superestimar ou subestimar as estimativas. Ambos os modelos subestimaram AGB quando comparado aos dados de campo.

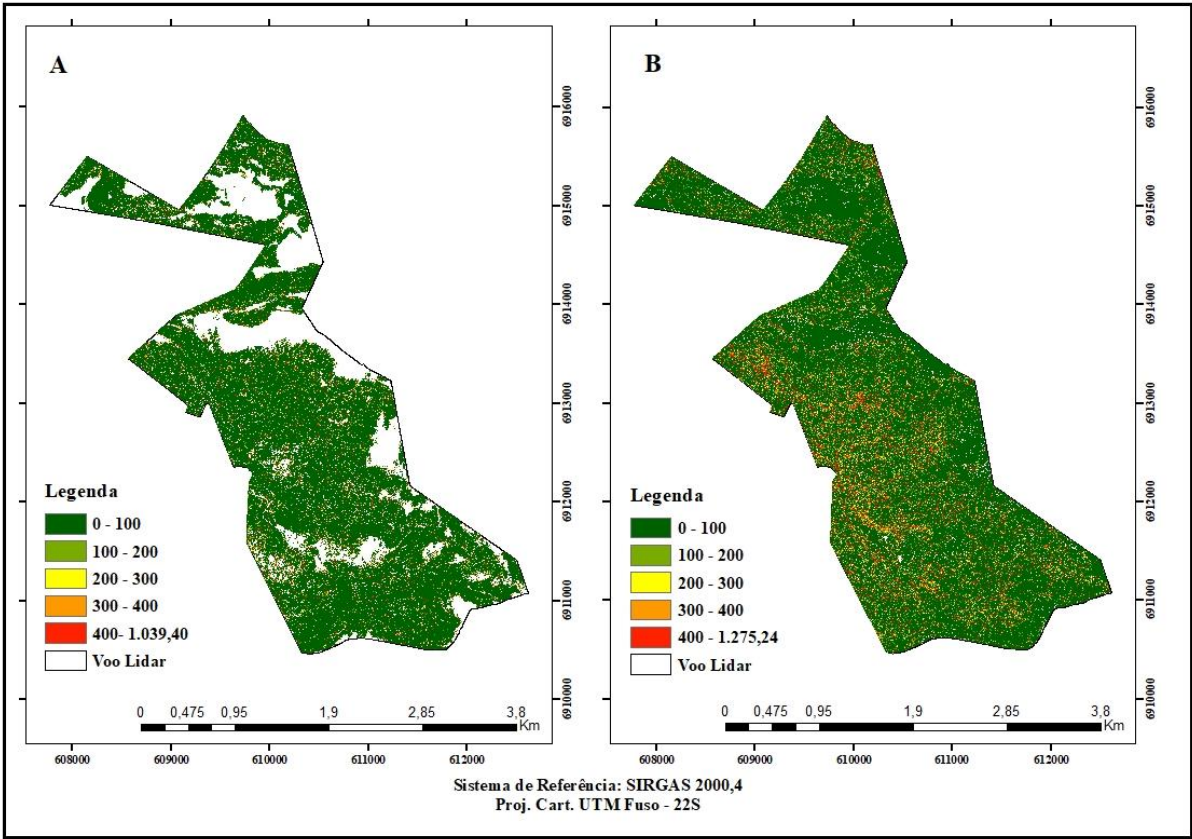
Tabela 10. Validação dos modelos de regressão (t/ha).

Parcelas	Inventário Florestal	RLM	RLS	RMSE RLM	RMSE RLS	BIAS RLM	BIAS RLS
2	291,82	211,83	116,98	<b>58,49</b>	148,55	-29,46	-29,19
6	176,79	197,86	293,25				

Em que: RLM- regressão linear múltipla; RLS- regressão linear simples. Fonte: Autor (2024)

Na Figura 14 representa a distribuição da AGB na RPPN Complexo Serra da Farofa. Onde: A foi aplicado a RLM e a biomassa variando de 0 a 1039,40 (t/ha) e em B foi aplicado o RLS e a biomassa variando de 0 a 1275,24 (t/ha).

Figura 17. Espacialização AGB (t/ha). Em que A- usou-se regressão linear múltipla especificada na Figura 13; B- usou-se a regressão linear simples especificada na Figura 14.



Fonte: Autor (2024)

Os modelos RLM e RLS atendem as condicionantes da regressão; normalidade dos resíduos, ausência de *outliers* nos resíduos, independência dos resíduos, homocedasticidade e multicolinearidade (aplicado no RLM). Os resultados das análises dos pressupostos, as imagens das métricas usadas nos modelos de regressão e análise estatística *do Stepwise* para escolha das variáveis são apresentados no apêndice.

## 7. DISCUSSÃO

O CHM fornece dados sobre as alturas da floresta, possibilitando a avaliação da estrutura vertical, o que é diretamente relacionado ao volume e à biomassa da vegetação (CUNHA; CENTENO, 2005; AHMAD *et al.*, 2023). Com isso é possível realizar a identificação das copas e suas respectivas dimensões, entre outros parâmetros que são cruciais para a caracterização das árvores (CUNHA; CENTENO, 2005; SALEKIN *et al.*, 2024), permitindo a realização de medições individuais (PERSSON *et al.*, 2002; GAO; ZHANG, 2021; SALEKIN *et al.*, 2024).

A diferenças entre as alturas observadas é destacada pela heterogeneidade da floresta nativa. Essa variação foi observada no trabalho de Gao e Zhang (2021), em que desigualdade das alturas e formas das copas das árvores se reflete na segmentação dos CHMs, ajustando-se a valores diferentes de escala para diferentes copas. O uso do CHM em grandes áreas florestais se torna uma alternativa viável em relação ao tempo e recurso disponíveis (CUNHA; CENTENO, 2005).

HE *et al.* (2013) encontraram que as variáveis derivadas do Lidar, como a altura média e a cobertura da copa, são as mais significativas para prever a AGB, com  $R^2$  ajustados de 0,727 e RMSE 15.237, em uma regressão linear múltipla.

Em Sheridan *et al.* (2015), os modelos regressão usando métricas derivados do Lidar foram testadas em três tamanho amostrais, sendo estas caracterizadas como sub parcelas, parcelas e em hectare. As melhores métricas para AGB nas sub parcelas foram altura média, hb20-25 e d3 (hb – faixas de alturas e d - densidade), com o  $R^2$  de 0,77, 0,52 e 0,67, respectivamente. Para as parcelas, as métricas altura média, hb20-25 e d3, obtiveram um  $R^2$  de 0,83, 0,56 e 0,76, e para hectare, as métricas foram altura média, hb15-20 e d3, com  $R^2$  de 0,73, 0,63 e 0,73, respectivamente para regressão linear simples. Nos modelos de regressão múltipla, as métricas de altura ou densidade aumentaram a capacidade preditiva, apresentando um  $R^2$  de 0,78 para as três sub parcelas, para as parcelas o  $R^2$  foi de 0,87, 0,86 e 0,86 e para área (hectare) foi de 0,74 e de 0,75.

Gao e Zhang (2021) identificaram as variáveis mais relevantes da nuvem de pontos Lidar para estimar a AGB em plantações com estrutura florestal complexa. Para o cipreste chinês, as variáveis principais foram altura média da copa, variância de altura, percentil de

altura e média da diferença de altura. Para o pinheiro, destacaram-se a mediana da altura, percentil de altura, declive e rugosidade do terreno. Para o eucalipto, as variáveis mais importantes foram percentis de altura H60, H50 (H - altura), mediana e alturas da copa nos percentis Hc40, Hc20 e Hc50 (Hc – altura acumulada). Para outras árvores de folha larga, as variáveis significativas foram percentil 1, dissimilaridade de altura e mediana da altura. Os modelos não lineares apresentaram maior precisão de treinamento para AGB, exceto para o eucalipto (0,56). Para outras árvores de folha larga, a precisão foi de 0,79, e para cedro chinês e pinheiros, acima de 0,9. Entre os modelos lineares, a regressão *Stepwise* foi a mais precisa, com 0,72 para o eucalipto. No caso das árvores de folha larga, a regressão de *ridge* foi a mais precisa (0,52), seguida pela *stepwise*. Em geral, os modelos não lineares mostraram maior precisão, seguidos pelo método *stepwise*.

Evidencia-se que para diferentes composições florestais pode-se obter diferentes métricas altamente correlacionadas aos dados de inventário. Para este trabalho as métricas *zpcum3* e *zpcum5* representam percentis acumulados de altura, enquanto *zentropy* mede a complexidade da distribuição de altura. Sendo a variável *zpcum3* e *zentropy* para parcelas de 200m<sup>2</sup> a que apresentou uma correlação de Pearson de 0,82 e 0,74 respectivamente, indicando forte e moderada correlação com a AGB obtida por inventário florestal. A métricas *zpcum3* apresentaram correlações de 0,93 (muito forte) para parcelas de 800m<sup>2</sup>.

Os modelos foram treinados de forma independente para os polígonos de 200 m<sup>2</sup> e 800 m<sup>2</sup>. A comparação entre diferentes tamanhos de recortes da nuvem de pontos permite identificar quais modelos forneceram estimativas mais precisas. O polígono de 200 m<sup>2</sup> obteve um R<sup>2</sup> de 0,996 e um RMSE de 12,73 t/ha indicando uma boa precisão nas estimativas de biomassa. O polígono de 800 m<sup>2</sup> obteve um R<sup>2</sup> de 0,934 e um RMSE de 51,4 t/ha, sugerindo que o tamanho do recorte da nuvem de pontos pode influenciar na estimativa da AGB.

Nesse sentido, a diferença do RMSE pode estar relacionada com o tamanho da parcela de calibração utilizada, que era de 200 m<sup>2</sup>. No entanto, se a parcela em campo tivesse o mesmo tamanho do polígono de 800 m<sup>2</sup>, que foi usado para fazer o recorte na nuvem de pontos Lidar, o RMSE poderia ser menor em relação ao polígono de 200 m<sup>2</sup>. Quanto maior a parcela de campo (calibração) e o polígono referente à parcela (de campo usada para calibrar), maiores são as informações disponíveis, que podem ser usadas para estimar a AGB.

Melo (2017) e Rex (2019) observaram que parcelas menores podem subestimar a biomassa, pois não representa eficazmente a distribuição diamétrica da floresta (MASCARO *et al.*, 2011). Isso ocorre porque parcelas menores têm menor probabilidade de incluir árvores com grandes diâmetros, que contribuem significativamente para a biomassa total. Asner e Mascaro (2014) também destacaram a influência do tamanho da parcela na estimativa da biomassa (ou do estoque de carbono).

Eles demonstraram que, à medida que o tamanho da parcela aumentava para 1 ha, a incerteza entre as estimativas de biomassa obtidas pelo Lidar e os dados de campo diminuía constantemente. Em escalas de 1 ha, os erros entre as estimativas feitas pelo Lidar e as feitas no campo foram de 10 a 14%, indicando uma boa precisão nas estimativas quando se usaram parcelas maiores. Maurya *et al.* (2015) discutem que o tamanho da parcela tem um impacto significativo na predição da biomassa. Parcelas maiores melhoram a precisão dos modelos, pois capturam mais variação espacial, reduzem o erro de posicionamento e diminuem o efeito das bordas das parcelas, que podem causar discrepâncias entre os dados de campo e o Lidar.

A espacialização de biomassa com dados LiDAR é uma ferramenta precisa para estimar biomassa em larga escala, reduzindo custos e esforços de campo, além de apoiar o manejo florestal e políticas públicas (SILVA, 2013). Essa abordagem possibilita análises espaciais detalhadas e temporais, como o monitoramento de mudanças no estoque de carbono devido a práticas de manejo ou eventos como desmatamentos (MAPPING GLOBAL FOREST ABOVEGROUND BIOMASS, 2016). Contudo, limitações como saturação do sensor em florestas densas (CHEN, 2012) e discrepâncias entre inventários e dados Lidar, especialmente com parcelas pouco representativas, podem levar a erros (SAARELA *et al.*, 2015). A integração de Lidar e inventários, associada a técnicas como aprendizado de máquina, melhora a precisão das estimativas. Métricas Lidar combinadas com variáveis de campo, como densidade da madeira, reduzem erros (CAO *et al.*, 2014), enquanto redes neurais e modelos avançados aumentam a confiabilidade das estimativas (LI *et al.*, 2020).

## 8. CONCLUSÕES

O uso de Lidar aerotransportado para estimar a biomassa acima do solo (AGB) no fragmento de Floresta Ombrófila Mista Alto-Montana foi eficaz, apresentando boa correlação entre as métricas derivadas do Lidar e os dados de campo, especialmente para os polígonos de 200 m<sup>2</sup>, onde a correlação entre *zpcum5* e *zentropy* com a AGB foi elevada (0,82 e 0,74, respectivamente). Isso valida a hipótese de que os dados obtidos pelo LiDAR têm uma relação significativa com os dados de campo.

A partir do CHM e das métricas extraídas da nuvem de pontos Lidar, foi possível desenvolver dois modelos de regressão (linear simples e múltipla) para a estimativa da biomassa. O modelo de regressão múltipla se mostrou mais aderente, apresentando um R<sup>2</sup> de 0,996 e RMSE de 12,73 t/ha para os polígonos de 200m<sup>2</sup>. Esse modelo demonstrou ser eficaz, com um erro relativamente baixo e uma boa explicação da variabilidade da AGB nas parcelas estudadas, atendendo aos objetivos do estudo e mostrando que a metodologia pode ser uma alternativa viável às abordagens tradicionais de inventário florestal.

O modelo de regressão linear simples fornecido pelos polígonos de 800 m<sup>2</sup>, apresentou um resultado satisfatório da estimativa da AGB com um R<sup>2</sup> de 0,934, porém com RMSE de 51,4 t/ha, superior ao modelo de regressão múltipla. Isso pode ter ocorrido pelo tamanho da parcela de campo ser menor que do polígono usado para recorta e nuvem de pontos Lidar.

Por fim, recomenda-se que futuros estudos investiguem a calibração de modelos utilizando diferentes tamanhos de parcelas para refinar as estimativas de AGB. Além disso, estudos comparativos entre diferentes modelos de regressão e métricas Lidar, incluindo a comparação entre abordagens simples e múltiplas, poderiam fornecer insights adicionais sobre a precisão e aplicabilidade dos métodos para áreas florestais heterogêneas.

## 9. REFERÊNCIA BIBLIOGRÁFICA

AHMAD, Naveed; ULLAH, Saleem; ZHAO, Na; MUMTAZ, Faisal; ALI, Asad; ALI, Anwar; TARIQ, Aqil; KAREEM, Mariam; IMRAN, Areeba Binte; KHAN, Ishfaq Ahmad. Comparative Analysis of Remote Sensing and Geo-Statistical Techniques to Quantify Forest Biomass. **Forests**, v. 14, n. 2, p. 379, 13 fev. 2023. MDPI AG, *doi:10.3390/f14020379*.

AHMAD, A.; LIU, J.; LIU, Q.; ULLAH, S.; KHALID, F.; TAIMURE; ISMAIL, M.; MANNAN, A. Tree species composition, growing stock and biomass carbon dynamics of the major timber species in Hindu Kush regions of Pakistan. **Brazilian Journal of Biology**, v. 84, p. 1-13, 2024.

ASNER, Gregory P.; MASCARO, Joseph. Mapping tropical forest carbon: calibrating plot estimates to a simple lidar metric. **Remote Sensing of Environment**, v. 140, p. 614-624, jan. 2014. Elsevier BV, *doi:10.1016/j.rse.2013.09.023*.

BAGNATO, V. S. Os fundamentos da luz LASER. Física na Escola, São Carlos, v. 2, n. 2, p. 4-9, 2001.

BALTSAVIAS, E. P. Airborne laser scanning: existing systems and firms and other resources. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, n. 2, p. 164-198, 1999.

BEAUDOIN, Guillaume; RAFANOHARANA, Serge; BOISSIÈRE, Manuel; WIJAYA, Arief; WARDHANA, Wahyu. Completing the Picture: importance of considering participatory mapping for redd+ measurement, reporting and verification (mrv). **Plos One**, v. 11, n. 12, p. 1-24, 15 dez. 2016. Public Library of Science (PLoS), *doi:10.1371/journal.pone.0166592*.

BEHLING, Alexandre. **Modelagem da biomassa de árvores para assegurar aditividade dos seus componentes**. 117 f. Tese (Doutorado em Engenharia Florestal) – Setor de Ciências Florestais – Universidade Federal do Paraná, Curitiba, 2016.

BIRDSEY, Richart. A. Carbon accounting rules and guidelines for the United States Forest Sector. **Journal of Environmental Quality, Madison**, v. 35, p. 1518-1524, 2006.

BRANDALIZE, M. C. B.; PHILIPS, J. W. Padrões de classificação de equipamentos laser utilizados em levantamentos terrestres e aéreos. **Geodésia Online-Revista da Comissão Brasileira de Geodésia**, Florianópolis, v. 1, p. 1, 2002.

CALDEIRA, Marcos Vinicius Winckler; WATZLAWICK, Luciano Farinha; SOARES, Ronaldo Viana; VALÉRIO, Alvaro Felipe. Estimativa de Biomassa em Espécies Arbóreas da

Floresta Ombrófila Mista Montana - General Carneiro-PR. **Biomassa & Energia**, v.1, p.291-310, 2004.

CAMPBELL, Bruce M. Beyond Copenhagen: redd+, agriculture, adaptation strategies and poverty. **Global Environmental Change**, v. 19, n. 4, p. 397-399, out. 2009. Elsevier BV, *doi:10.1016/j.gloenvcha.2009.07.010*.

CHAMBERS, Jeffrey Q; SANTOS, Joaquim dos; RIBEIRO, Ralfh J; HIGUCHI, Niro. Tree damage, allometric relationships, and above-ground net primary production in central Amazon forest. **Forest Ecology and Management**, v. 152, n. 1-3, p. 73-84, out. 2001. Elsevier BV, *doi:10.1016/s0378-1127(00)00591-0*.

CHEN, Q. LiDAR remote sensing of vegetation biomass. **Remote Sensing of Environment**, v. 121, p. 186-193, 2012. *doi: 10.1016/j.rse.2012.02.022*.

CARDOSO, Denise Jeton; PARRON, Lucilia Maria; FRANCISCON, Luziane. Carbono de biomassa em floresta nativa e sistemas florestais como indicador de serviços ambientais. **Serviços Ambientais em Sistemas Agrícolas**, Brasília, Embrapa. 2015.

CAO, L.; ZHU, X.; JIA, K. Improved estimates of forest biomass using LiDAR data and the integration of key environmental variables. **Ecological Indicators**, v. 45, p. 593-602, 2014. *doi: 10.1016/j.ecolind.2014.05.024*.

CORTE, Ana Paula Dalla; BROADBENT, Eben North; SANTOS, Lucas Henderson de Oliveira; KARASINSKI, Mauro Alessandro; SANQUETTA, Carlos Roberto; PRATA, Gabriel Atticciati; ALMEIDA, Danilo Roberti Alves de; SILVA, Carlos Alberto. **Aplicações do lidar para o inventário florestal** –: enfoque unidade de área. Ponta Grossa - Pr: Antena, 2022.

CUNHA, F; CENTENO, C. T. M. Segmentação de imagens geradas por perfilamento a laser para delimitação de árvores individuais em uma área de reflorestamento de eucaliptos. In: **Simpósio Brasileiro de Sensoriamento Remoto**, 12. (SBSR), Goiânia. Anais. São José dos Campos: INPE. p. 737-744. ISBN 85-17-00018-8, 2005

DELITTI, Welington Braz Carvalho; PAUSAS, Juli Garcia; BURGER, Deborah Moreira. Belowground biomass seasonal variation in two Neotropical savannahs (Brazilian Cerrados) with different fire histories. **Annals of Forest Science**, v. 58, n. 7, p. 713-721, out. 2001. EDP Sciences, *doi:10.1051/forest:2001158*.

FONTOURA, Máгда Rosa; CARON, Braulio Otomar; ELOY, Elder; TREVISAN, Rômulo; TRAUTENMÜLLER, Jonathan William; BEHLING, Alexandre. Modelos alométricos para estimativa de biomassa em área de regeneração natural de *Ateleia glazioviana* baill. **Floresta**, Curitiba, v. 47, n. 4, p. 469-478, 2017.

FRY, Ian. Reducing Emissions from Deforestation and Forest Degradation: opportunities and pitfalls in developing a new legal regime. **Review of European Community & International Environmental Law**, v. 17, n. 2, p. 166-182, ago. 2008. Wiley, doi:10.1111/j.1467-9388.2008.00597.x.

GAO, Linghan; ZHANG, Xiaoli. 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. 1-19, 6 dez. 2021. MDPI AG, doi:10.3390/f12121713.

GARCIA-GUTIERREZ, Jorge; GONZALEZ-FERREIRO, Eduardo; RIQUELME-SANTOS, Jose C.; MIRANDA, David; DIEGUEZ-ARANDA, Ulises; NAVARRO-CERRILLO, Rafael M. Evolutionary feature selection to estimate forest stand variables using LiDAR. **International Journal of Applied Earth Observation and Geoinformation**, v. 26, p. 119-131, fev. 2014. Elsevier BV, doi:10.1016/j.jag.2013.06.005.

GIBBS, Holly K; BROWN, Sandra; NILES, John O; A FOLEY, Jonathan. Monitoring and estimating tropical forest carbon stocks: making REDD a reality. **Environmental Research Letters**, v. 2, n. 4, p. 1-13, out. 2007. IOP Publishing, doi:10.1088/1748-9326/2/4/045023.

GIONGO, Marcos; KOEHLER, Henrique Soares; MACHADO, Sebastião do Amaral; KIRCHNER, Flavio Felipe; MARCHETTI, Marco. LiDAR: princípios e aplicações florestais. **Pesquisa Florestal Brasileira**, v. 30, n. 63, p. 231-244, 28 out. 2010. Embrapa Florestas, doi:10.4336/2010.pfb.30.63.231.

GOETZ, Scott; DUBAYAH, Ralph. Advances in remote sensing technology and implications for measuring and monitoring forest carbon stocks and change. **Carbon Management**, v. 2, n. 3, p. 231-244, jun. 2011. Informa UK Limited, doi:10.4155/cmt.11.18.

HE, Qisheng; CHEN, Erxue; AN, Ru; LI, Yong. Above-Ground Biomass and Biomass Components Estimation Using LiDAR Data in a Coniferous Forest. **Forests**, v. 4, n. 4, p. 984-1002, 20 nov. 2013. MDPI AG, doi:10.3390/f4040984.

HEBBALI, A. **olsrr: Tools for building regression models**. 2020. Disponível em: <https://cran.r-project.org/web/packages/olsrr/index.html>. Acesso em: 20 jun. 2024.

HERNÁNDEZ-STEFANONI, José Luis; REYES-PALOMEQUE, Gabriela; CASTILLO-SANTIAGO, Miguel Ángel; GEORGE-CHACÓN, Stephanie P.; HUECHACONA-RUIZ, Astrid Helena; TUN-DZUL, Fernando; RONDON-RIVERA, Dinosca; DUPUY, Juan Manuel. Effects of Sample Plot Size and GPS Location Errors on Aboveground Biomass Estimates from LiDAR in Tropical Dry Forests. **Remote Sensing**, v. 10, n. 10, p. 1-15, 2 out. 2018. MDPI AG, *doi*:10.3390/rs10101586.

HIGUCHI, Niro; CHAMBERS, Jeffrey; SANTOS, Joaquim dos; RIBEIRO, Ralfh João; PINTO, Alberto Carlos Martins; SILVA, Roseana Pereira da; ROCHA, Rosana de Miranda; TRIBUZY, Edgard Siza. Dinâmica e balanço do carbono da vegetação primária da Amazônia Central. **Floresta**, v.34 p.295-304, 2004.

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. Cambridge University Press, 2021.

JENSEN, John R. Sensoriamento Remoto Do Ambiente: Uma Perspectiva Em Recursos Terrestres (Tradução Da Segunda Edição). Inf. Syst. 2009.

JIMÉNEZ, E; VEGA, Ja; FERNÁNDEZ-ALONSO, Jm; VEGA-NIEVA, D; ORTIZ, L; LÓPEZ-SERRANO, Pm; LÓPEZ-SÁNCHEZ, Ca. Estimation of aboveground forest biomass in Galicia (NW Spain) by the combined use of LiDAR, LANDSAT ETM+ and National Forest Inventory data. **Iforest – Biogeosciences and Forestry**, v. 10, n. 3, p. 590-596, 30 jun. 2017. Italian Society of Silviculture and Forest Ecology (SISEF), *doi*:10.3832/ifor1989-010.

KLABIN S.A. **Reservas Particulares do Patrimônio Natural (RPPN'S)**. Disponível em: <https://klabin.com.br/sustentabilidade/meio-ambiente-e-biodiversidade/rppns>. Acesso em: 18 fev. 2024.

KLABIN S.A. **Plano de manejo RPPN Complexo Serra da Farofa**. 2020.

LAY, Usman Salihu; PRADHAN, Biswajeet; YUSOFF, Zainuddin Bin Md; ABDALLAH, Ahmad Fikri Bin; ARYAL, Jagannath; PARK, Hyuck-Jin. Data Mining and Statistical Approaches in Debris-Flow Susceptibility Modelling Using Airborne LiDAR Data. **Sensors**, v. 19, n. 16, p. 3451, 7 ago. 2019. MDPI AG, *doi*:10.3390/s19163451.

LAURIN, Gaia Vaglio; CHEN, Qi; LINDSELL, Jeremy A.; COOMES, David A.; FRATE, Fabio del; GUERRIERO, Leila; PIROTTI, Francesco; VALENTINI, Riccardo. Above ground biomass estimation in an African tropical forest with lidar and hyperspectral data. **Isprs Journal of Photogrammetry and Remote Sensing**, v. 89, p. 49-58, mar. 2014. Elsevier BV, *doi:10.1016/j.isprsjprs.2014.01.001*.

LEFSKY, Michael A.; COHEN, Warren B.; PARKER, Geoffrey G.; HARDING, David J. Lidar Remote Sensing for Ecosystem Studies. **Bioscience**, v. 52, n. 1, p. 19-30, 2002. Oxford University Press (OUP), *doi:10.1641/0006-3568(2002)052[0019:lrsfes]2.0.co;2*.

LI, Chungan; LIN, Xin; DAI, Huabing; LI, Zhen; ZHOU, Mei. Effects of Plot Size on Airborne LiDAR-Derived Metrics and Predicted Model Performances of Subtropical Planted Forest Attributes. **Forests**, v. 13, n. 12, p. 1-15, 11 dez. 2022. MDPI AG, *doi:10.3390/f13122124*.

LI, W.; LIU, L.; LI, S. Machine learning approaches for estimating forest aboveground biomass using LiDAR data. *Forests*, v. 11, n. 7, p. 754, 2020. Disponível em: <https://doi.org/10.3390/f11070754>.

LILLESAND, Thomas. M.; KIEFER, Ralph. W.; CHIPMAN, Jonathan. W. Remote sensing and image interpretation. 7. ed. Hoboken: Wiley, 2015.

LIU, Luxia; PANG, Yong; LI, Zengyuan; SI, Lin; LIAO, Shengxi. Combining Airborne and Terrestrial Laser Scanning Technologies to Measure Forest Understorey Volume. **Forests**, v. 8, n. 4, p. 111, 6 abr. 2017. MDPI AG, *doi:10.3390/f8040111*.

MASCARO, J. et al. Evaluating uncertainty in mapping forest carbon with airborne LiDAR. **Remote Sensing of Environment**, v. 115, n. 12, p. 3770-3774, 2011.

MALHI, Yadvinder; SAATCHI, Sassan; GIRARDIN, Cecile; ARAGÃO, Luiz E. O. C. The production, storage, and flow of carbon in Amazonian forests. **Amazonia and Global Change**, p. 355-372, 2009. American Geophysical Union, *doi:10.1029/2008gm000779*.

MAUYA, Ernest William; ENE, Liviu Theodor; BOLLANDSÅS, Ole Martin; GOBAKKEN, Terje; NÆSSET, Erik; MALIMBWI, Rogers Ernest; ZAHABU, Eliakimu. Modelling aboveground forest biomass using airborne laser scanner data in the miombo woodlands of Tanzania. **Carbon Balance and Management**, v. 10, n. 1, p. 1-16, dez. 2015. Springer Science and Business Media LLC, *doi:10.1186/s13021-015-0037-2*.

MELIN, Markus; SHAPIRO, Aurelie C.; GLOVER-KAPFER, Paul. LiDAR for ecology and conservation - WWF Conservation Technology Series (3). **Unpublished**, p. 1-41, 2017. Unpublished, *doi:10.13140/RG.2.2.22352.76801*.

MELO, Antonio Willian Flores. **Alometria de Árvores e Biomassa Florestal na Amazônia Sul-Occidental**, 2017. Tese (Doutorado em Ciências de Florestas Tropicais), Instituto Nacional de Pesquisas da Amazônia Programa de Pós-Graduação em Ciências de Florestas Tropicais, 154 f. 2017.

NI-MEISTER, Wenge; LEE, Shihyan; STRAHLER, Alan H.; WOODCOCK, Curtis E.; SCHAAF, Crystal; YAO, Tian; RANSON, K. Jon; SUN, Guoqing; BLAIR, J. Bryan. Assessing general relationships between aboveground biomass and vegetation structure parameters for improved carbon estimate from lidar remote sensing. **Journal of Geophysical Research: Biogeosciences**, v. 115, n. 2, p. 1-12, jun. 2010. American Geophysical Union (AGU), *doi:10.1029/2009jg00093*.

OEHMCKE, Stefan; LI, Lei; TREPEKLI, Katerina; REVENGA, Jaime C.; NORD-LARSEN, Thomas; GIESEKE, Fabian; IGEL, Christian. Deep point cloud regression for above-ground forest biomass estimation from airborne LiDAR. **Remote Sensing of Environment**, v. 302, p. 113968, mar. 2024. Elsevier BV, *doi:10.1016/j.rse.2023.113968*.

PACKALÉN, Petteri; MALTAMO, Matti. The k-MSN method for the prediction of species-specific stand attributes using airborne laser scanning and aerial photographs. **Remote Sensing of Environment**, v. 109, n. 3, p. 328-341, ago. 2007. Elsevier BV, *doi:10.1016/j.rse.2007.01.005*.

PAN, Yude; BIRDSEY, Richard A.; FANG, Jingyun; HOUGHTON, Richard; KAUPPI, Pekka E.; KURZ, Werner A.; PHILLIPS, Oliver L.; SHVIDENKO, Anatoly; LEWIS, Simon L.; CANADELL, Josep G. A Large and Persistent Carbon Sink in the World's Forests. **Science**, v. 333, n. 6045, p. 988-993, 19 ago. 2011. American Association for the Advancement of Science (AAAS), *doi:10.1126/science.1201609*.

PEREIRA, A.; GOMES, A.; PEREZ-ALBERTI, A. Vantagens da utilização de dados ALS (LiDAR) na caracterização morfológica das vertentes costeiras da Galiza Espanha: aplicação ao setor de Mougás. **Revista de Geografia e Ordenamento do Território**, Porto, v. 1, n. 4, p. 223-248, 2013.

PEREIRA, J. P. **Mensuração automática de copas de *Araucaria angustifolia* (Bertol.) Kuntze a partir de dados LiDAR para estimativa de variáveis dendrométricas.** 140 f. Dissertação (Mestrado) - Programa de Pós-Graduação em Engenharia Florestal, CAV - UDESC. Lages, 2014.

PERSSON, A; HOLMGREN, J; SODERMAN, U. Detecting and measuring individual trees using an airborne laser scanner. **Photogrammetric Engineering and Remote Sensing**, v. 68, n. 9, p. 925-932, 2002.

PILLODAR, Fejaycris O.; MERO, Danilo C.; MOSTRALES, Daniel S.; ASTILLERO, Shara Grace C.; IGNACIO, Ma. Teresa T. Estimation of Aboveground Biomass and Carbon Stock of Bacolod Protected Landscape and Seascape Using LiDAR Data and GIS. **International Journal of Advances in Agricultural and Environmental Engineering**, v. 4, n. 1, p. 1-5, 26 jan. 2017. International Institute of Engineers, *doi:10.15242/ijaaee.c0117003*.

POPESCU, Sorin C.. Estimating biomass of individual pine trees using airborne lidar. **Biomass and Bioenergy**, v. 31, n. 9, p. 646-655, set. 2007. Elsevier BV, *doi:10.1016/j.biombioe.2007.06.022*.

POPESCU, Sorin C.; ZHAO, Kaiguang; NEUENSCHWANDER, Amy; LIN, Chinsu. Satellite lidar vs. small footprint airborne lidar: comparing the accuracy of aboveground biomass estimates and forest structure metrics at footprint level. **Remote Sensing of Environment**, v. 115, n. 11, p. 2786-2797, nov. 2011. Elsevier BV, *doi:10.1016/j.rse.2011.01.026*.

REUTEBUCH, Stephen E.; ANDERSEN, Hans-Erik; MCGAUGHEY, Robert J. Light detection and ranging (LIDAR): an emerging tool for multiple resource inventory. **Journal of forestry**, v. 103, n. 6, p. 286-292, 2005.

REX, Franciel Eduardo. **Estimativas do estoque e dinâmica de biomassa acima do solo utilizando diferentes abordagens estatísticas e dados Lidar em floresta tropical.** 2019. 119 f. Tese (Doutorado) - Curso de Programa de Pós-Graduação em Engenharia Florestal, Universidade Federal do Paraná, Curitiba, 2019.

REZENDE, Alba Valéria; VALE, Ailton Teixeira do; SANQUETTA, Carlos Roberto; FIGUEIREDO FILHO, Afonso; FELFILI, Jeanine Maria. Comparação de modelos matemáticos para estimativa do volume, biomassa e estoque de carbono da vegetação lenhosa de um cerrado *sensu stricto* em Brasília, DF. **Scientia Forestalis**, n.71, p.65-76, 2006.

ROUSSEL, Jean-Romain; AUTY, David; COOPS, Nicholas C.; TOMPALSKI, Piotr; GOODBODY, Tristan R.H.; MEADOR, Andrew Sánchez; BOURDON, Jean-François; BOISSIEU, Florian de; ACHIM, Alexis. LidR: an r package for analysis of airborne laser scanning (ALS) data. **Remote Sensing of Environment**, v. 251, p. 1-15, dez. 2020. Elsevier BV, *doi:10.1016/j.rse.2020.112061*.

SAARELA, S.; KÄRKKÄINEN, N.; SÄYNÄJÄKANGAS, T. Effects of sample size and model form on the accuracy of model-based estimators of growing stock volume. **Canadian Journal of Forest Research**, v. 45, n. 11, p. 1524-1534, 2015. Disponível em: <https://doi.org/10.1139/cjfr-2015-0169>.

SALIS, Suzana M.; ASSIS, Marco A.; MATTOS, Patrícia P.; PIÃO, Antonio C.s. Estimating the aboveground biomass and wood volume of savanna woodlands in Brazil's Pantanal wetlands based on allometric correlations. **Forest Ecology and Management**, v. 228, n. 1-3, p. 61-68, jun. 2006. Elsevier BV, *doi:10.1016/j.foreco.2006.02.025*.

SANTOS, Kleber dos; SANQUETTA, Carlos Roberto; EISFIELD, Rozane de Loyola; WATZLAWICK, Luciano Farinha; ZILIOTTO, Marco Aurélio Busch; PIZZATTO, Pedro N. Equações volumétricas por classe diamétrica para algumas espécies folhosas da Floresta Ombrófila Mista no Paraná, Brasil. **Revista de Ciências Exatas e Naturais**, v.8, v.1, p.99-112, 2006.

SALEKIN, Serajis; PONT, David; DICKINSON, Yvette; AMARASENA, Sumedha. Spatially Explicit Individual Tree Height Growth Models from Bi-Temporal Aerial Laser Scanning. **Remote Sensing**, v. 16, n. 13, p. 1-15, 21 jun. 2024. MDPI AG, *doi:10.3390/rs16132270*.

SCARANO, Fabio Rubio; CEOTTO, Paula. Brazilian Atlantic forest: impact, vulnerability, and adaptation to climate change. **Biodiversity And Conservation**, v. 24, n. 9, p. 2319-2331, set. 2015. Springer Science and Business Media LLC, *doi: 10.1007/s10531-015-0972-y*.

SCHWAAB, Jonas; DAVIN, Edouard L.; BEBI, Peter; DUGUAY-TETZLAFF, Anke; WASER, Lars T.; HAENI, Matthias; MEIER, Ronny. Increasing the broad-leaved tree fraction in European forests mitigates hot temperature extremes. **Scientific Reports**, v. 10, n. 1, p. 1-9, 25 ago. 2020. Springer Science and Business Media LLC, *doi:10.1038/s41598-020-71055-1*.

SHERIDAN, Ryan; POPESCU, Sorin; GATZIOLIS, Demetrios; MORGAN, Cristine; KU, Nian-Wei. Modeling Forest Aboveground Biomass and Volume Using Airborne LiDAR

Metrics and Forest Inventory and Analysis Data in the Pacific Northwest. **Remote Sensing**, v. 7, n. 1, p. 229-255, 24 dez. 2014. MDPI AG, *doi:10.3390/rs70100229*.

SILVA, Carlos Alberto; KLAUBERG, Carine; HENTZ, Ângela Maria Klein; CARVALHO, Samuel de Padua Chaves; CORTE, Ana Paula dalla. Predição da biomassa aérea em plantações de *Pinus taeda* L. por meio de dados LiDAR aerotransportado. **Scientia Forestalis**, v. 45, n. 115, p. 527-539, 1 set. 2017. Instituto de Pesquisa e Estudos Florestais (IPEF), *doi:10.18671/scifor.v45n115.10*.

SIMULA, Markku; MANSUR, Eduardo. A global challenge needing local response: a common approach to defining and measuring forest degradation can lead to unique solutions for addressing it. **Unasylva**, v 62 (238) p. 3-7, 2011.

SOUZA, Ivo Henrique Ribeiro; NICOLETTI, Marcos Felipe. Quantificação de biomassa e carbono em Floresta Ombrófila Mista Alto-Montana (relatório entregue para KLABIN S. A.), 2023.

SRINIVASAN, Shruthi; POPESCU, Sorin C.; ERIKSSON, Marian; SHERIDAN, Ryan D.; KU, Nian-Wei. Multi-temporal terrestrial laser scanning for modeling tree biomass change. **Forest Ecology and Management**, v. 318, p. 304-317, abr. 2014. Elsevier BV, *doi:10.1016/j.foreco.2014.01.038*.

TRAUTEN MÜLLER, Jonathan William. **Correlações e estimadores de biomassa acima do solo em florestas no sul do Brasil**. 2019. 119 f. Tese (Doutorado) - Curso de Programa de Pós-Graduação em Engenharia Florestal, Universidade Federal do Paraná, Curitiba, 2019.

WAGNER, W.; ULLRICH, A.; MELZER, T.; BRIESE, C.; KRAUS, K. From singlepulse to full-waveform airborne laser scanners: Potential and practical challenges. International Archives of Photogrammetry, **Remote Sensing and Spatial Information Sciences**, v. 35, p. 201–206, 2004.

WASER, L. T., BALTSAVIAS, E., ECKER, K., EISENBEISS, H., FELDMEYER-CHRISTE, E., GINZLER, C., KÜCHLER, M., ZHANG, L. Assessing changes of forest area and shrub encroachment in a mire ecosystem using digital surface models and CIR aerial images. **Remote Sensing of Environment**. v. 112, n. 5, p. 1956 – 1968, 2008.

WATZLAWICK, Luciano Farinha; GALLO, Maria Fernanda Subtil; RECH, Matheus; SENS, Talyta Mytsuy Zanardini Galeski; SILVA, Richeliel Albert Rodrigues; MAZON, Joelmir Augostinho. MÉTODO BOTANAL APLICADO A QUANTIFICAÇÃO DA BIOMASSA NA

SERAPILHEIRA EM FLORESTA OMBRÓFILA MISTA. **Conceitos e Conhecimentos de Métodos e Técnicas de Pesquisa Científica em Engenharia Florestal**, p. 120-131, 14 jan. 2021. Atena Editora. *doi:10.22533/at.ed.27721130111*.

WU, Chaofan; SHEN, Huanhuan; SHEN, Aihua; DENG, Jinsong; GAN, Muye; ZHU, Jinxia; XU, Hongwei; WANG, Ke. Comparison of machine-learning methods for above-ground biomass estimation based on Landsat imagery. **Journal of Applied Remote Sensing**, v. 10, n. 3, p. 1-17, 8 ago. 2016. SPIE-Intl Soc Optical Eng, *doi:10.1117/1.jrs.10.035010*.

ZHANG, Wuming; QI, Jianbo; WAN, Peng; WANG, Hongtao; XIE, Donghui; WANG, Xiaoyan; YAN, Guangjian. An Easy-to-Use Airborne LiDAR Data Filtering Method Based on Cloth Simulation. **Remote Sensing**, v. 8, n. 6, p. 1-22, 15 jun. 2016. MDPI AG, *doi:10.3390/rs8060501*.

ZENG, Peng; ZHANG, Wangfei; LI, Yun; SHI, Jianmin; WANG, Zhanhui. Forest Total and Component Above-Ground Biomass (AGB) Estimation through C- and L-band Polarimetric SAR Data. **Forests**, v. 13, n. 3, p. 1-19, 11 mar. 2022. MDPI AG, *doi:10.3390/f13030442*.

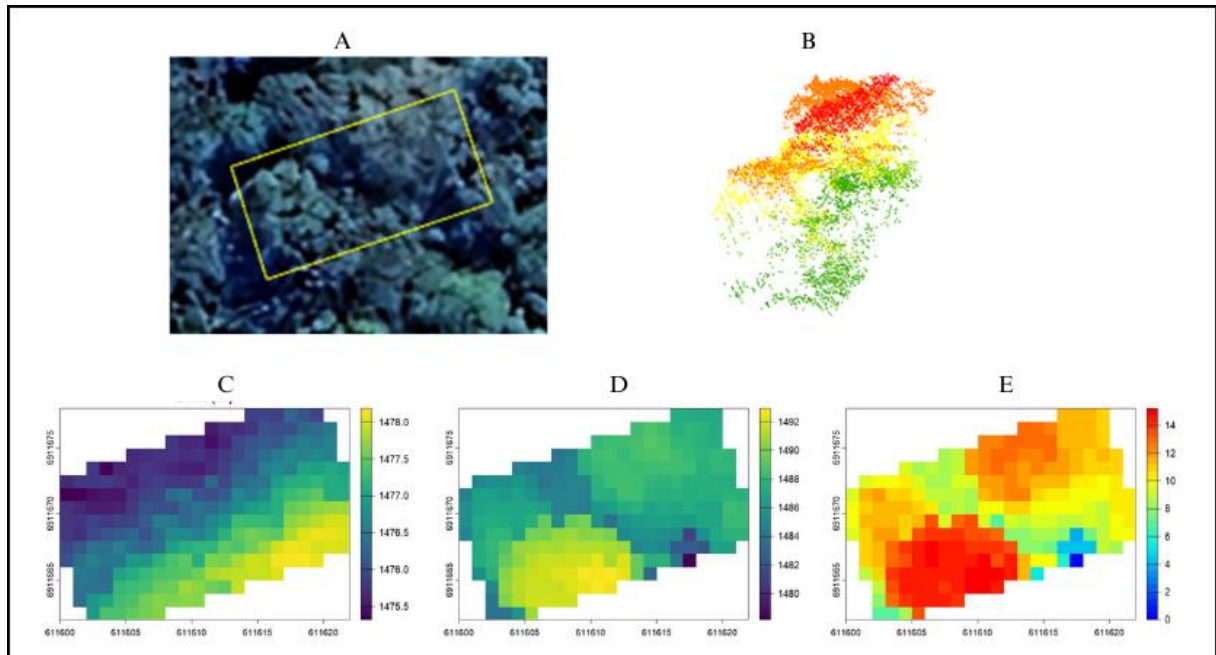
ZIEGELMAIER NETO, Bill Herbert. **Classificação dos estágios de sucessão da Floresta Atlântica utilizando dados multiplataforma orbitais e ALS**. 2022. 93 f. Dissertação (Mestrado) - Curso de Pós-Graduação em Engenharia Florestal, Universidade do Estado de Santa Catarina, Lages, 2022.

ZOLKOS, S.G.; GOETZ, S.J.; DUBAYAH, R. A meta-analysis of terrestrial aboveground biomass estimation using lidar remote sensing. **Remote Sensing of Environment**, v. 128, p. 289-298, jan. 2013. Elsevier BV, *doi:10.1016/j.rse.2012.10.017*.

## 10. APÊNDICES

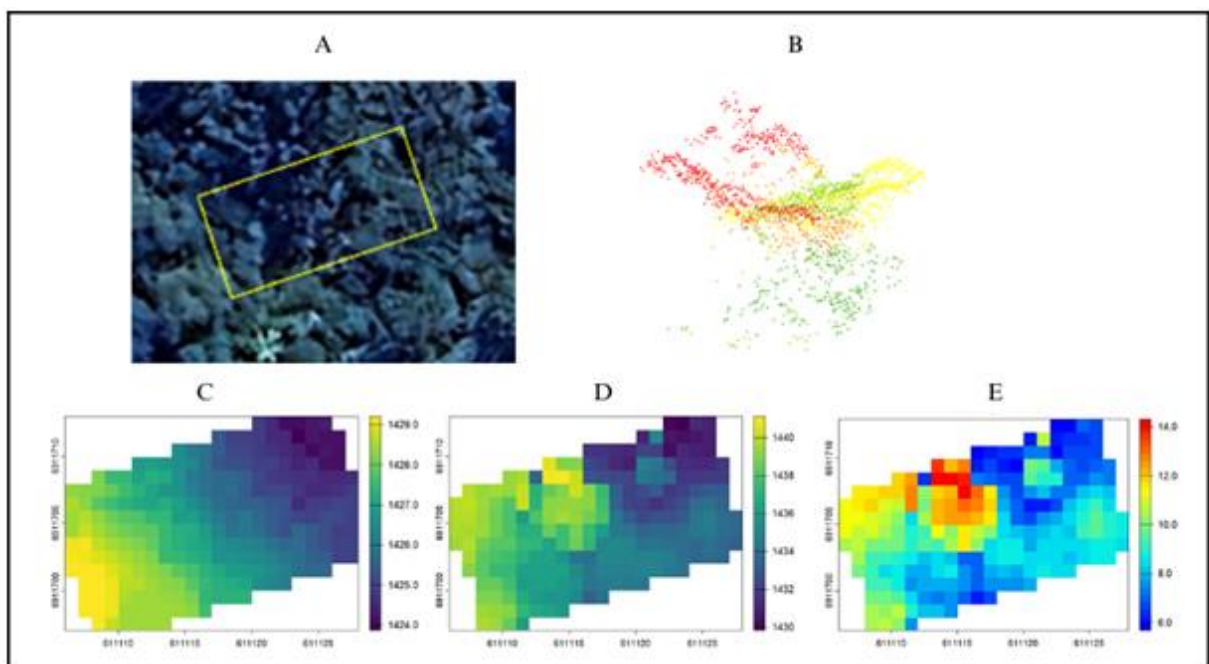
Nas Figuras a seguir podemos observar a imagem do Google Earth, nuvem de pontos Lidar e os modelos digitais das parcelas amostradas.

Figura 18. Representação do polígono de 200m<sup>2</sup>, referente a parcela 2. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.



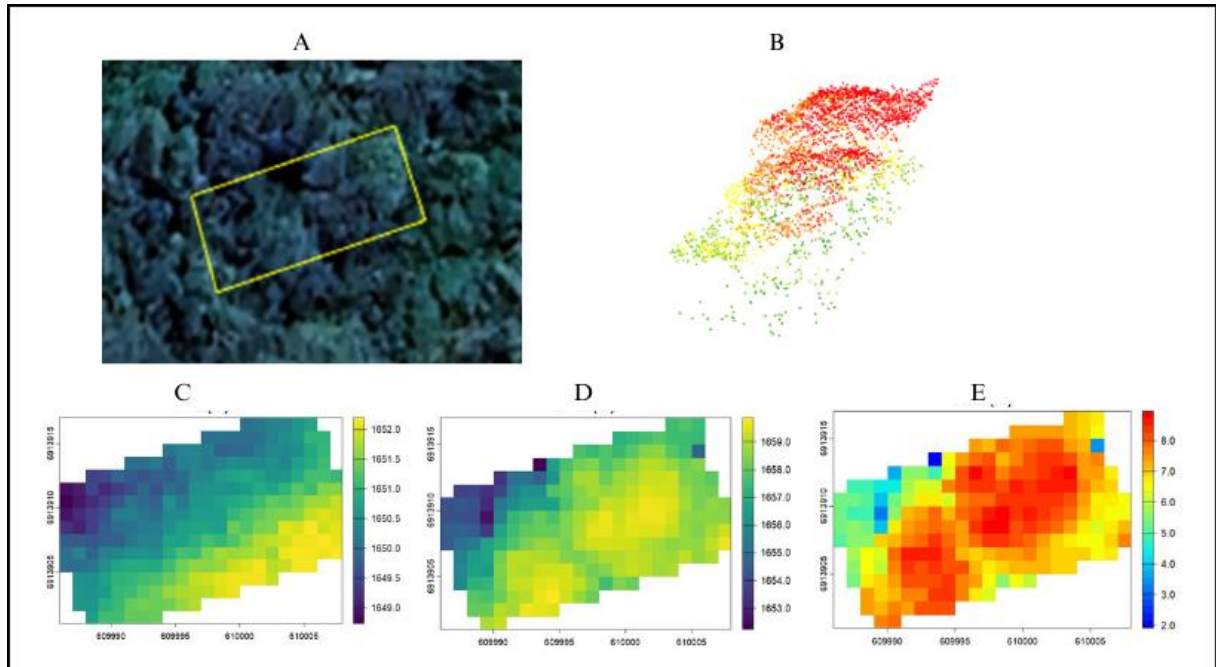
Fonte: Autor (2024).

Figura 19. Representação do polígono de 200m<sup>2</sup>, referente a parcela 3. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.



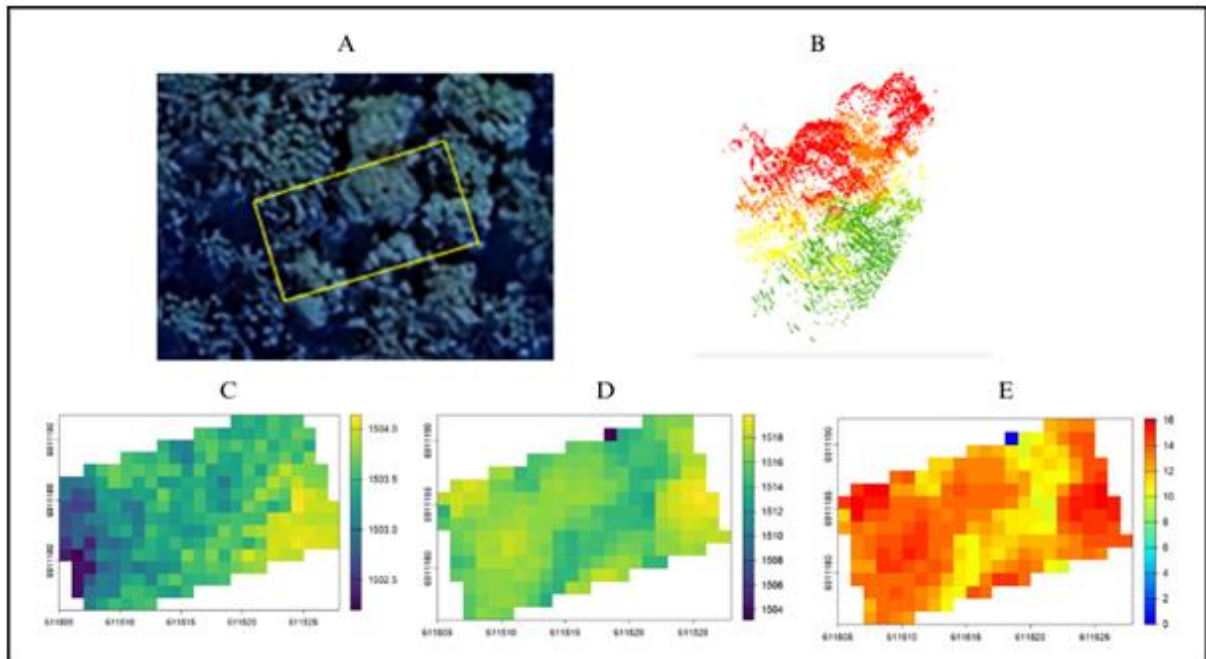
Fonte: Autor (2024).

Figura 20. Representação do polígono de 200m<sup>2</sup>, referente a parcela 5. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.



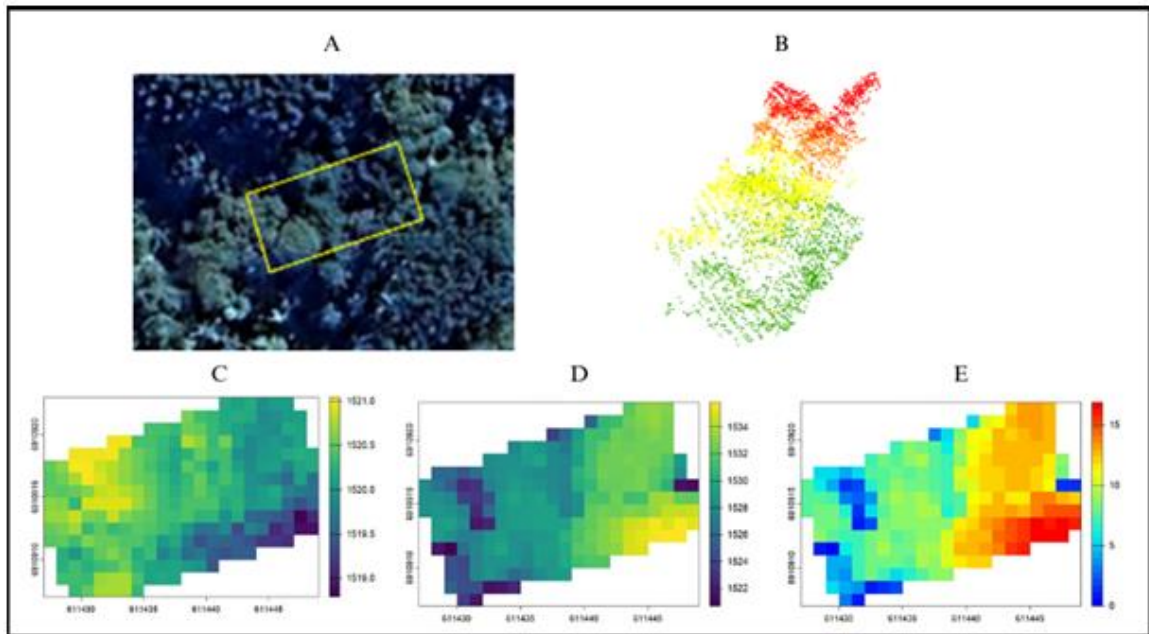
Fonte: Autor (2024).

Figura 21. Representação do polígono de 200m<sup>2</sup>, referente a parcela 6. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.



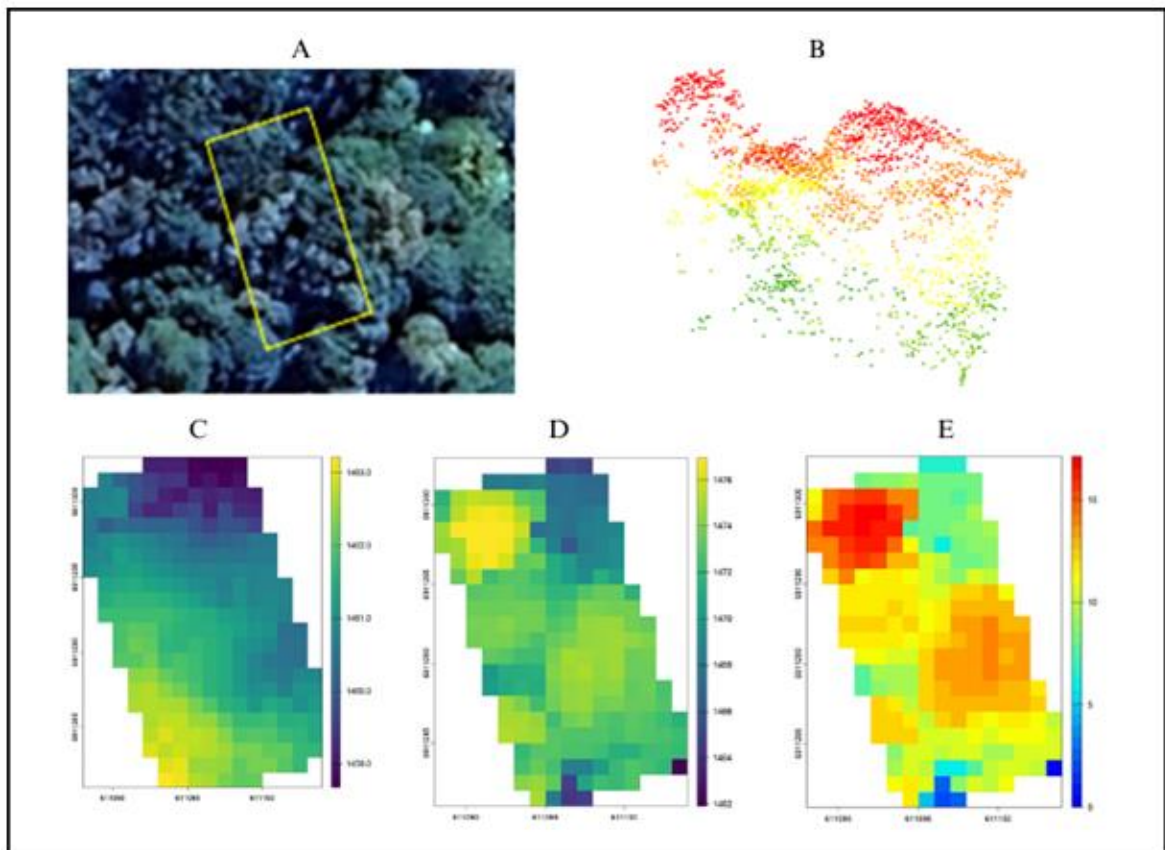
Fonte: Autor (2024).

Figura 22. Representação do polígono de 200m<sup>2</sup>, referente a parcela 7. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.



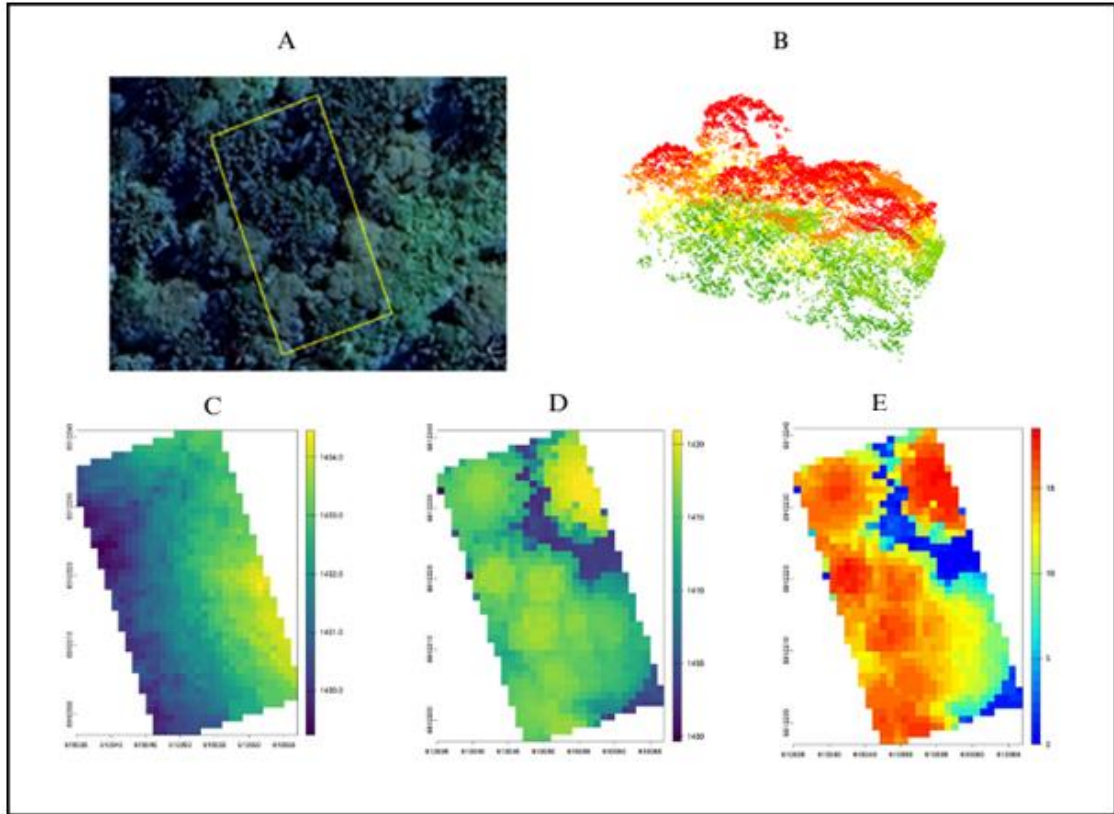
Fonte: Autor (2024).

Figura 23. Representação do polígono de 200m<sup>2</sup>, referente a parcela 8. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.



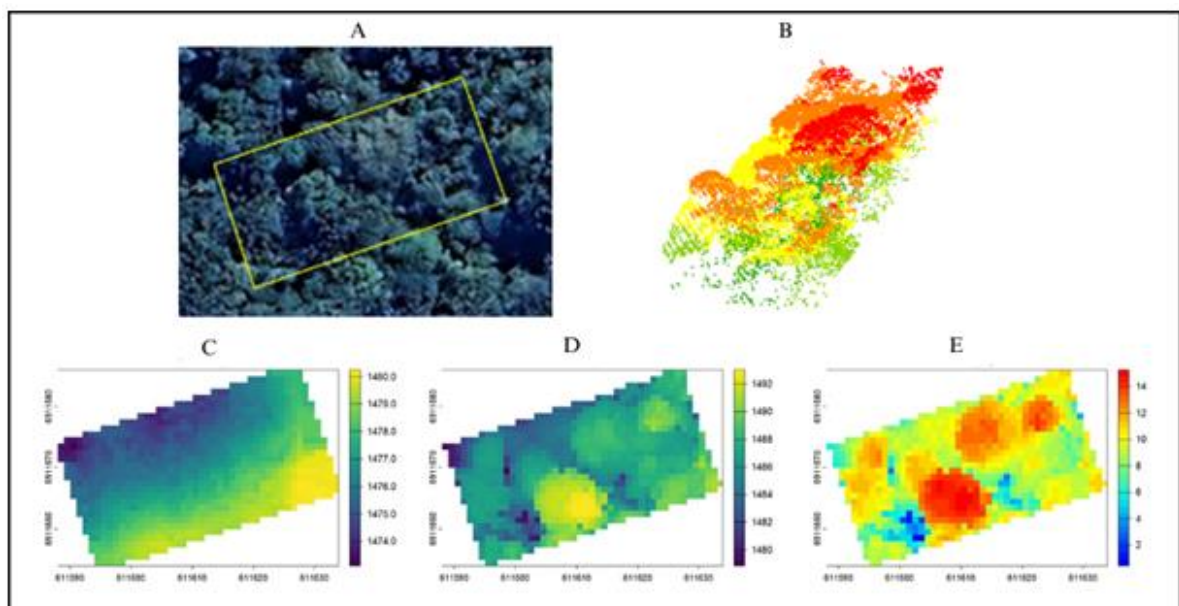
Fonte: Autor (2024).

Figura 24. Representação do polígono de 800m<sup>2</sup>, referente a parcela 1. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.



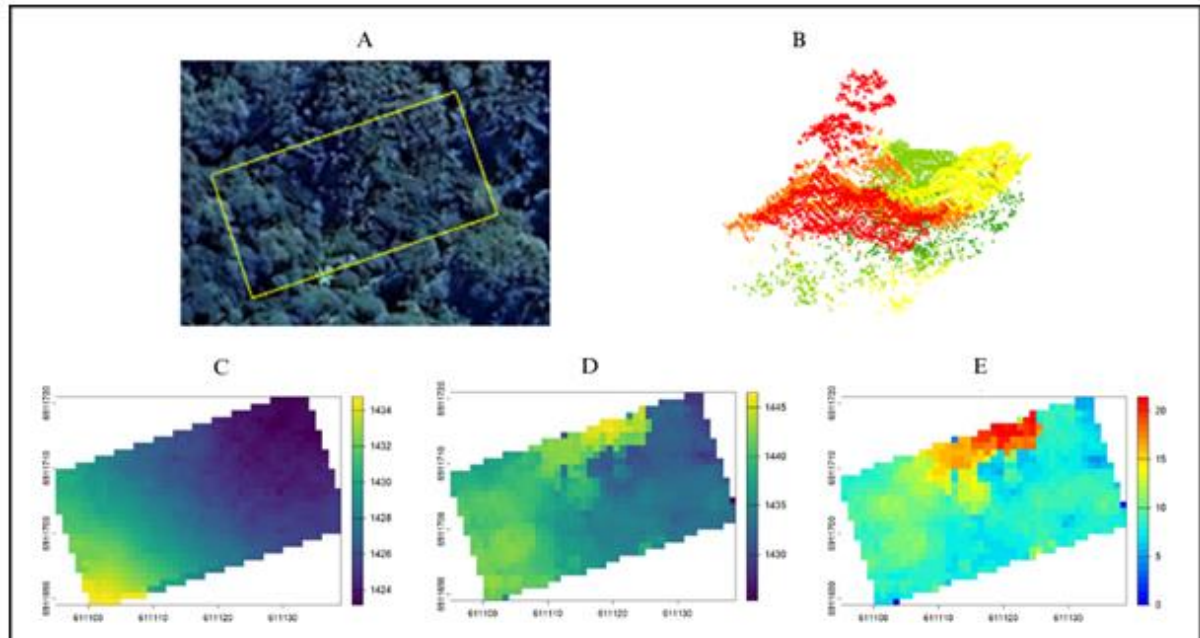
Fonte: Autor (2024).

Figura 25. Representação do polígono de 800m<sup>2</sup>, referente a parcela 2. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.



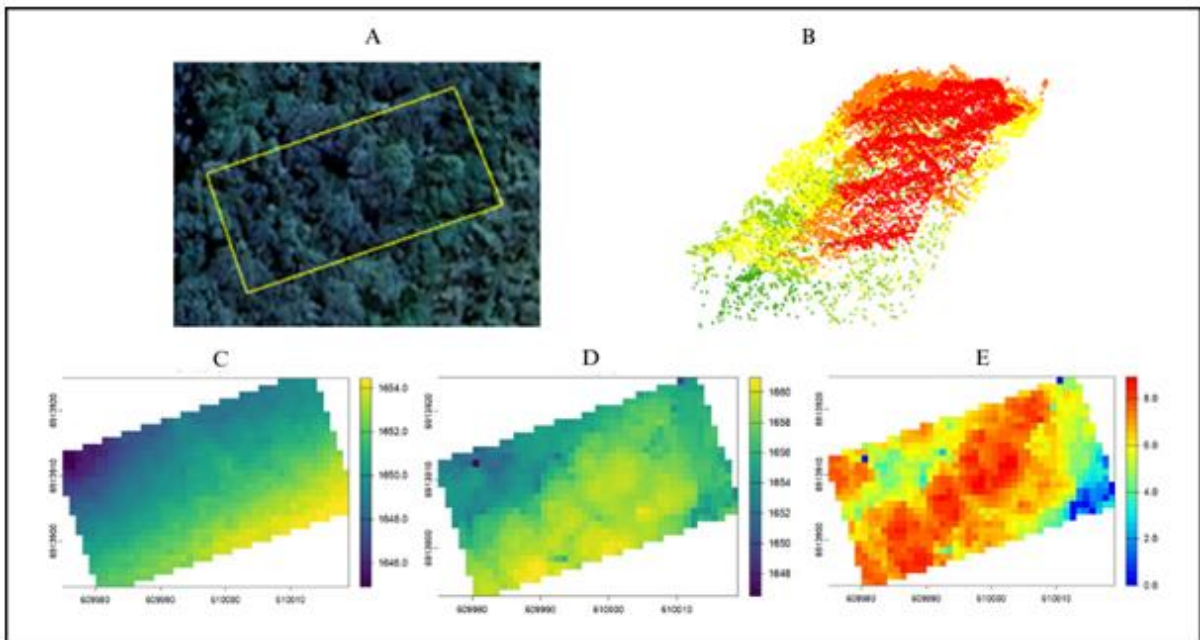
Fonte: Autor (2024).

Figura 26. Representação do polígono de 800m<sup>2</sup>, referente a parcela 3. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.



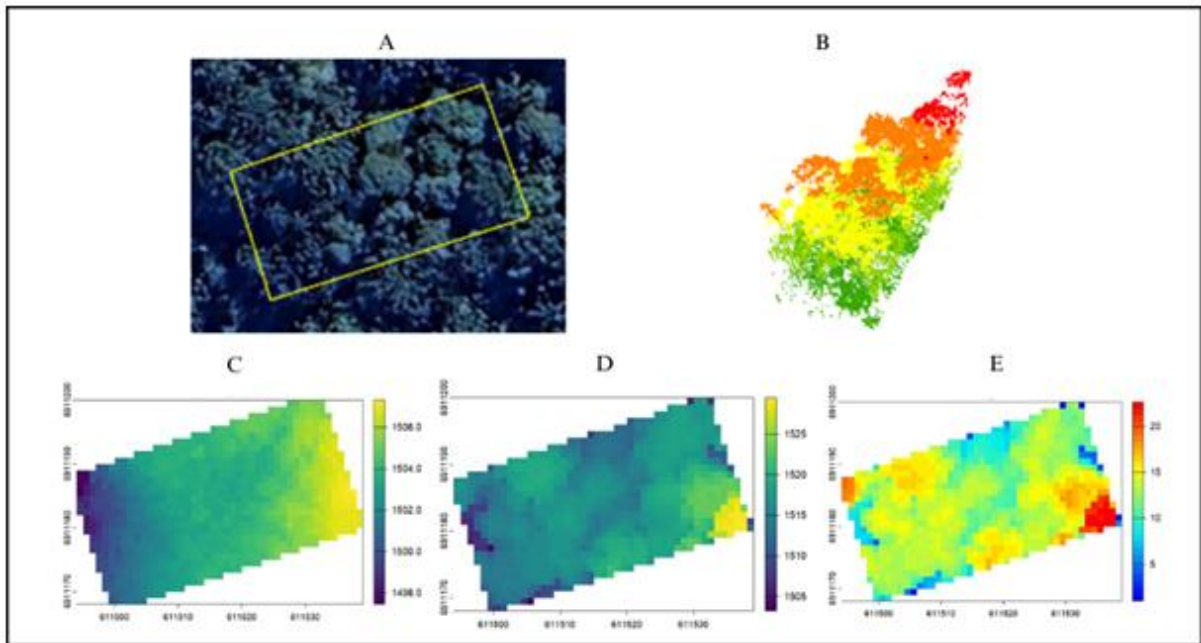
Fonte: Autor (2024).

Figura 27. Representação do polígono de 800m<sup>2</sup>, referente a parcela 5. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.



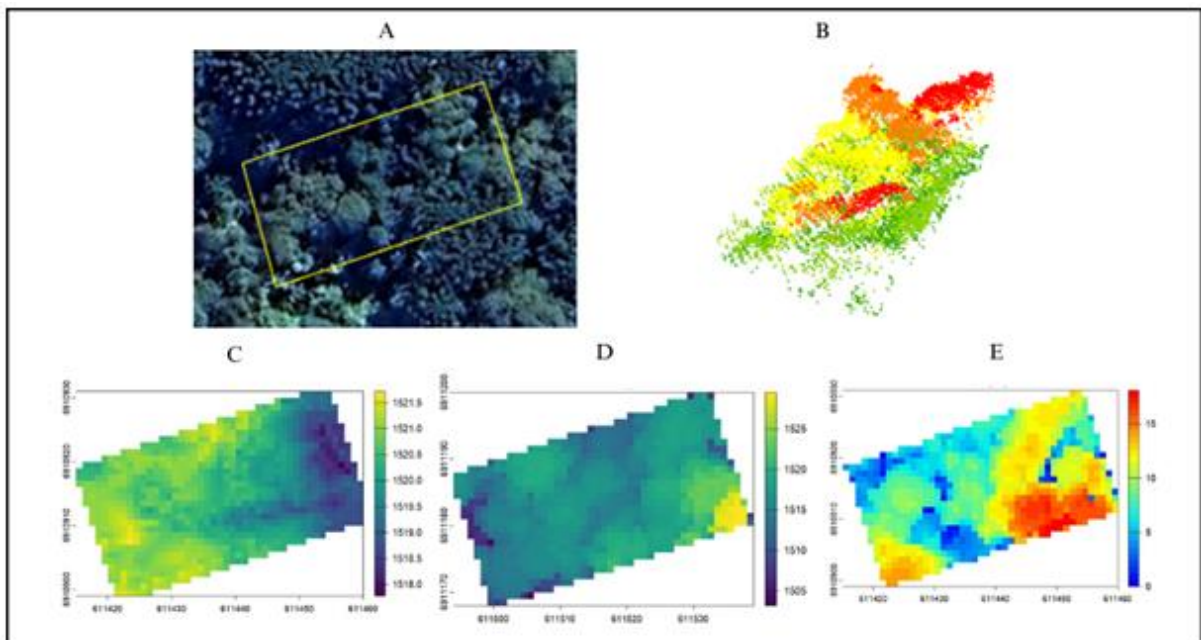
Fonte: Autor (2024).

Figura 28. Representação do polígono de 800m<sup>2</sup>, referente a parcela 6. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.



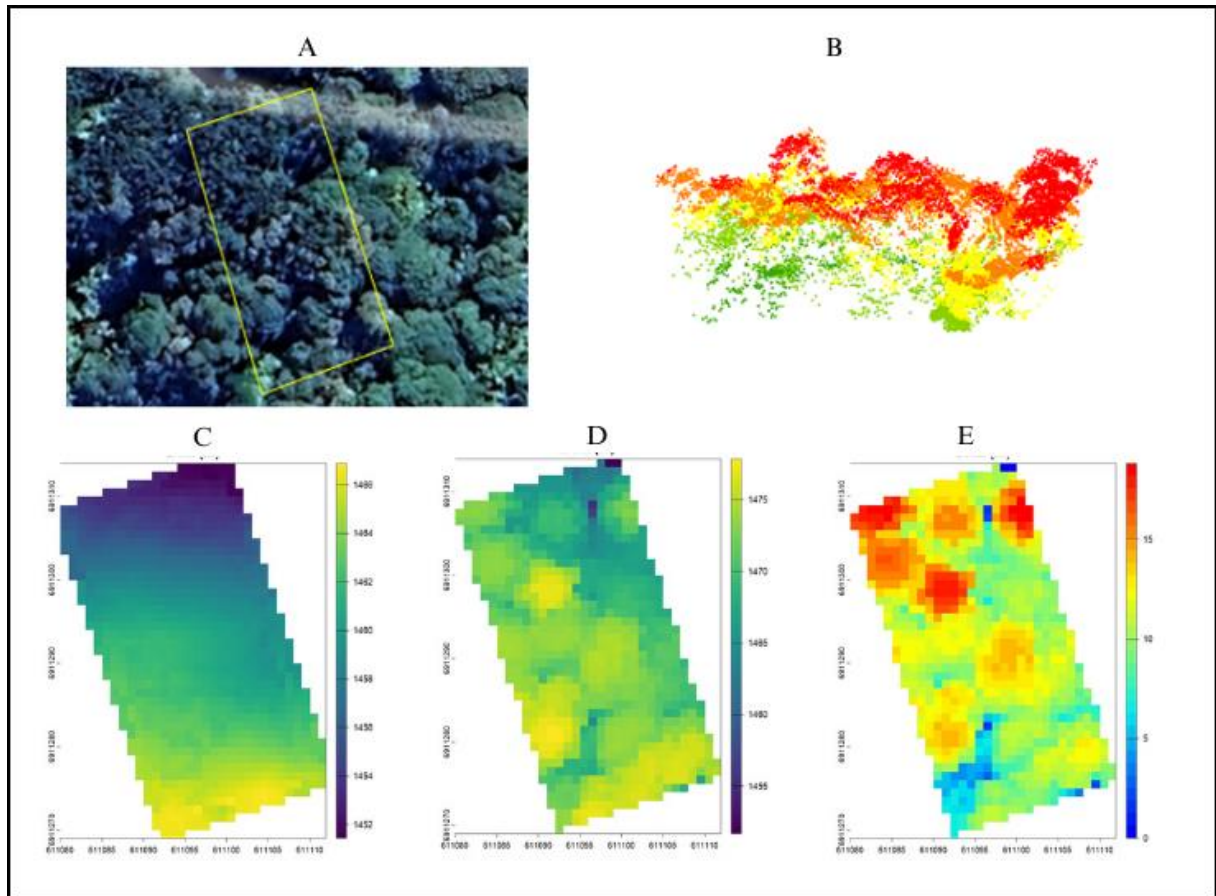
Fonte: Autor (2024).

Figura 29. Representação do polígono de 800m<sup>2</sup>, referente a parcela 7. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.



Fonte: Autor (2024).

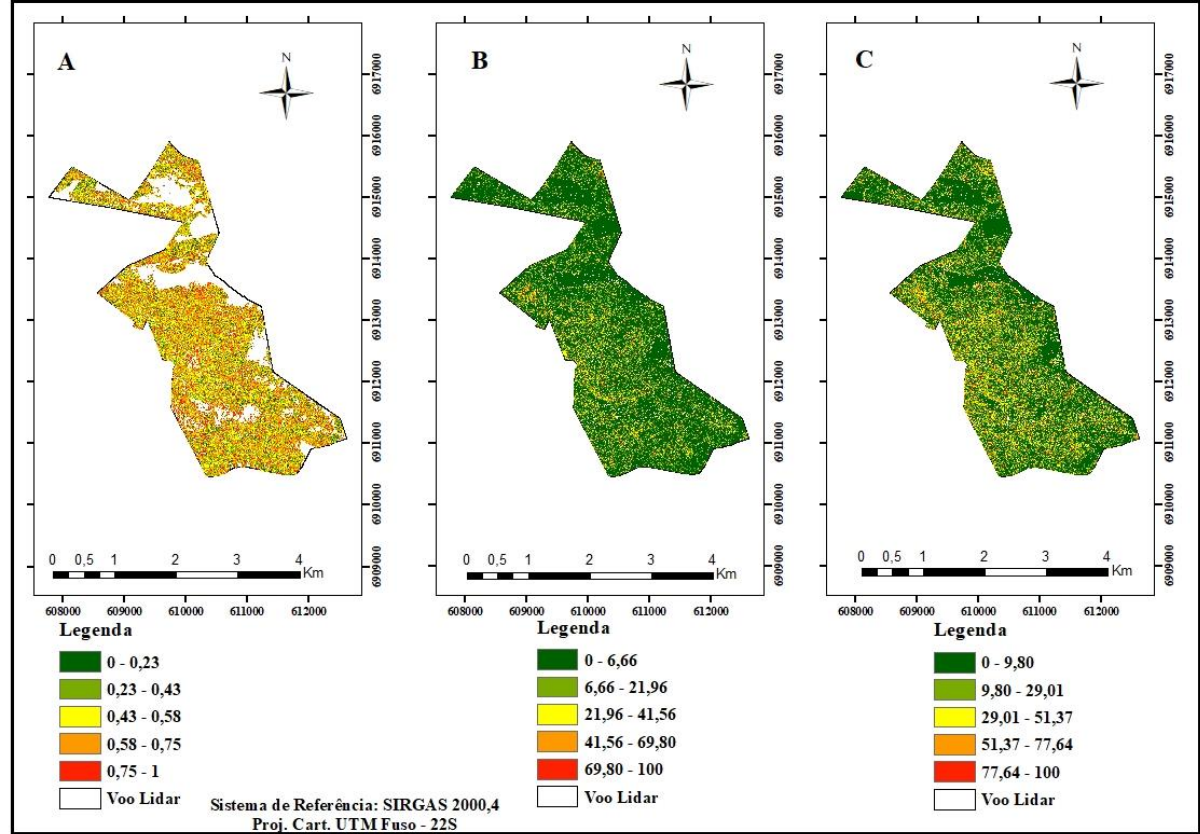
Figura 30. Representação do polígono de 800m<sup>2</sup>, referente a parcela 7. Em que: A- Google Earth; B- Nuvem de pontos Lidar; C- DTM; D- DSM; E- CHM.



Fonte: Autor (2024).

Na Figura 31, observa-se as métricas zentropy, zpcum3 e zpcum5, que foram escolhidas pelo Stepwise.

Figura 31. Métricas usados nas regressões. Em que A- zentropy; B- zpcum3; C- zpcum5



Fonte: Autor (2024).

Análise estatística do *Stepwise (both)* para o modelo de regressão da biomassa em parcela de 200m² (Figura 32).

Figura 32. Modelo para regressão linear múltipla.

Stepwise Summary						
Step	Variable	AIC	SBC	SBIC	R2	Adj. R2
0	Base Model	67.870	67.089	NA	0.00000	0.00000
1	zpcum5 (+)	64.297	63.126	NA	0.67195	0.56260
2	zentropy (+)	47.625	46.063	NA	0.99216	0.98433

Final Model Output

Model Summary			
R	0.996	RMSE	12.725
R-Squared	0.992	MSE	161.929
Adj. R-Squared	0.984	Coef. Var	8.137
Pred R-Squared	0.916	AIC	47.625
MAE	11.339	SBC	46.063

RMSE: Root Mean Square Error  
MSE: Mean Square Error  
MAE: Mean Absolute Error  
AIC: Akaike Information Criteria  
SBC: Schwarz Bayesian Criteria

ANOVA					
	Sum of Squares	DF	Mean Square	F	Sig.
Regression	102514.412	2	51257.206	126.616	0.0078
Residual	809.645	2	404.823		
Total	103324.057	4			

Parameter Estimates							
model	Beta	Std. Error	Std. Beta	t	Sig	lower	upper
(Intercept)	-1923.737	206.159		-9.331	0.011	-2810.768	-1036.706
zpcum5	7.541	0.705	0.687	10.691	0.009	4.506	10.576
zentropy	2209.038	244.352	0.581	9.040	0.012	1157.678	3260.397

Fonte: Autor (2024).

Análise estatística do *Stepwise (both)* para o modelo de regressão da biomassa em parcela de 800m² (Figura 33).

Figura 33. Modelo de regressão simples.

Stepwise Summary						
Step	Variable	AIC	SBC	SBIC	R2	Adj. R2
0	Base Model	67.870	67.089	NA	0.00000	0.00000
1	zpcum3 (+)	59.586	58.414	NA	0.87215	0.82953

Final Model Output

Model Summary			
R	0.934	RMSE	51.401
R-Squared	0.872	MSE	2642.080
Adj. R-Squared	0.830	Coef. Var	26.838
Pred R-Squared	0.557	AIC	59.586
MAE	44.368	SBC	58.414

RMSE: Root Mean Square Error  
MSE: Mean Square Error  
MAE: Mean Absolute Error  
AIC: Akaike Information Criteria  
SBC: Schwarz Bayesian Criteria

ANOVA					
	Sum of Squares	DF	Mean Square	F	Sig.
Regression	90113.659	1	90113.659	20.464	0.0202
Residual	13210.399	3	4403.466		
Total	103324.057	4			

Parameter Estimates							
model	Beta	Std. Error	Std. Beta	t	Sig.	lower	upper
(Intercept)	-83.359	78.881		-1.057	0.368	-334.392	167.674
zpcum3	13.586	3.003	0.934	4.524	0.020	4.028	23.143

Fonte: Autor (2024).

Análise das condicionantes da regressão:

- Normalidade dos resíduos

Para avaliar a normalidade dos resíduos foi usado o teste de Shapiro-Wilk. O p-valor é maior que 0,05, ou seja, os resíduos apresentam uma distribuição normal (Tabela 11).

Tabela 11. Teste de Shapiro-Wilk

<b>AGB</b>	<b>w</b>	<b>p-valor</b>
<b>RLM</b>	0,91793	0,5167
<b>RLS</b>	0,93715	0,6459

Em que: RLM- regressão linear múltipla; RLS- regressão linear simples. Fonte: Autor (2024).

- Outliers nos resíduos

Para verificar se existem resíduos que possam ser considerados como outliers considerando o Z-score, com abrangência de  $\pm 3$  desvios padronizados, utilizaremos a sumarização da função “rstandard” para o modelo desenvolvido. Com ela, observamos a amplitude dos resíduos padronizados e, caso existam valores inferiores a -3 e superiores a +3 desvios, é indicativo de existência de pontos atípicos. A média e mediana também devem estar próximas de zero. Os valores estão dentro da amplitude de -3 a +3, a média e mediana estão próximas de zero, indicando que não possui Outliers nos resíduos (Tabela 12).

Tabela 12. Resultado do Summary

<b>AGB</b>	<b>min</b>	<b>1stQu.</b>	<b>median</b>	<b>mean</b>	<b>3rdQu.</b>	<b>max</b>
<b>RLM</b>	-1,39	-1,26	0,04	-0,06	0,92	1,40
<b>RLS</b>	-1,32	-0,51	-0,07	0,12	1,20	1,33

Em que: RLM- regressão linear múltipla; RLS- regressão linear simples. Fonte: Autor (2024).

- Independência dos resíduos (Teste de Durbin-Watson)

Espera-se que a estatística D-W Statistic esteja entre 1 e 3. No caso deste teste, a hipótese nula ( $H_0$ ) é de que não existe correlação entre os resíduos e, a hipótese alternativa ( $H_1$ ) é que existe correlação entre os resíduos. Portanto, interpreta-se o valor de p-value da seguinte forma: quando o p-value for maior que 0,05 ( $p > 0,05$ ) a hipótese nula -  $H_0$  é aceita. Caso contrário ( $\leq 0,05$ ), a hipótese alternativa seria aceita -  $H_1$ . Neste caso não teríamos correlação entre os resíduos. O p-valor  $> 0,05$  apresentando correlação entre os resíduos (Tabela 13).

Tabela 13. Teste de Durbin-Watson.

<b>AGB</b>	<b>Autocorrelation</b>	<b>D-W Statistic</b>	<b>p-Value</b>
<b>RLM</b>	-0,22	2,08	0,74
<b>RLS</b>	0,28	0,98	0,11

Em que: RLM- regressão linear múltipla; RLS- regressão linear simples. Fonte: Autor (2024).

- Homocedasticidade (Teste de Breusch-Pagan)

No teste de Breusch-Pagan para verificação da homocedasticidade, a hipótese nula ( $H_0$ ) é de que existe homocedasticidade dos dados ( $p > 0,05$ ) e a hipótese alternativa é de que não há homocedasticidade dos dados (menor ou igual à 0,05). O  $p$  – valor  $> 0,05$  indicando que existe homocedasticidade (Tabela 14).

Tabela 14. Teste de Breusch-Pagan.

<b>AGB</b>	<b>BP</b>	<b>p-valor</b>
<b>RLM</b>	2,88	0,24
<b>RLS</b>	0,01	0,91

Em que: RLM- regressão linear múltipla; RLS- regressão linear simples. Fonte: Autor (2024).

- Multicolinearidade

Uma das possibilidades para detecção da presença de multicolinearidade trata-se do cálculo do Fator de Inflação de Variância (FIV, ou do inglês VIF - variance inflation factor), que mede o quanto da variância de cada coeficiente de regressão do modelo desenvolvido se encontra inflado em relação à situação em que as variáveis independentes não estão correlacionadas. De forma geral, quando o VIF é maior que 10 há indicação de multicolinearidade significativa. A aplicação deste teste só faz sentido quando tivermos mais do que uma variável independente. O  $VIF < 10$  ou seja não apresenta multicolinearidade significativa (Tabela 15).

Tabela 15. Multicolinearidade da regressão linear múltipla.

	<b>zpcum5</b>	<b>zentropy</b>
<b>VIF</b>	1,05477	1,054767

Fonte: Autor (2024).