UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO DE CIÊNCIAS AGRÁRIAS E ENGENHARIAS
DEPARTAMENTO DE CIÊNCIAS FLORESTAIS E DA MADEIRA

WANDER DEIVID CARDOSO DOS SANTOS

ESTIMAÇÃO DO DIÂMETRO MÉDIO, ALTURA MÉDIA E BIOMASSA ACIMA DO SOLO EM FLORESTAS DA REGIÃO MERIDIONAL DA SERRA DO ESPINHAÇO UTILIZANDO DADOS LIDAR

JERÔNIMO MONTEIRO
ESPÍRITO SANTO
2024

WANDER DEIVID CARDOSO DOS SANTOS

ESTIMAÇÃO DO DIÂMETRO MÉDIO, ALTURA MÉDIA E BIOMASSA ACIMA DO SOLO EM FLORESTAS DA REGIÃO MERIDIONAL DA SERRA DO ESPINHAÇO UTILIZANDO DADOS LIDAR

Monografia apresentada ao Departamento de Ciências Florestais e da Madeira da Universidade Federal do Espírito Santo, como requisito para obtenção do título de Engenheiro Florestal.

JERÔNIMO MONTEIRO
ESPÍRITO SANTO
2024

WANDER DEIVID CARDOSO DOS SANTOS

ESTIMAÇÃO DO DIÂMETRO MÉDIO, ALTURA MÉDIA E BIOMASSA ACIMA DO SOLO EM FLORESTAS DA REGIÃO MERIDIONAL DA SERRA DO ESPINHAÇO UTILIZANDO DADOS LIDAR

Monografia apresentada ao Departamento de Ciências Florestais e da Madeira da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do título de Engenheiro Florestal

Aprovada em 10 de setembro de 2024

COMISSÃO EXAMINADORA

Documento assinado digitalmente
ADRIANO RIBEIRO DE MENDONCA
Data: 03/10/2024 18:11:42-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. Adriano Ribeiro de Mendonça
Universidade Federal do Espírito Santo
Orientador

Documento assinado digitalmente
NIVEA MARIA MAFRA RODRIGUES
Data: 03/10/2024 13:40:47-0300
Verifique em https://validar.iti.gov.br

MS Nívea Maria Mafra Rodrigues
Universidade Federal do Espírito Santo

Documento assinado digitalmente
LUCAS DUARTE CALDAS DA SILVA
Data: 03/10/2024 13:05:58-0300
Verifique em https://validar.iti.gov.br

MS. Lucas Duarte Caldas da Silva
Universidade Federal do Espírito Santo

AGRADECIMENTOS

Aos meus pais, Kelly e Job, e meus irmãos por estarem sempre ao meu lado me incentivando e mostrando que sempre teremos alguém em quem nos espelhar.

A minha esposa e parceira de vida, Letícia, que sempre esteve mostrando que cada dia tem algo singular e que nunca é tarde para tentar algo novo, sendo minha base e meu abrigo durante as tempestades.

Aos meus inúmeros amigos que a UFES me deu, por cada momento único propiciado, tanto deitado na frente da biblioteca quanto nas lamentações que antecediam cada momento de avaliação, estando sempre próximos todos os dias letivos, tornando cada dia mais leve.

Aos amigos do LaMFLOR que tiveram a paciência e pelo espaço fornecido, tanto para a troca de ideias quanto de conhecimento.

A AGROFLOR e seus funcionários pelo apoio, pela a amizade e pelas conversas que foram importantes para conclusão do presente trabalho.

Ao professor Adriano Ribeiro, pelos conselhos e pela instrução.

RESUMO

O Brasil possui mais da metade do seu território coberto de vegetação florestal, o que equivale a cerca de 13% de toda a vegetação existente no mundo, abrigando a grande parte de toda a diversidade arbórea existente. Com essa biodiversidade arbórea, o armazenamento de carbono em forma de biomassa se torna um dos principais objetivos de projetos de reflorestamento para a diminuição ou mitigação do efeito estufa. Contudo, estimar algumas variáveis biométricas como a biomassa para áreas extensas se tornam um desafio por meio dos métodos tradicionais de inventário. Neste contexto, o presente trabalho tem como objetivo avaliar a acurácia das estimativas do diâmetro médio, altura total média e da biomassa acima do solo em uma floresta nativa em Minas Gerais por meio de escaneamento a laser aerotransportado (ALS). Foram mensurados o diâmetro a 1,3 m do solo (*D*), a altura total (*H*) dos indivíduos e a biomassa acima do solo (W_t) foi estimado por meio da equação desenvolvida para floresta estacional semidecidual em Viçosa-MG. Os dados das nuvens de pontos provenientes do LiDAR foram tratados para remoção de estruturas que não eram alvos do estudo por meio do software CloudCompare. As métricas das parcelas foram extraídas e computadas com o pacote LidR. As variáveis foram selecionadas por meio do pacote leaps para testar modelos de regressão com 1, 2, 3, 4 e 5 variáveis no ambiente do RStudio. Para avaliar a acurácia e seleção do melhor modelo, foram utilizadas as estatísticas Raiz Quadrada Médio do Erro (RQME), o coeficiente de determinação ajustado (R^2aj) e, ainda, avaliada a multicolinearidade por meio do valor de influência da variância (VIF). As variáveis da nuvem de pontos que foram selecionadas para o melhor modelo de biomassa acima do solo (*Wt*) foram *zq65*, *zpcum9* e *p3th*, que explicaram 75,22% da variação dos dados em campo (R^2aj), com RQME de 12,50 t/parcela e RQME (%) de 45,26%. Para a estimativa do *D* médio, as variáveis selecionadas no melhor modelo foram *imean*, *zpcum7* e *zq65* que obteve R^2aj de 71,37%, RQME 1,036 cm e RQME (%) 10,68%. Houveram cinco métricas que juntas compuseram o melhor modelo para estimativa da *H* média (*zq15*, *zpcum8*, *iskew*, *ipcumzq50* e *p1th*) com um coeficiente de determinação de 70,16% e com o RQME de 1,0746 e RQME (%) de 11,89%. A variável relacionada a altura do percentil 65 foi selecionada para o melhor modelo para estimar *D* e biomassa acima do solo, mostrando ser a variável que mais teve importância no estudo. Desta maneira, os dados do LiDAR mostraram relativamente eficazes para estimar dados de *D*, *H* e W_t.

Palavras-chave: Regressão Linear Múltipla, Métricas LiDAR, Estimativa.

SUMÁRIO

LISTA DE FIGURAS IX
1. INTRODUÇÃO 11
2. OBJETIVOS 12
2.1 OBJETIVO GERAL 12
2.2 OBJETIVOS ESPECÍFICOS 13
3. REVISÃO DE LITERATURA 13
3.1 INVENTÁRIO FLORESTAL TRADICIONAL 13
3.2 LIDAR 14
4. MATERIAL E MÉTODOS 17
4.1 ÁREA DE ESTUDO 17
4.2 INVENTÁRIO FLORESTAL TRADICIONAL 18
4.3 BIOMASSA ACIMA DO SOLO 19
4.4 COLETA E PROCESSAMENTO DE DADOS LIDAR 19
4.5 AJUSTE DE MODELOS PARA ESTIMAR O DIÂMETRO MÉDIO, ALTURA TOTAL MÉDIA E BIOMASSA TOTAL ACIMA DO SOLO 21
4.6 AVALIAÇÃO DOS RESULTADOS 22
5. RESULTADOS E DISCUSSÃO 22
5.1 INVENTÁRIO FLORESTAL TRADICIONAL 22
5.2 LIDAR 24
5.2.1 Modelo para Estimação do Diâmetro Médio 27
5.2.2 Modelo para Estimação de Altura Total Média 30
5.2.3 Modelo para Estimação da Biomassa Acima do Solo 33
6. CONCLUSÕES 36
7. REFERÊNCIAS 37
APÊNDICES 42

LISTA DE TABELAS

Tabela 1 - Média ($\bar{x}$), desvio padrão da média (s), variância (s²) e coeficiente de variação (CV%) da W_t, *D* e *H*. 23
Tabela 2 - Métricas selecionadas para modelos com uma, duas ou três variáveis. ..27
Tabela 3 - Estimativa dos parâmetros dos modelos para estimar a *D*.....28
Tabela 4 – Coeficiente de determinação ajustado (R² aj), raiz dos quadrados médio do erro (RQME) e raiz dos quadrados médios dos erros percentual (RQME(%)) para os modelos para estimar *D.* 28
Tabela 5 - Métricas selecionadas para modelos com uma, duas e cinco variáveis...30
Tabela 6 - Estimativa dos parâmetros dos modelos para estimar a *H* média. 30
Tabela 7 - Coeficiente de determinação ajustado (R² aj), raiz dos quadrados médio do erro (RQME) e raiz dos quadrados médios dos erros percentual (RQME(%)) para os modelos para estimar *H*. 31
Tabela 8 – Métricas selecionadas para modelos com uma, duas ou três variáveis. .33
Tabela 9 – Estimativa dos parâmetros dos modelos para estimar a Biomassa Acima do Solo. 33
Tabela 10 – Coeficiente de determinação ajustado (R² aj), raiz dos quadrados médio do erro (RQME) e raiz dos quadrados médios dos erros percentual (RQME(%)) para os modelos para estimar W_t. 34

LISTA DE FIGURAS

Figura 1 - Esquema operacional de funcionamento de um sistema LiDAR aerotransportado 15
Figura 2 - Localização da área de estudo. 17
Figura 3 – Modelo digital de terreno da área de estudo. 24
Figura 4 – Nuvem de pontos normalizada da área de estudo 24
Figura 5 – Gráfico da correlação de Pearson das variáveis de interesse para a Biomassa Acima do solo(*Wt*), Diâmetro Médio (*D*) e Altura Máxima (*H*) 26
Figura 6 - Gráfico de dispersão dos valores observados/medidos e valores estimados por meio do modelo ajustado para a estimativa de Diâmetro Médio. 29
Figura 7 - Gráfico de dispersão dos valores observados/medidos e valores estimados por meio do modelo ajustado para a estimativa da altura total média 32
Figura 8 - Gráficos de dispersão dos valores observados/medidos e valores estimados por meio do modelo ajustado para a estimativa de Biomassa Acima do Solo (W_t) dos modelos regressão selecionados. 35

1. INTRODUÇÃO

O Brasil possui cerca de 55% do território coberto com vegetação florestal e abriga a maior parte da área de florestas tropicais do mundo, o que torna necessário ter ciência e monitorar a biodiversidade existente (SERVIÇO FLORESTAL BRASILEIRO, 2019). Estudar a cobertura vegetal é de grande importância devido pois ele influencia na biodiversidade florestal, atuando na proteção e nas características dos recursos hídricos e do solo (JESUS et al., 2015).

O Inventário Florestal Tradicional (IFT) está diretamente relacionado a medição de variáveis como diâmetro, altura, volume, taxa de crescimento, cálculo de biomassa acima do solo, forma e idade, individual ou do povoamento, e dimensão de seus produtos (KERSHAW et al., 2017). Dentre estas variáveis, as principais que se obtém medidas em campo em um IFT são o diâmetro a 1,3 m do solo (*D*) e a altura total (*H*), pois são informações essenciais para a estimação da área basal, volume, dentre outras variáveis (LEMOS, 2010). O *D* pode ser medido com o auxílio de uma fita métrica ou fita diamétrica, enquanto a altura, que é de maior dificuldade de mensuração, pode ser medido com auxílio de clinômetros, hipsômetros ou réguas telescópicas.

A obtenção destas informações nos inventários florestais frequentemente são atividades que exigem muita mão de obra e, assim, uma quantidade grande de recursos. Diante disso, se torna imprescindível a busca de outros métodos que nos permita ter maior rapidez nas medidas de variáveis como *D* e *H* com acurácia semelhante ou melhor que aos dados obtidos no campo.

Entre as estimativas que podem ser obtidas por meio do *D* e *H*, pode se citar a obtenção da biomassa em formações florestais. Segundo Silveira (2010), a biomassa e o carbono quantificado em fragmentos florestais auxiliam nas estimativas de ciclagem de nutrientes, uso para fins energéticos e como base para estudos de sequestro de carbono. Estudos que envolvem a quantificação da biomassa possuem grande importância para compreender e direcionar as decisões relacionadas ao manejo dos recursos florestais (JÚNIOR et al., 2023).

Neste contexto, as geotecnologias desempenham um papel crucial no aprimoramento dos processos de inventário florestal, fornecendo métodos precisos e eficientes para avaliar os recursos florestais, com os sistemas Light Detection and

Ranging (LiDAR) facilitando a extração de parâmetros de árvores, permitindo mapeamento e inventário florestais detalhados e os sistemas de geoinformações aprimoram o processamento e o gerenciamento de dados (ASENOVA et al., 2022; LAHSSINI et al., 2018; MAISTRENKO et al., 2019)

O LiDAR é uma tecnologia que, nos últimos anos, vem sendo usada e estudada em aplicações florestais de maneira crescente. Isso ocorre devido ao fato de apresentar uma grande capacidade de obtenção de informações de grandes áreas em um curto espaço de tempo, em comparação ao inventário tradicional (SILVA et al., 2017). Os sistemas LiDAR funcionam com pulsos de laser com elevada frequência de repetição. Inicialmente, foi elaborado para levantamentos de dados para elaboração de Modelos Digitais de Elevação (MDE) em regiões em que métodos tradicionais não eram suficientes e o acesso era dispendioso (GIONGO et al., 2010).

Segundo Petean (2015), as plataformas mais utilizadas com o sensor LiDAR no setor florestal são as sub-orbitais, nelas incluem o escaneamento a laser aerotransportado (ALS – Airborne Laser Scanning) e o terrestre (TLS – Terrestrial Laser Scanning). A plataforma orbital é a menos utilizada (OLS – Orbital Laser Scanning). Os levantamentos florestais baseados no ALS se destacam devido a quantidade de informações tridimensionais que podem ser coletadas com alta resolução e vários estudos no cenário internacional foram feitos (CONTO et al., 2015). Magdon et al. (2018) indicam que o uso de dados de ALS combinados com dados de inventário florestal tradicional melhoram a acurácia das estimativas de biomassa acima do solo. Diversas pesquisas foram realizadas utilizando dados de ALS na área florestal (SUIR et al., 2023; ZHAO et al., 2022). Zhao et al. (2022) utilizaram dados coletados por ALS e dados multiespectrais de alta resolução para estimar a biomassa de indivíduos arbóreos na China. Estes autores obtiveram estimativas de biomassa acima do solo a nível de indivíduo espacialmente detalhadas e de alta confiabilidade.

2. OBJETIVOS

2.1 OBJETIVO GERAL

- Avaliar a acurácia das estimativas do diâmetro médio, altura total média e da biomassa acima do solo em uma floresta nativa em Minas Gerais por meio de dados ALS.

2.2 OBJETIVOS ESPECÍFICOS

- Selecionar as métricas que melhor explicam a variação do diâmetro médio, altura total média e biomassa acima do solo; e
- Analisar as estimativas do diâmetro médio, altura total média e biomassa acima do solo por meio das métricas obtidas da nuvem de pontos LiDAR.

3. REVISÃO DE LITERATURA

3.1 INVENTÁRIO FLORESTAL TRADICIONAL

O inventário florestal é um componente de grande importância para o manejo florestal sustentável, fornecendo dados para planejamento, monitoramento, avaliação, pesquisa, crescimento e produção, biodiversidade e venda de madeira (HEYM et al., 2021). Os dados de inventário florestal podem ser usados para melhorar o planejamento do manejo florestal de várias maneiras. Inventários florestais podem ser classificados de acordo com objetivo, área de abrangência, maneira em que a amostragem é feita, dentre outros (GUTERRES, 2023).

O censo florestal, conhecido como inventário 100%, é aquele em que obtemos informações qualitativas e quantitativas a nível de população, como diâmetro médio e altura. Mas, frequentemente, este tipo de obtenção de dados se torna impraticável por ser onerosa, gastar muito tempo e mão de obra. Assim, torna evidente a necessidade de estimar os parâmetros populacionais de maneira precisa e eficiente por meio da amostragem (FARIAS et al., 2002).

Os valores de D podem ser obtidos por meio de uma suta, fita métrica e diamétrica e, para aferição da altura total (H), uma régua telescópica ou hipsômetros. Tais dados podem ser obtidos por inventários feito anteriormente por entidades ligadas ao governo ou não. He et al. (2013) propôs o cálculo da biomassa acima do solo por meio da soma das biomassas individuais de caules, ramos, folhagens e frutos por equações em que relacionam o produto do D^2 e H.

Com o avanço das ciências florestais, foram propostos inúmeros métodos de aplicação de inventário e o mais utilizado e difundido é a amostragem com parcelas de área fixa (MARQUES; WIEMANN; KNEIB, 2023). Para aumentar a precisão e, por consequência, diminuir os erros é necessário que sejam lançadas mais parcelas em campo. O que recai sobre a mesma fragilidade do censo florestal: quanto maior a precisão e a área a ser amostrada maior o custo inerente ao inventário (LI et al, 2023).

3.2 LIDAR

LiDAR, uma abreviação para *Light Detection and Ranging*, representa uma tecnologia de grande importância em diversas aplicações, como na obtenção de atributos florestais, oferecendo uma abordagem tridimensional detalhada por meio da utilização de pulsos de laser para medição precisa de distâncias (NISHIWAKI et al., 2023). Os sistemas LiDAR emitem feixes de laser e medem o tempo de retorno dos feixes após atingirem um objeto. Os feixes de laser são dispersos ou refletidos por partículas ou objetos no volume de medição, e um dispositivo recebe uma parte da luz dispersa ou refletida. Então, a luz recebida é coerentemente sobreposta a um feixe de luz de referência e enviada para um detector, resultando em um sinal gerado pelo detector. A velocidade de uma partícula ou objeto no volume de medição é determinada usando a análise espectral e a modulação de frequência pré-definida (PETERS; BRINKMEYER; BOLLIG, 2023).

Os sistemas LiDAR podem ser divididos em LiDAR terrestres, aerotransportados e orbitais. O LiDAR terrestre (TLS) se destaca na coleta de dados florestais detalhados, como biomassa e estrutura do dossel, permitindo representações 3D de elementos florestais e sua adoção é dificultada por altos custos, falta de treinamento e infraestrutura insuficiente para processamento de dados (BARROS et al., 2022). O LiDAR aerotransportado é eficaz para gerar Modelos Digitais de Terreno (MDT), especialmente em florestas densas, embora enfrente limitações de custo e tempo para grandes áreas (CALDEIRA; POLIDORI, 2023). Sistemas LiDAR orbitais, como IceSat e CALIPSO, fornecem dados globais sobre perfis atmosféricos e cobertura da terra, cruciais para modelagem climática e previsões meteorológicas (FOULADINEJAD et al., 2019)

Um sistema LiDAR aerotransportado é composto por vários componentes essenciais que trabalham em conjunto para emitir pulsos de laser, coletar dados de retorno e gerar informações tridimensionais detalhadas do terreno. Segundo Giongo et al. (2010), os sistemas ALS são compostos por um sensor laser que registra o tempo em que o sinal é emitido e o mesmo sinal retorna ao sensor ao tocar um determinado ponto, um Sistema Inercial de Navegação (INS – Inertial Navigation System), um Global Position System (GPS) integrado a plataforma do ALS e um computador para controle e armazenamento dos dados (Figura 1).

Figura 1 - Esquema operacional de funcionamento de um sistema LiDAR aerotransportado

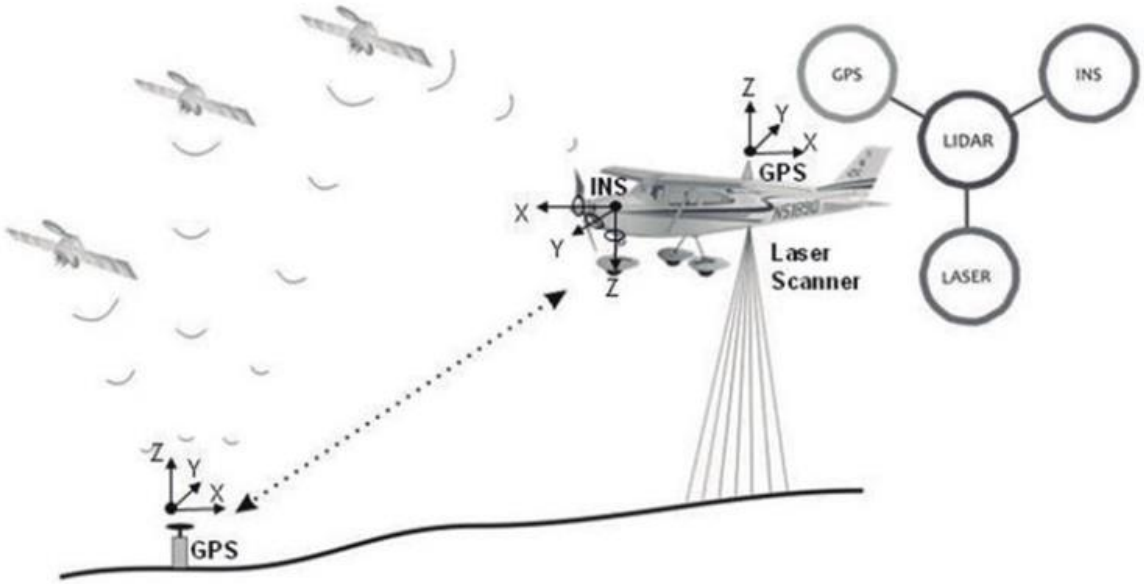

Fonte: GIONGO et al. (2010)

O perfilamento laser funciona da seguinte maneira: feixes infravermelhos são emitidos em direção à superfície terrestre. Quando os feixes tocam a superfície, o receptor conectado ao equipamento reflete e capta os feixes. Para cada feixe emitido, é registrado o tempo de percurso entre a aeronave e o objeto. Como é conhecido que a distância que o feixe percorre é produto da velocidade da luz pelo tempo de resposta divididos por dois, pode-se calcular o tempo de percurso do laser (GIONGO et al., 2010).

Como o ALS emite um pulso que atinge a superfície e retorna, é possível associar cada ponto a uma coordenada, altitude, distância e intensidade de retorno. A quantidade de pulso que o sensor emite em uma determinada área é representada pela densidade de pontos e quanto maior a densidade de pontos, maior será o detalhamento do ambiente. Cada um ponto compõe a nuvem de pontos que é utilizado para modelar a superfície por meio dos Modelos Digitais de Terreno (MDT) e Modelos Digitais de Superfície (MDS) (GIONGO et al., 2010).

Ao fornecer informações detalhadas sobre a estrutura vertical dos povoamentos de árvores de maneira precisa, a tecnologia LiDAR aerotransportada revolucionou a pesquisa de recursos florestais. Os principais indicadores de recursos florestais, como volume de estoque florestal, diâmetro na altura do peito e biomassa florestal, podem ser estimados com ele (WANG et al., 2023). As variáveis florestais e as métricas LiDAR podem ser relacionadas. A estimação de variáveis florestais baseada em LiDAR é prática e é amplamente usada no monitoramento de recursos florestais (MAHONEY et al., 2022).

As métricas extraídas da nuvem de pontos são parâmetros estatísticos que descrevem o conjunto de dados para estudo de determinada vegetação ou estrutura. As métricas são calculadas tendo como base a nuvem de pontos original, onde Z representa os valores de elevação ou, em nuvem de pontos normalizadas, a coordenada Z reflete a altura (SILVA, 2013).

Ao mapear estoques de carbono e biomassa florestal acima do solo, a tecnologia LiDAR é particularmente útil porque fornece maior resolução e precisão do que apenas imagens ópticas. A filtragem de ruído do solo, que exclui os retornos do solo das nuvens de pontos LiDAR, pode melhorar a modelagem da biomassa acima do solo em paisagens heterogêneas, mas deve ser considerada com cuidado em paisagens extremamente fragmentadas (MAHONEY et al., 2021).

4. MATERIAL E MÉTODOS

4.1 ÁREA DE ESTUDO

A área de estudo (Figura 2) compreende um fragmento florestal da Reserva da Biosfera da Serra do Espinhaço (RBSE), em Minas Gerais, localizada entre as latitudes 18°49’22” e 19°3’48”S e longitudes 43°15’40” e 43°47’1”O. Esta região é caracterizada por um cinturão orogênico, limitado a sudeste pelo Cráton do São Francisco, estendendo-se por aproximadamente 300 km na direção norte-sul, desde o Quadrilátero Ferrífero (Serra do Ouro Branco-MG) até a região de Olhos d'Água-MG. O clima é classificado como Cwb, segundo Köppen, ou seja, mesotérmico com chuvas de verão e verões brandos. A temperatura média anual é de 18,7 ºC, com invernos frios e secos e verões brandos e úmidos, e a precipitação média anual é de aproximadamente 1.500 mm (ABREU, 1995).

Figura 2 - Localização da área de estudo.

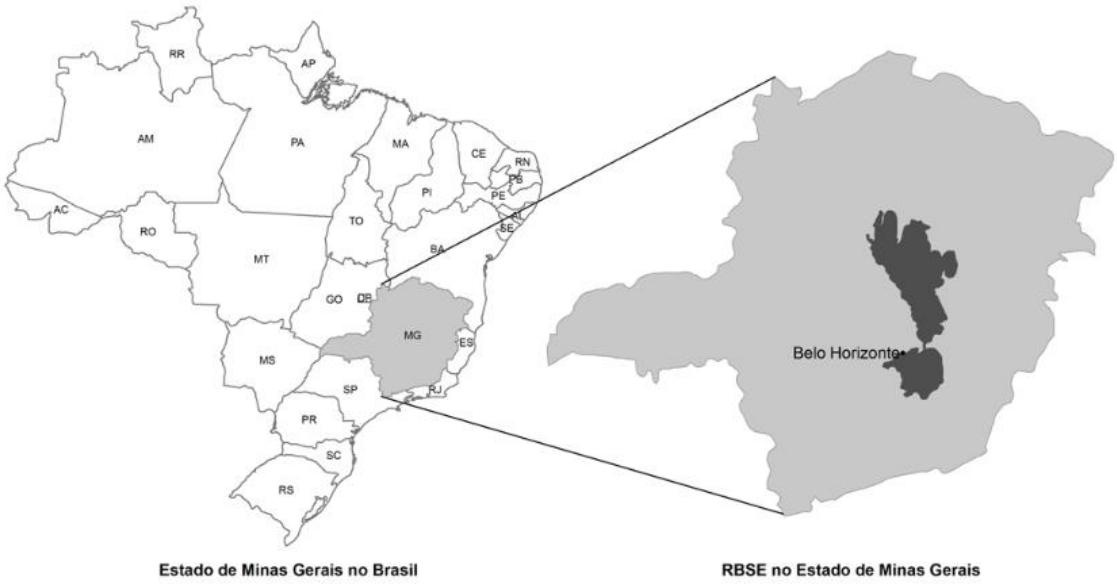

Fonte: Gontijo (2011).

A RBSE é considerada estratégica e importante para a conservação, pois abriga três biomas de alta relevância: Cerrado (a oeste), Mata Atlântica (a leste e sul), e a interseção entre Mata Atlântica e Caatinga (no norte). A região apresenta espécies com alto grau de endemismo e alta fragilidade devido a pressões antrópicas. Existem espécies endêmicas e ameaçadas em áreas de Campos Rupestres na porção

Espinhaço e nos Campos Rupestres Ferruginosos no Quadrilátero Ferrífero e na borda leste do Espinhaço (MUCIDA et al., 2019).

4.2 INVENTÁRIO FLORESTAL TRADICIONAL

O inventário florestal foi realizado em 2022, utilizando amostragem casual estratificada e as coordenadas das parcelas foram extraídas utilizando-se de aparelhos manuais de GPS do modelo Garmim GPSMAP 62 SC. Foram alocadas 26 parcelas na fitofisionomia de Floresta Estacional Semidecidual em Estágio Inicial de Regeneração (FESDI), 113 parcelas em estágio Médio de Regeneração (FESDM), oito parcelas em estágio Avançado de Regeneração (FESDA) e quatro parcelas em fitofisionomia com alta ocorrência de espécies do gênero Eremanthus, (*Eremanthus crotonoides*, *Eremanthus incanus* e o *Eremanthus erythropappus*). Cada parcela possuía 10x30 metros (inserir valor em hectares), onde todos os indivíduos com diâmetro a 1,3 m do solo (*D*) acima de 7 cm foram identificados e feita a aferição do *D* por meio da fita diamétrica e de suas alturas com a régua telescópica.

As médias de *D* e *H* foram calculadas considerando o desvio padrão (S), variância (S²) e coeficiente de variação (CV), utilizando as seguintes equações:

$$\overline{D} = \frac{\sum_{i=1}^{n} D_i}{n} \quad (1)$$

$$\overline{H} = \frac{\sum_{i=1}^{n} H_i}{n} \quad (2)$$

$$S^2 = \frac{\sum_{i=1}^{n} (x_i - \bar{x})^2}{n-1} \quad (3)$$

$$S = \pm\sqrt{S^2} \quad (4)$$

$$CV = \pm\frac{S}{\bar{x}} \quad (5)$$

Em que:

D_i é o diâmetro a altura do peito do i-ésimo indivíduo da parcela;

H_i é a altura do i-ésimo indivíduo da parcela;

x_i é o valor i-ésimo de interesse;

$\overline{x}$ é o média do valor de interesse;

S² é a variância;

S é o desvio padrão da média; e

n é o total de observações.

4.3 BIOMASSA ACIMA DO SOLO

A biomassa acima do solo das árvores foi obtida por meio da adaptação da equação desenvolvida por Amaro (2010) que estimou a biomassa acima do solo (W_f) em uma floresta estacional semidecidual no município de Viçosa-MG (equação 6 - R^2 de 95,63%). A obtenção da biomassa acima do solo total (Equação 9) foi estimada por meio da soma da biomassa acima do solo do fuste (w_f), dos galhos (w_g) (Equação 7) e das folhas (w_{fo}) (Equação 8). Para calcular a biomassa das folhas e ramos foi utilizada a proporção utilizada por Torres et al. (2013), em que a biomassa dos ramos representa 25,96% da biomassa do fuste e a biomassa das folhas representa cerca de 4,45% da biomassa do fuste.

$$w_f = 0{,}033430\ D^{2{,}397902}\ H^{0{,}426536} \tag{6}$$

$$w_g = 0{,}2596\ w_f \tag{7}$$

$$w_{fo} = 0{,}0445\ w_f \tag{8}$$

$$Wt = w_f + w_g + w_{fo} \tag{9}$$

4.4 COLETA E PROCESSAMENTO DE DADOS LIDAR

A coleta de dados LiDAR foi realizada por meio de uma aeronave AS350 PT-HYY, que voou a uma altitude de 600 metros acima do solo e coletou dados das posições x, y e z, correspondendo às coordenadas leste-oeste, norte-sul e elevação, respectivamente. A densidade foi de 8,19 pontos por metro quadrado, com uma sobreposição de 60% longitudinal e 30% lateral. O sensor LiDAR emitiu pulsos de laser durante o voo e os tempos de emissão e retorno foram registrados para calcular distâncias. A seguir serão apresentadas as especificações do LiDAR Optech ALTM GEMINI.

Quadro 1 – Especificações do laser scan Optech ALTM GEMINI

Parâmetros	Especificações
Resolução em range	1 cm
Largura da faixa	Variável de 0 a 0.93 x altitude m
Resolução angular	0.01º
Frequência de oscilação lateral	Variável, máximo 100 Hz
Largura da onda do laser	1064 nm
Frequência dos impulsos do laser	33 kHz (altitude Max AGL 3500m) 100 kHz (altitude máx. AGL 2500m) 142 kHz (altitude máx. AGL 1700m) 189 kHz (altitude máx. AGL 1100m)
Divergência da faixa	Dual com 0.3 mrad ou 0.8 mrad (1/e nominal)
Classe do Laser	Classe IV produto laser (FDA CFR 21)
Receptor GPS	Interno Novotel Millenium DL
Potência requisitada	28 VDC @ 45 Amperes de pico
Temperatura operacional	Rack de controle: +10 ºC a +50 °C Armazenamento: -10ºC até 50ºC
Umidade	0% a 95% sem condensação

Fonte: Autor (2024)

Após o voo, os dados brutos foram pós-processados para georreferenciamento, remoção de pontos inesperados e correção de erros sistemáticos, resultando em uma nuvem de pontos tridimensional que capturou a vegetação e a topografia detalhadas da área de estudo. Os arquivos finais, com cerca de 63,35 milhões de pontos, estão no sistema de coordenadas SIRGAS 2000/UTM ZONA 23S.

Após a coleta dos dados pelo ALS, foi feita a remoção de pontos atípicos manualmente pelo software CloudCompare. Posteriormente, os pontos foram classificados para identificar aqueles pertencentes ao solo utilizando a bliblioteca LidR. Utilizaram-se as funções filter_duplicates para filtrar pontos duplicados, classify_noise para classificar ruído, e rasterize_terrain com o algoritmo tin e resolução de 1 metro para criar um modelo digital do terreno MDT. Após a criação do MDT foi feito o Modelo Digital de superfície (MDS) por meio da função rasterize_canopy com o algoritmo p2r() e com resolução de 1 metro. A função rasterize_terrain normaliza a nuvem de pontos trazendo-a a um plano de referência com coordenada Z = 0 para todos os pontos do

solo, permitindo a criação do Modelo de Altura de Copa das Árvores (CHM) por meio da função rasterize_canopy. Após todas as etapas supracitadas, foram extraídas as métricas por meio da função crown_metrics. As 53 métricas extraídas podem ser apreciadas no Quadro 2.

Quadro 2 - Métricas extraídas da nuvem de pontos LiDAR

Variável	**Descrição**
zmax	Altura máxima
zmin	Altura mínima
zmean	Altura total média
zskew	Assimetria dos valores de altura
zsd	Desvio padrão da altura
zq1 até zq99	Percentil de altura 1º até o 99º
pzabovemean	Proporção de retornos acima da cota média
pzabove2	Proporção de retornos acima de 2 metros
zentropy	Índice de diversidade de Shannon normalizado
imean	Intensidade média
zkurt	curtose
zpcum1 até zpcum9	Densidade dos retornos cumulativos de 10% até 90% da altura
Iskew	Distorção dos retornos
ipcumzq10 ate ipcumzq90	Percentual da intensidade dos retornos dos percentis 10 a 90
p1th, p2th, p3th e p4th	Percentual dos 1º, 2º, 3º e 4º retornos
itot	Soma das intensidades dos retornos

4.5 AJUSTE DE MODELOS PARA ESTIMAR O DIÂMETRO MÉDIO, ALTURA TOTAL MÉDIA E BIOMASSA TOTAL ACIMA DO SOLO

As métricas que foram obtidas foram levadas em consideração ao construir o modelo de regressão linear múltipla $\hat{y} = a_1x_1 + a_2x_2 +...+ a_nx_n + b$, onde b e a_1 a a_n são os parâmetros, x_1 a x_n são os valores das variáveis preditoras.

Para a seleção das variáveis dos modelos para estimar a *H* média, *D* médio e W_t utilizou-se a função regsubsets da biblioteca leaps, que analisa diversos modelos com número de variáveis diferentes e retorna os melhores modelos utilizando critérios de seleção, como critério de informação de Akaike (AIC) de maneira exaustiva.

Após a seleção dos modelos, foi analisada a existência de multicolinearidade entre as variáveis de cada modelo por meio do Fator de Inflação de variância (VIF)

que mede quanto a variância do coeficiente de determinação estimado para uma variável é inflada devido à multicolinearidade com as outras variáveis independentes. Foram selecionados apenas modelos com o VIF menores que 10 No final, cada um dos modelos foi comparado de acordo com suas estatísticas.

4.6 AVALIAÇÃO DOS RESULTADOS

Para a avaliação da exatidão das estimativas geradas para *D*, *H* e W_t, foram utilizadas as estatísticas: Coeficiente de determinação ajustado (10 - Kvålseth, 1985) e raiz do quadrado médio do erro (11). O coeficiente de determinação ajustado varia de 0 a 1 e quanto mais próximo do valor 1, melhor o ajuste do modelo aos dados. Além disso, foram feitas as análises gráficas dos valores observados e estimados.

$$\overline{R}^2 = 1 - \frac{(n-1)}{(n-p)}(1-R^2) \tag{10}$$

Em que: $R^2 = 1 - \frac{\sum_{i=1}^{n}(Y_i - \hat{Y}_i)^2}{\sum_{i=1}^{n}(Y_i - \overline{Y}_i)^2}$

$$RQME(\%) = \frac{100}{\overline{Y}}\sqrt{\frac{\sum_{i=1}^{n}\left(Y_i - \hat{Y}_i\right)^2}{n}} \tag{11}$$

Em que: Y_i é a variável dependente observada; $\hat{Y}_i$ é a variável dependente estimada; $\overline{Y}$ é a média da variável dependente observada; n é a número de observações e p é o número de parâmetros da equação.

5. RESULTADOS E DISCUSSÃO

5.1 INVENTÁRIO FLORESTAL TRADICIONAL

O *D*, *H* e estoque de W_t pode ser verificado na Tabela 1. O *D*, *H* e W_t foram obtidos para as classes FESDI, FESDM, FESDA e Candeal (alta ocorrência de

espécie do gênero *Eremanthus*) e foram de 16,1591, 47,9502, 219,9856 e 9,4153 t/parcela.

Tabela 1 - Média ($\overline{x}$), desvio padrão da média (s), variância (s^2) e coeficiente de variação (CV%) da W_t, *D* e *H*.

Fitofisionomia	Variável	$\overline{x}$	s^2	s	CV (%)
FESDI	W_t (t/parcela)	110,51	0,05	0,18	0,16
	D (cm)	7,77	11,23	3,35	43,11
	H (m)	6,89	4,72	2,17	31,49
FESDM	W_t (t/parcela)	1695,20	0,73	0,66	0,04
	D (cm)	9,79	38,16	6,18	63,13
	H (m)	9,39	15,43	3,93	41,85
FESDA	W_t (t/parcela)	514,04	28,84	4,62	0,90
	D (cm)	14,00	158,99	12,61	90,07
	H (m)	12,83	45,16	6,72	52,38
Candeal	W_t (t/parcela)	18,37	0,01	0,08	0,41
	D (cm)	7,01	5,88	2,42	34,52
	H (m)	4,29	3,21	1,79	41,72

O FESDA foi a fitofisionomia que teve o maior valor de W_t. Isso ocorre, principalmente, devido ao fato de quanto mais o fragmento florestal avança no estágio de regeneração, maior são os *D* e a *H* dos indivíduos. Desta maneira, os indivíduos pertencentes aos estágios de regeneração mais elevados, em média, possuem maior biomassa que indivíduos de estágios iniciais de regeneração. O Candeal, por se tratar de uma fitofisionomia com árvores mais distantes e solos mais pobres nutricionalmente, possuem menor *H* e *D*, isso implica em menos acúmulo de W_t.

O FESDI, FESDA e FESDM tiveram as parcelas 169 (38,10 t/parcela), 6 (613,67 t/parcela) e 201 (138,20 t/parcela), respectivamente, com valores de biomassa notavelmente superiores à média, faz com que os valores de desvio padrão sejam elevados. Características como disponibilidade de nutrientes, tipo de solo, radiação solar e disponibilidade hídrica, também são fatores que influenciam o acúmulo de biomassa. Na paisagem de tipo mediterrâneo da Reserva Biológica Jasper Ridge, notou-se que a radiação solar, o tipo de substrato e a posição topográfica são preditores significativos de biomassa acima do solo (DAHLIN; ASNER; FIELD, 2012). Outro fator que influenciou diretamente na média, variância e desvio

padrão da W_t foi a heterogeneidade da área de estudo. Por se tratar de uma área em regeneração natural, algumas parcelas podem ser enquadradas como FESDM, de acordo com a legislação vigente. Contudo, indicadores como o diâmetro médio sugerem características de florestas em estágio avançado de regeneração natural.

5.2 LIDAR

Com base na nuvem de pontos fornecidas, foi obtido o MDT (Figura 3).

Figura 3 – Modelo digital de terreno da área de estudo.

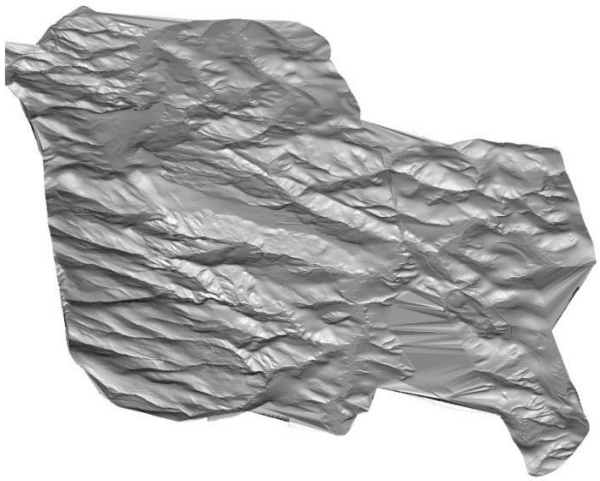

Fonte: Autor (2024).

A partir do MDT foram geradas as nuvens de pontos normalizadas (Figura 4), no qual foi possível a extração das parcelas do inventário para o cálculo das métricas e a estimação do D, H e W_t.

Figura 4 – Nuvem de pontos normalizada da área de estudo

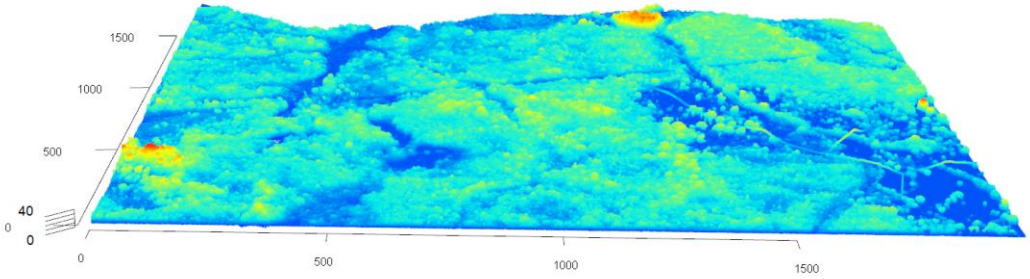

Fonte: Autor (ano)

Analisando a correlação das variáveis obtidas por meio do LiDAR, foi possível investigar a correlação entre a Biomassa Acima do solo (W_t), Diâmetro Médio, a altura total média e os dados do laser aerotransportado (Figura 5). O *D* é uma medida diretamente relacionada a altura e o volume do tronco de uma árvore. Como o tronco representa uma porção significativa da biomassa de uma árvore, há uma relação direta e forte entre o *D* e *Wt* e *H* e *D*. Árvores com maiores *D*s geralmente têm mais biomassa porque elas possuem troncos mais grossos e, frequentemente, maior volume de madeira. O *D* é uma variável significativamente correlacionada com a estimativa de biomassa, o que faz com que seja amplamente utilizada em equações alométricas para estimativa de biomassa (LI et al., 2019; WANG, X.; GARD; VAN DE KUILEN, 2019).

Figura 5 – Gráfico da correlação de Pearson das variáveis de interesse para a Biomassa Acima do solo(*Wt*), Diâmetro Médio (*D*) e Altura Máxima (*H*)

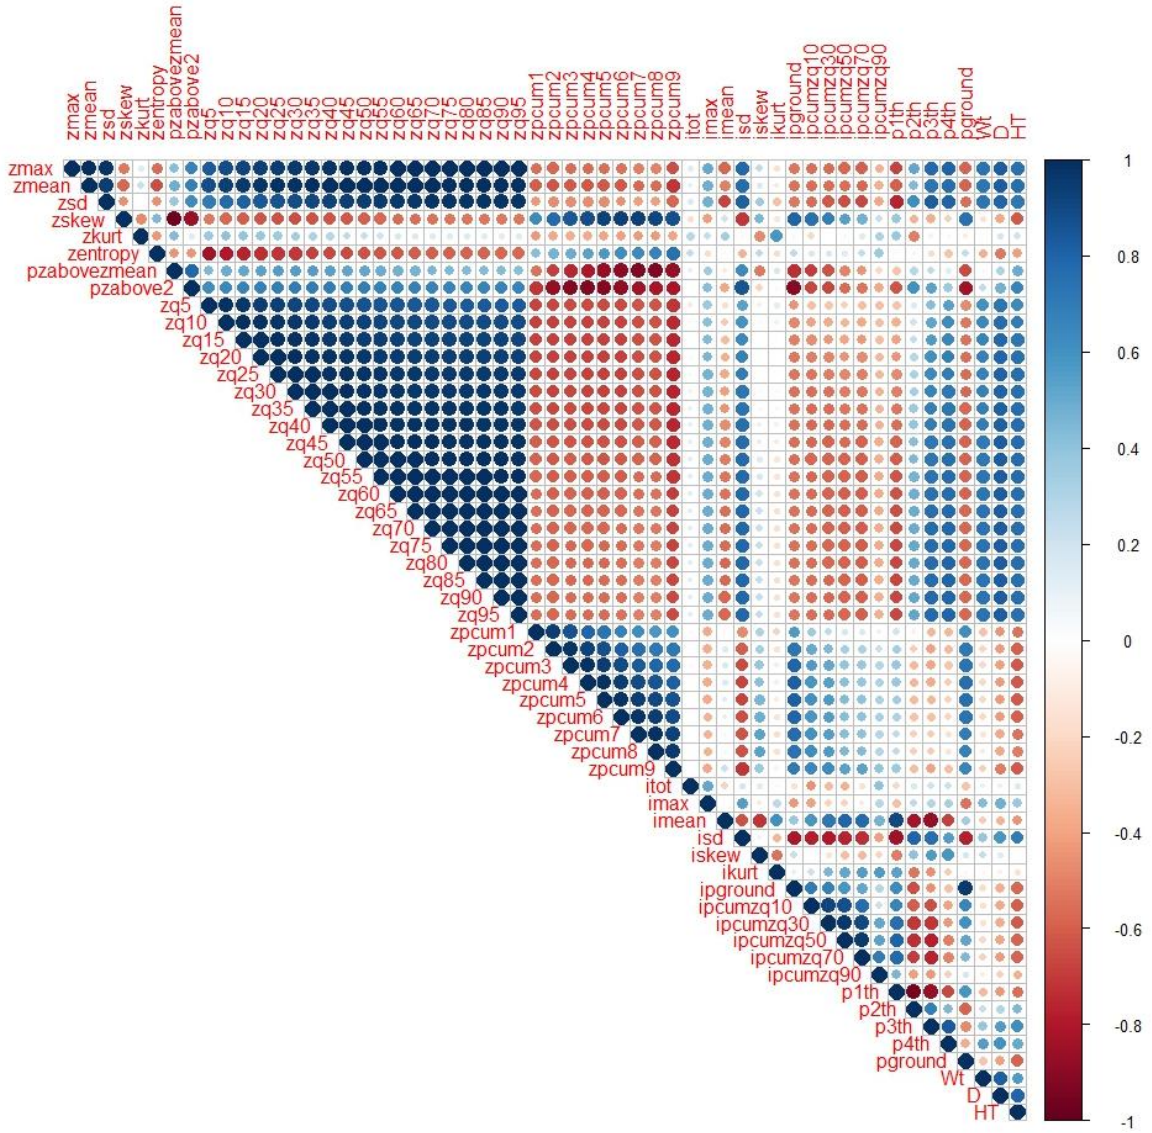

Fonte: Autor (2024).

Foram encontradas 18 variáveis que obtiveram *r* superior ou igual a 0,70 (entre 0,70 e 0,74), o que demonstra uma possível alta correlação entre os valores estimados e medidos/observados. É possível notar que vários pares de variáveis possuem correlação e essa correlação pode indicar uma possível multicolinearidade entre as métricas LiDAR o que pode diminuir a precisão da previsão do modelo (JAMES et al., 2023).

5.2.1 Modelo para Estimação do Diâmetro Médio

Na Tabela 2 estão apresentadas as variáveis selecionadas para os modelos com VIF < 10. Árvores mais altas tendem a ter maior *D*, pois troncos maiores suportam copas mais altas e maiores. Portanto, um *zq65* e *imean* maiores indicam árvores mais altas e, consequentemente, maiores *D*. A correlação ocorre porque o crescimento em altura está frequentemente relacionado ao crescimento em diâmetro. Como o *zpcum7* está relacionada a distribuição vertical da biomassa, pois é o percentil 70% dos retornos de altura, valores maiores de *zpcum7* indicam que uma porção significativa da vegetação está situada em alturas maiores, sugerindo árvores mais altas e possivelmente com maiores diâmetros. Desta maneira, *zq65*, *imean* e o *zpcum7* foram as variáveis que integram os modelos que melhor ajustaram aos dados devido à forte correlação do *D* com a estrutura vertical da floresta e o crescimento das árvores, como bem salientam Mahajan (2020), Yun et al. (2022) e Zimble et al. (2003).

Tabela 2 - Métricas selecionadas para modelos com uma, duas ou três variáveis.

Modelo	Variáveis Selecionadas
1	*zq65*
2	*zq65 + imean*
3	*zq65 + zpcum7 + imean*

Fonte: Autor (2024).

A altura do percentil 65 foi selecionada em todos os modelos, o que mostra a importância da variável na estimação do diâmetro na área de estudo. Contudo, apenas o percentil 65 de altura pode explicar 68,24% da variação dos dados em campo, indicando que a parte inferior do dossel da vegetação pode estar relacionada a grande variação do diâmetro médio encontrado em campo.

As estimativas dos parâmetros e o teste para os parâmetros são apresentados na Tabela 3. Verifica-se que todos os parâmetros são significativos ($p<0,05$), com exceção do intercepto dos modelos 2 e 3.

Tabela 3 - Estimativa dos parâmetros dos modelos para estimar a *D*.

Modelo	Parâmetro	Valor Estimado	Erro Padrão	tc	p-valor
1	β_0	5,712	0,278	20,518	<0,001
	β_1	0,372	0,024	15,474	<0,001
2	β_0	1,7440	1,4896	1,1708	0,2442
	β_1	0,4139	0,0281	14,7333	<0,001
	β_3	0,0360	0,0133	2,7089	<0,001
3	β_0	-1,3635	1,9083	-0,7145	0,4764
	β_1	0,4660	0,0344	13,5525	<0,001
	β_3	0,0336	0,0134	2,5154	0,0134
	β_4	0,0474	0,0137	3,4477	<0,001

Na Tabela 4 estão as estatísticas de acurácia para os modelos para estimar *D* médio com VIF < 10.

Tabela 4 – Coeficiente de determinação ajustado (R^2 aj), raiz dos quadrados médio do erro (RQME) e raiz dos quadrados médios dos erros percentual (RQME(%)) para os modelos para estimar *D.*

Modelo	R^2	R^2 aj	RQME	RQME (%)
1	0,6852	0,6824	1,1011	11,35
2	0,7051	0,6997	1,066	10,99
3	0,7214	0,7137	1,036	10,68

O modelo que melhor ajustou aos dados foi o 3, pois obteve maior valor de R^2aj e menor RQME (%). Os resultados obtidos foram similares a estudos de outros autores. Zhang, Cao e She, (2017) ajustaram modelos para estimar *D* em uma floresta boreal e obtiveram um R^2 variando entre 0,48 a 0,74 e RQME (%) variando entre 8,59% a 12,33% com modelos de regressão linear múltipla que utilizaram o percentil de altura 95 e a densidade de pontos abaixo do percentil 10 e 70. Na Figura 6, estão plotados os valores observados e os respectivos valores preditos por meio do modelo ajustado.

Figura 6 - Gráfico de dispersão dos valores observados/medidos e valores estimados por meio do modelo ajustado para a estimativa de Diâmetro Médio.

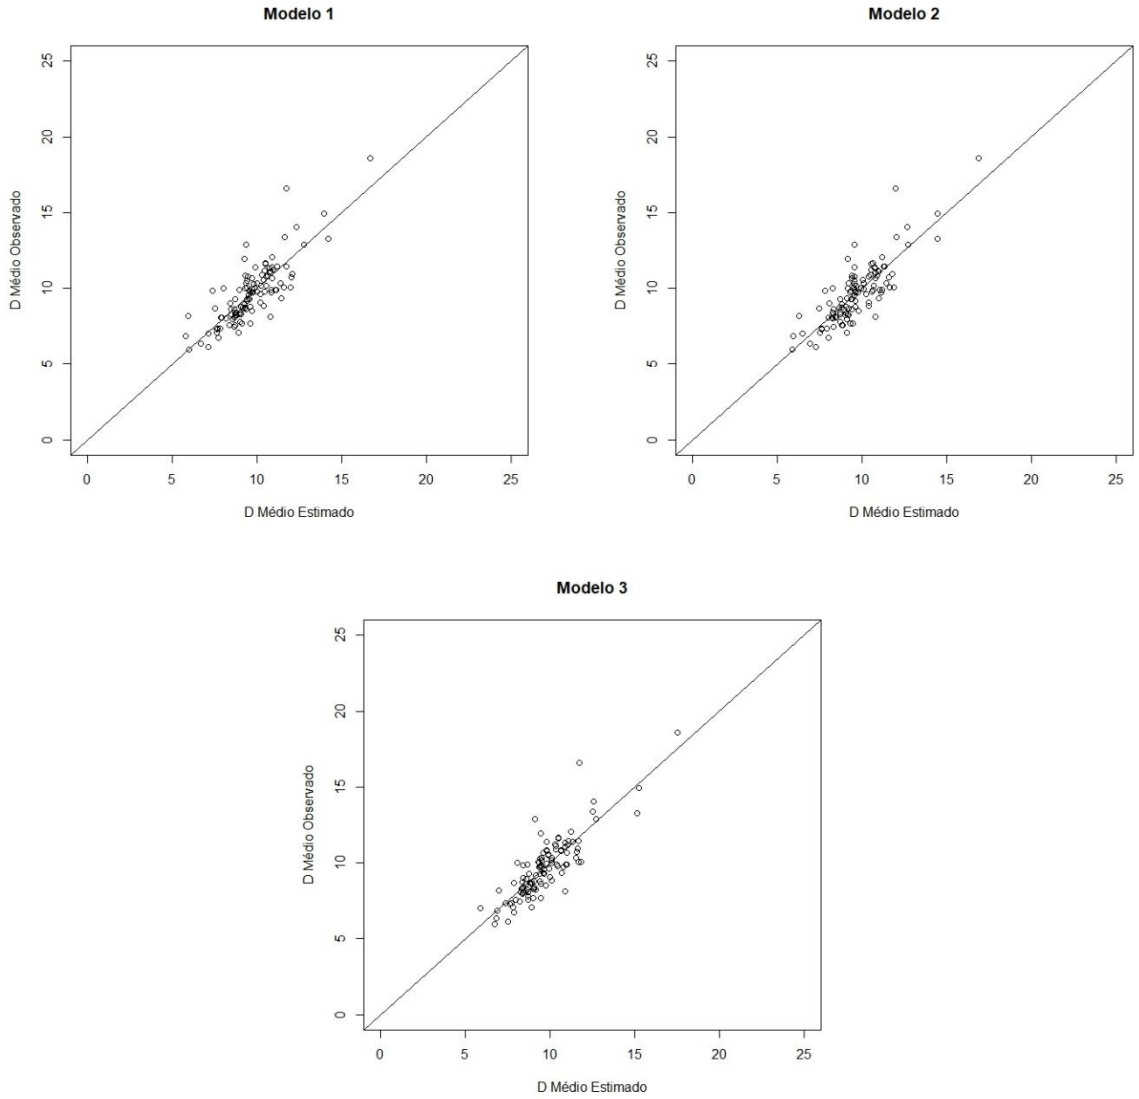

Fonte: Autor (2024).

Os valores de RQME e RQME (%) foram inferiores aos relatados por diversos autores, especialmente em comparação com modelos que utilizaram estimativas de medição direta a partir de nuvens de pontos. Corte et al. (2020) obtiveram estimativas diretamente dessas nuvens de pontos e encontraram RQME de 3,46 cm, RQME (%) de 11,31% e um coeficiente de correlação de 0,77 em uma área de ILPF (integração lavoura-pecuária-floresta) com plantações seminais de *Eucalyptus benthamii*.

O modelo para estimar *D* médio foi relativamente eficiente, ultrapassando valores encontrados em literatura que tinham como características principais ou medir diretamente um atributo florestal e/ou florestas mais homogêneas.

5.2.2 Modelo para Estimação de Altura Total Média

Na Tabela 5 são apresentadas as variáveis selecionadas com VIF < 10, modelos com 3 e 4 variáveis apresentaram VIF superior ao valor supracitado e não foram incluídos no presente estudo.

Tabela 5 - Métricas selecionadas para modelos com uma, duas e cinco variáveis

Modelo	Variáveis Selecionadas
1	*zq40*
2	*zq25 + ipcumzq30*
3	*zq15 + zpcum8 + iskew + ipcumzq50 + p1th*

Três das variáveis que compuseram os melhores modelos estavam relacionadas a densidade dos pontos, podendo ser de maneira percentual ou total cumulativo (*zpcum*, *p1th* e *ipcumzq*) ou relacionado a distorção dos retornos (*iskew*). A densidade dos retornos está relacionada diretamente com o tamanho da copa das árvores. O *p1th* está relacionado a porcentagem dos primeiros retornos, e está presente na composição do melhor modelo selecionado é esperado por estar relacionado diretamente com o topo do dossel das árvores.

As estimativas dos parâmetros e o teste para os parâmetros são apresentados na Tabela 6. Verifica-se que todos os parâmetros foram significativos (p<0,05), com exceção do intercepto do modelo 2.

Tabela 6 - Estimativa dos parâmetros dos modelos para estimar a *H* média.

Modelo	Parâmetro	Valor Estimado	Erro Padrão	tc	p-valor
1	β_0	5,4740	0,3112	17,5911	<0,001
	β_1	0,4171	0,0336	12,4293	<0,001
2	β_0	10,1080	1,0104	10,0044	0,2442
	β_1	0,3999	0,0451	8,8734	<0,001
	β_3	-0,1676	0,0372	-4,5050	<0,001

3	β_0	13,2756	1,4820	8,9579	<0,001
	β_1	0,6286	0,0684	9,1893	<0,001
	β_2	0,1191	0,0290	4,1039	<0,001
	β_3	-7,1287	1,4322	-4,9774	<0,001
	β_4	-0,2106	0,0511	-4,1226	<0,001
	β_5	-0,0814	0,0243	-3,3420	0,001

O modelo que apresentou o melhor ajuste, segundo os critérios estatísticos, foi o Modelo 3 com maiores valores de R² ajustado e menor RQME (%), sucedido pelo Modelo 2 e o Modelo 1 (Tabela 7). Verifica-se que a medida que aumenta o número de variáveis, aumenta a acurácia das estimativas. Contudo, em alguns casos, houve um aumento da colinearidade entre as variáveis, o que culminou no aumento do VIF. O aumento do VIF não ocorreu para o caso em que foram analisadas 5 variáveis.

Tabela 7 - Coeficiente de determinação ajustado (R² aj), raiz dos quadrados médio do erro (RQME) e raiz dos quadrados médios dos erros percentual (RQME(%)) para os modelos para estimar *H*.

Modelo	R	R²	R² aj	RQME	RQME (%)
1	0,7643	0,5841	0,5803	1,27	14,04
2	0,7979	0,6366	0,6300	1,19	13,12
3	0,8376	0,7016	0,6875	1,07	11,89

O modelo que melhor se ajustou aos dados foi o modelo 3, por apresentar maior R²aj e menor RQME. Na Figura 7 podem ser contemplados os gráficos dos valores observados e os respectivos valores preditos por meio do modelo ajustado.

Figura 7 - Gráfico de dispersão dos valores observados/medidos e valores estimados por meio do modelo ajustado para a estimativa da altura total média .

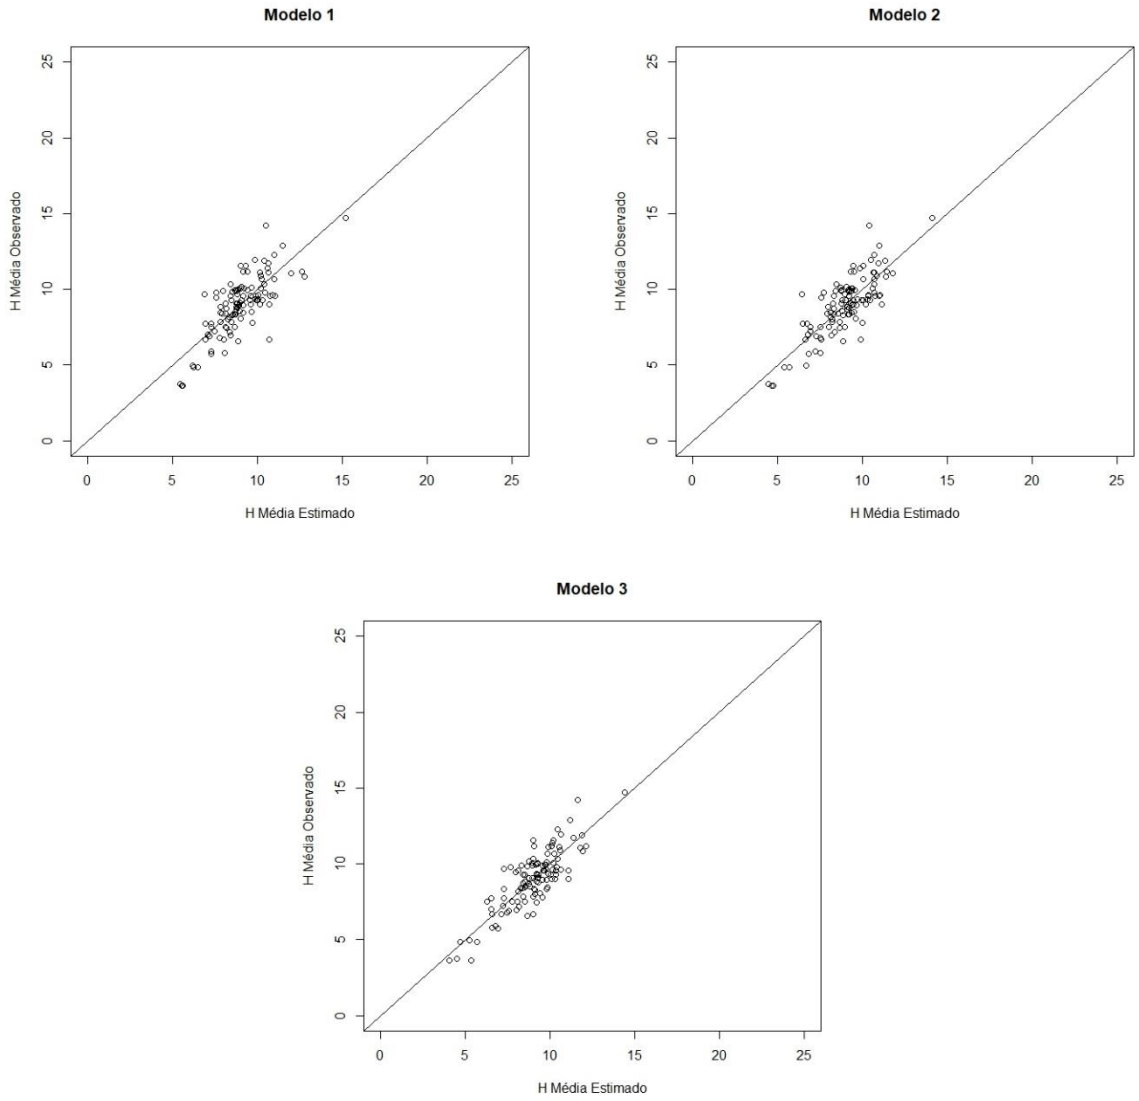

Fonte: Autor

Os valores de RQME foram similares e o RQME (%) foram relativamente maiores aos encontrados por outros autores. Wallace et al. (2016) compararam a varredura a laser aerotransportado (ALS) e o *Structure from Motion* (SfM) para medir e quantificar propriedades estruturais de uma floresta de eucalipto com características esclerofilias na Tasmânia, Austrália, em que obteram um RQME de 0,92 m para o ALS e 1,30 m para o SfM. Corte et al. (2020) avaliaram o potencial uso de um sistema UAV-lidar para medir métricas estruturais florestais (*D* e *H* individual) por uma abordagem automática em um sistema integrado de lavoura-pecuária e floresta no município de

Pinhais no Paraná, sendo que para a estimativa da altura foi utilizado a altura do percentil 95% derivada das métricas do LiDAR encontrando um RQME de 1,51% e 7,91%, respectivamente. Vale salientar que a densidade de pontos por m² utilizado por vários autores foram muito superiores ao usado no presente estudo, em alguns casos chegando a mais de 1400 pontos por m².

5.2.3 Modelo para Estimação da Biomassa Acima do Solo

Na Tabela 8 estão apresentadas as variáveis selecionadas com o VIF < 10. A altura das árvores está diretamente relacionada a biomassa que possui e todos os modelos selecionados possuem a altura máxima ou o percentil de altura como variáveis selecionadas. A biomassa também está relacionada a porcentagem volumétrica de retornos (*zpcum*), pois quanto maior a biomassa acima do solo, maior vão ser os retornos relacionados. As variáveis selecionadas foram similares a outros estudos realizados. Pan; Huang, Huang (2023) encontraram em seus estudos que um modelo de regressão que as variáveis relacionadas à altura máxima, altura do percentil 95 e 65 foram as principais preditora da biomassa.

Tabela 8 – Métricas selecionadas para modelos com uma, duas ou três variáveis.

Modelo	Variáveis Selecionadas
1	*zmax*
2	*zsd + p3th*
3	*zq65 + zpcum9 + p3th*

Fonte: Autor

As estimativas dos parâmetros e o teste para os parâmetros são apresentados na Tabela 9. Verifica-se que todos os parâmetros são significativos (p<0,05).

Tabela 9 – Estimativa dos parâmetros dos modelos para estimar a Biomassa Acima do Solo.

Modelo	Parâmetro	Valor Estimado	Erro Padrão	tc	p-valor
1	β_0	- 23,48	12,546	-5,400	<0,001
	β_1	4,131	0,331	12,4873	<0,001
2	β_0	-29,810	3,954	-7,538	<0,001
	β_1	24,449	1,827	13,380	<0,001
	β_3	-5,263	-0,824	-6,390	<0,001

Modelo	Parâmetro	Valor Estimado	Erro Padrão	tc	p-valor
3	β_0	-132,110	15,050	-8,778	<0,001
	β_1	8,532	0,543	15,709	<0,001
	β_3	1,448	0,191	7,596	<0,001
	β_4	-4,125	0,653	-6,312	<0,001

O modelo que apresentou o melhor ajuste, segundo os critérios estatísticos, foi o Modelo 3 com maiores valores de R² ajustado e menor RQME (%), sucedido pelo Modelo 2 e Modelo 1 (Tabela 10). Verifica-se que à medida em que foi selecionado um número maior de variáveis, a acurácia das estimativas aumentou.

Tabela 10 – Coeficiente de determinação ajustado (R² aj), raiz dos quadrados médio do erro (RQME) e raiz dos quadrados médios dos erros percentual (RQME(%)) para os modelos para estimar W_t.

Modelo	R²	R² aj	RQME	RQME (%)
1	0,5864	0,5826	16,53	60,16
2	0,6923	0,6867	14,12	51,89
3	0,7589	0,7522	12,50	45,26

Fonte: Autor

O valor do RQME (%) foi muito superior ao encontrado por Zhang et al. (2023), em que estimaram a biomassa acima do solo em uma floresta subtropical no nordeste de Conghua, província de Guangdong na China, desenvolveram um modelo por meio da altura total média, altura dos percentis 80, 90 e 95 e densidades de pontos de 20_30 metros, a 14 metros, 22 metros e 26 metros para produzir um mapa de referência de biomassa satisfatório. Apesar do R² do presente estudo ter sido superior aos autores supracitados, os valores de RQME (%) foram mais de duas vezes menores, o que sugere estimativas com menores erros entre os valores estimados e medidos de biomassa. Como pode ser visualizado na Figura 8, conforme são acrescentadas variáveis ao modelo, melhor é o ajuste e menor é a diferença entre o que foi medido e o que foi estimado.

Figura 8 - Gráficos de dispersão dos valores observados/medidos e valores estimados por meio do modelo ajustado para a estimativa de Biomassa Acima do Solo (W_t) dos modelos regressão selecionados.

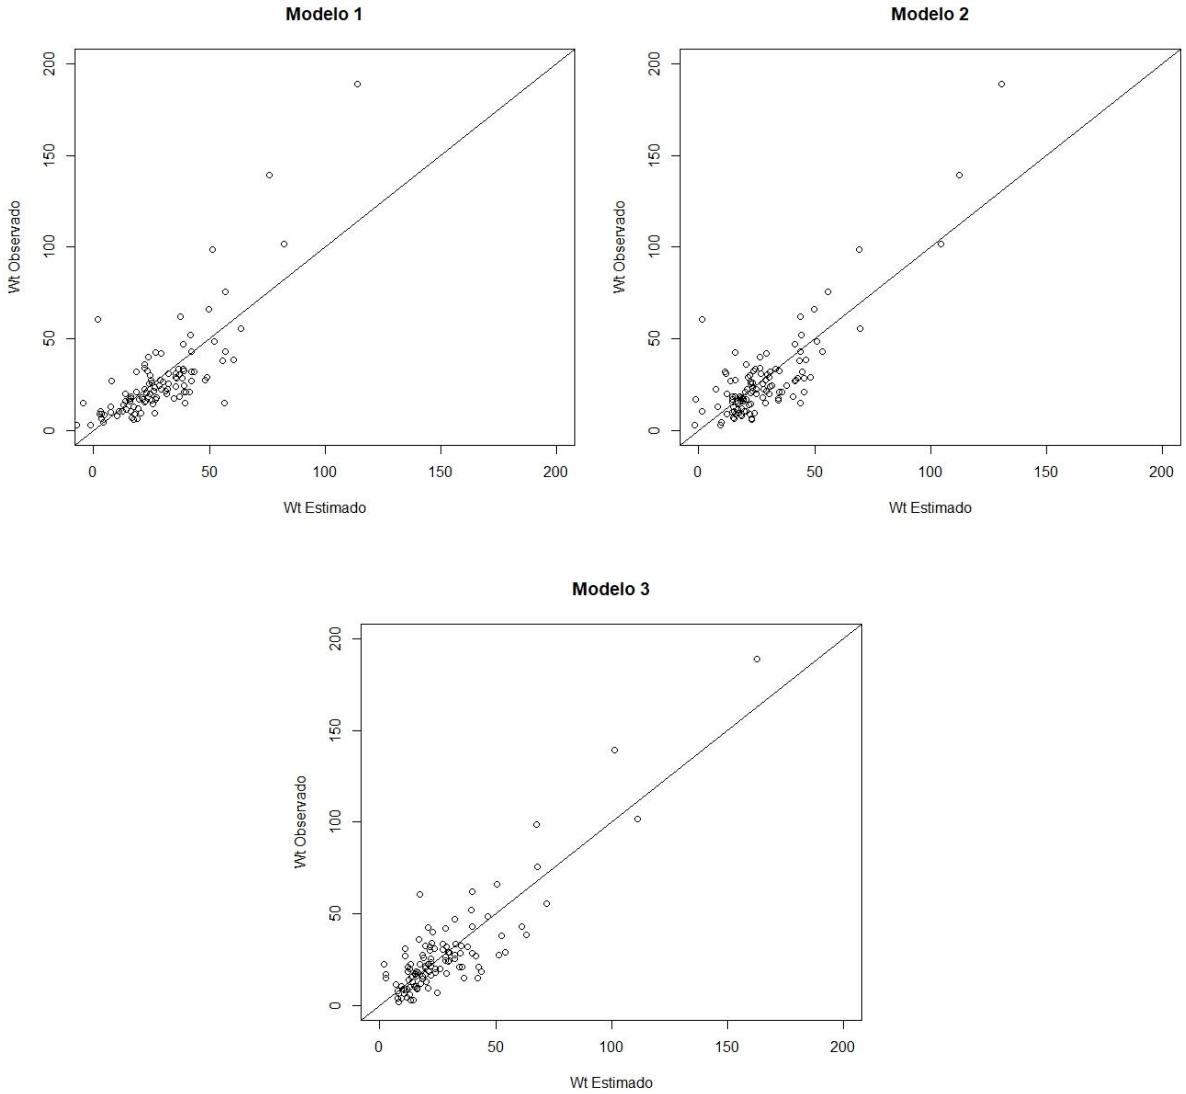

Fonte: Autor (2024).

6. CONCLUSÕES

Os dados de inventário quando relacionados com as métricas do LiDAR se mostraram eficientes para obtenção de estimativas de *D* médio, *H* média e W_t. Por meio deste estudo foi possível verificar que as métricas que melhor explicam a variabilidade da biomassa acima do solo foram *zq65*, *zpcum9*, *p3th*. Enquanto para o *D* médio, as métricas que melhor explicaram foi o *imean*, *zpcum7* e *zq65*. Em relação a estimativa da *H* média, houveram cinco variáveis que melhor explicaram a variação da altura total média (*zq15*, *zpcum8*, *iskew*, *ipcumzq50*, *p1th*). Desta maneira, os melhores modelos geraram estimativas de média acurácia devido a heterogeneidade das fitofisionomias analisadas. A variável altura do percentil 65 esteve nos melhores modelos ajustados para *D* médio e W_t, mostrando a importância das variáveis relacionadas a parte inferior do dossel da vegetação.

7. REFERÊNCIAS

AMARO, M. A. **Quantificação do estoque volumétrico, de biomassa e de carbono em uma Floresta Estacional Semidecidual no Município de Viçosa-MG**. 2010. XXp Tese (Doutorado em) – Universidade Federal de Viçosa, Viçosa, 2010.

ASENOVA, M.; DONCHEV, G.; EVANGELOV, E. Personal laser scanning technology for 3D mapping and forest inventory. **International Multidisciplinary Scientific GeoConference: SGEM**, v. 22, n. 2.1, p. 347-354, 2022. Disponível em: https://doi.org/10.5593/sgem2022/2.1/s10.41. Acesso em: 21 Set. 2024.

BARROS, Q. S. et al. Potencial da tecnologia LiDAR terrestre na área florestal. **Scientia Naturalis**, v. 5, n. 1, 2023. Disponível em: https://www.doi.org/10.29327/269504.5.1-29. Acesso em: 24 Set. 2024.

BUDEI, B. C. et al. Identifying the genus or species of individual trees using a three-wavelength airborne lidar system. **Remote Sensing of Environment**, v. 204, p. 632–647, 2018.

CALDEIRA, C. R. T. et al. Comparação entre os modelos digitais de terreno gerados por Radar em Banda P e LiDAR na Amazônia, um estudo de caso no Amapá (Brasil). **Revista de Geociências do Nordeste**, v. 9, n. 1, p. 59-70, 2023.

CORTE, A. P. D. et al. Measuring individual tree diameter and height using GatorEye High-Density UAV-Lidar in an integrated crop-livestock-forest System. **Remote Sensing**, v. 12, n. 5, p. 863, 2020. Disponível em: https://www.mdpi.com/2072-4292/12/5/863/htm. Acesso em: 24 Jun. 2024.

DAHLIN, K. M.; ASNER, G. P.; FIELD, C. B. Environmental filtering and land-use history drive patterns in biomass accumulation in a mediterranean-type landscape. **Ecological Applications**, v. 22, n. 1, p. 104–118, 2012. Disponível em: https://onlinelibrary.wiley.com/doi/full/10.1890/11-1401.1. Acesso em: 23 Jun. 2024.

FARIAS, C. A. de et al. Comparação de métodos de amostragem para análise estrutural de florestas ineqüiâneas. **Revista Árvore**, v. 26, n. 5, p. 541–548, 2002. Disponível em: https://www.scielo.br/j/rarv/a/wmDRkzMHNGb7m7TshwL3L6M/. Acesso em: 23 Jun. 2024.

FOULADINEJAD, F. et al. History and applications of space-borne lidars. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 42, p. 407-414, 2019. Disponível em: https://www.doi.org/10.5194/ISPRS-ARCHIVES-XLII-4-W18-407-2019. Acesso em: 24 Set. 2024.

GIONGO, M. et al. LiDAR: princípios e aplicações florestais. **Pesquisa Florestal Brasileira**, v. 30, n. 63, p. 231, 2010. Disponível em: https://pfb.cnpf.embrapa.br/pfb/index.php/pfb/article/view/148. Acesso em: 23 Jun. 2024.

GONTIJO, B. M. **Serra do espinhaço em foco**. Disponível em: https://www2.ufmg.br/imagensdoconhecimento/Imagens/Areas/Ciencias-Exatas-e-da-Terra/Serra-do-Espinhaco-em-foco#cont. Acesso em: 25 Jun. 2024.

GUTERRES, T. T. S. C. Uso de imagens aéreas obtidas por VANT em inventário florestal em uma floresta urbana no município de Belém, Pará, Brasil. 2023.

HE, Q. et al. Above-ground biomass and biomass components estimation using LiDAR data in a coniferous forest. **Forests** v. 4, n. 4, p. 984–1002, 2013. Disponível em: https://www.mdpi.com/1999-4907/4/4/984/htm. Acesso em: 23 Jun. 2024.

HEYM, M. et al. Utilising forest inventory data for biodiversity assessment. **Ecological Indicators**, v. 121, p.107-196, 2021. Disponível em: https://www.sciencedirect.com/science/article/pii/S1470160X20311353. Acesso em: 23 Jun. 2024.

JAMES, G. et al. **An introduction to statistical learning**. Springer Texts in Statistics. 2023. Disponível em: https://link.springer.com/10.1007/978-3-031-38747-0. Acesso em: 26 Jun. 2024.

JUNTTILA, S. et al. The potential of dual-wavelength terrestrial lidar in early detection of Ips typographus (L.) infestation – Leaf water content as a proxy. **Remote Sensing of Environment**, v. 231, 2019. Disponível em: https://www.sciencedirect.com/science/article/pii/S0034425719302834. Acesso em: 23 Jun. 2024.

JESUS, A. S. et al. Influência de aspectos geológicos, hidrogeológicos, geomorfológicos e da cobertura vegetal no estado de saturação do solo. In: CARVALHO, J. C.; GITIRANA JÚNIOR, G. F. N.; MACHADO, S. L.; MASCARENHAS, M. M. A.; SILVA FILHO, F. C. (org.). **Solos não saturados no contexto geotécnico. São Paulo: Associação Brasileira de Mecânica dos Solos e Engenharia Geotécnica**, 2015. Disponível em: https://doi.editoracubo.com.br/10.4322/978-65-992098-3-3.cap06. Acesso em: 26 Set. 2024.

JÚNIOR, A. R. S. et al. Quantification of above-ground carbon stocks in the Maranhão Amazon. **Revista Brasileira de Geografia Física**, v. 17, n. 4, p. 3008-3021, 2024.

KERSHAW, J. A. et al. Perpendicular distance sampling (PDS). **Forest Mensuration**, p. 415–425, 2017. Disponível em: https://books.google.com/books/about/Forest_Mensuration.html?hl=pt-BR&id=SGVJDQAAQBAJ. Acesso em: 23 Jun. 2024.

LAHSSINI, S. et al. Forest Inventory: Assessing Forest Resources for Sustaining Their Management–Contribution of Geospatial Technologies. **Geospatial Technologies for Effective Land Governance**, p. 174-193, 2019. Disponível em: https://doi.org/10.4018/978-1-5225-5939-9.ch011. Acesso em: 21 Set. 2024

LI, C. et al. Effect of sample size on the estimation of forest inventory attributes using airborne LiDAR data in large-scale subtropical areas. **Annals of Forest Science**, v.

80, n. 1, p. 40, 2023. Disponível em: https://doi.org/10.1186/s13595-023-01209-4. Acesso em: 23 Jun. 2024.

LI, Y. et al. Spatial structure of the vertical layers in a subtropical secondary forest 57 years after clear-cutting. **iForest - Biogeosciences and Forestry**, v. 12, n. 5, p. 442, 2019.

MA, J. et al. Compact dual-wavelength blue-green laser for airborne ocean detection lidar. **Applied Optics**, v. 59, n. 10, p. C87–C91, 2020. Disponível em: <https://opg.optica.org/viewmedia.cfm?uri=ao-59-10-C87&seq=0&html=true>. Acesso em: 23 Jun. 2024.

MACIEL, A. de O. Aplicações: mapeamento móvel utilizando tecnologia LIDAR. *In:* Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Curitiba, 30 de Abr. de 2011. Disponível em: http://marte.sid.inpe.br/col/dpi.inpe.br/marte/2011/07.18.14.18/doc/p0946.pdf. Acesso em: 23 Jun. 2024.

MAGDON, P. et al. Evaluating the potential of ALS data to increase the efficiency of aboveground biomass estimates in tropical peat–swamp forests. **Remote Sensing 2018**, v. 10, n. 9, p. 1344, 2018. Disponível em: https://www.mdpi.com/2072-4292/10/9/1344/htm. Acesso em: 23 Jun. 2024.

MAHAJAN, P. K. Estimating the effect of morphological characteristics on biomass potential in Acacia catechu using correlation and path coefficient analysis. **Indian Journal of Pure & Applied Biosciences**, v. 8, n. 4, p. 669–673, 2020. Disponível em: http://dx.doi.org/10.18782/2582-2845.8315. Acesso em: 23 Jun. 2024.

MAHONEY, M. J. et al. Filtering ground noise from LiDAR returns produces inferior models of forest aboveground biomass in heterogenous landscapes. **GIScience & Remote Sensing**, v. 59, n. 1, p. 1266–1280, 2022. Disponível em: https://www.tandfonline.com/doi/abs/10.1080/15481603.2022.2103069. Acesso em: 23 Jun. 2024.

MARQUES, I.; WIEMANN, P. F. V; KNEIB, T. A Variance Partitioning Multi-level Model for Forest Inventory Data with a Fixed Plot Design. **Journal of Agricultural, Biological and Environmental Statistics,** v. 28, n. 4, p. 706-725, 2023. Disponível em: https://doi.org/10.1007/s13253-023-00548-z. Acesso em: 24 Set. 2024.

MCGRATH, C. et al. Investigation of very low Earth orbits (VLEOs) for global spaceborne lidar. **CEAS Space Journal**, v. 14, n. 4, p. 625–636, 2022. Disponível em: https://link.springer.com/article/10.1007/s12567-022-00427-2. Acesso em: 25 Jun. 2024.

MUCIDA, D. P. et al. A degradação ambiental em narrativas de naturalistas do século XIX para a reserva da Biosfera da Serra do Espinhaço / Environmental degradation in narratives of naturalists of the 19th century for the Espinhaço Range Biosphere Reserve. **Caderno de Geografia**, v. 29, n. 57, p. 465–495, 2019. Disponível em:

https://periodicos.pucminas.br/index.php/geografia/article/view/19590. Acesso em: 23 Jun. 2024.

NISHIWAKI, A. A. M. et al. Uso do LiDAR na estimativa de atributos florestais: uma revisão. **Revista Brasileira de Geografia Física**, v. 16, n. 01, 2023. Disponível em: https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1151658/1/Uso-do-LiDAR-na-Estimativa-de-Atributos-Florestais.2023.pdf. Acesso em: 23 Jun. 2024.

PAN, H. L.; HUANG, C. M.; HUANG, C. Y. Mapping aboveground carbon density of subtropical subalpine dwarf bamboo (Yushania niitakayamensis) vegetation using UAV-lidar. **International Journal of Applied Earth Observation and Geoinformation**, v. 123, p. 103487, 2023. Acesso em: 26 Jun. 2024.

PETEAN, F. C. de S. **Uso de imagens hiperespectrais e da tecnologia LiDAR na identificação de espécies florestais em ambiente urbano na cidade de Belo Horizonte, Minas Gerais**. Dissertação (Mestrado em Recursos Florestais) - Escola Superior de Agricultura Luiz de Queiroz – Universidade de São Paulo. 2015. Disponível em: http://www.teses.usp.br/teses/disponiveis/11/11150/tde-28102015-171744/. Acesso em: 23 jun. 2024.

PETERS, G.; BRINKMEYER, E.; BOLLIG, C. **LIDAR measuring device**. Depositante: METEK METEOROLOGISCHE MESSTECHNIK GmbH. Deposito: 15 Abr. 2021. Concessão: 21 Fev. 2023.

SILVA, C. A. **Carbono na parte aérea de plantios de Eucalyptus spp.-em nível de árvore por amostragem destrutiva e para talhões inteiros após o ajuste de métricas LiDAR**. 2013. Tese (Doutorado). Universidade de São Paulo.

SCHLEICH, A. et al. Improving GEDI footprint geolocation using a high resolution digital terrain model. **Authorea Preprints**, 2023. Disponível em: https://www.authorea.com/doi/full/10.36227/techrxiv.21915267.v1?commit=0bcf458b50fc46643abf35257cb455250082c0f2. Acesso em: 25 Jun. 2024.

SILVA, C. A. et al. Impacts of airborne LiDAR pulse density on estimating biomass stocks and changes in a selectively logged tropical forest. **Remote Sensing**, v. 9, n. 10, p. 1068, 2017. Disponível em: https://www.mdpi.com/2072-4292/9/10/1068/htm. Acesso em: 23 Jun. 2024.

SILVEIRA, P. Estimativa da biomassa e carbono acima do solo em um fragmento de floresta ombrófila densa utilizando o método da derivação do volume comercial. **Revista Floresta**. n. 4, p. 789–800, 2010.

STEPHENS, P. R. et al. Airborne scanning LiDAR in a double sampling forest carbon inventory. **Remote Sensing of Environment**, v. 117, p. 348–357, 2012.

SUIR, G. M. et al. Multi-Temporal Trend Analysis of Coastal Vegetation Using Metrics Derived from Hyperspectral and LiDAR Data. **Remote Sensing**, v. 15, n. 8, p. 2098, 2023. Disponível em: https://www.mdpi.com/2072-4292/15/8/2098/htm. Acesso em: 23 Jun. 2024.

TORRES, C. M. M. E. et al. Quantificação de biomassa e estocagem de carbono em uma floresta estacional semidecidual, no parque tecnológico de Viçosa, MG. **Revista Árvore**, v. 37, n. 4, p. 647–656, 2013. Disponível em: https://www.redalyc.org/articulo.oa?id=48828747008. Acesso em: 23 Jun. 2024.

TORRE-TOJAL, L. et al. Above-ground biomass estimation from LiDAR data using random forest algorithms. **Journal of Computational Science**, 1 Fev. 2022. Disponível em: https://www.sciencedirect.com/science/article/pii/S1877750321001800. Acesso em: 26 Jun. 2024.

WANG, J. et al. Sample plots forestry parameters verification and updating using airborne LiDAR data. **Remote Sensing**, v. 15, n. 12, 2023. Disponível em: https://www.researchgate.net/publication/371523710_Sample_Plots_Forestry_Parameters_Verification_and_Updating_Using_Airborne_LiDAR_Data. Acesso em: 23 Jun. 2024.

WALLACE, L. et al. Assessment of forest structure using two UAV techniques: A comparison of airborne laser scanning and structure from motion (SfM) point clouds. **Forests**, v. 7, n. 3, p. 62, 2016.

WANG, X.; GARD, W.; VAN DE KUILEN, J. W. G. Vertical forest engineering: applications of vertical forests with self-growing connections in high-rise buildings. In: ISCHP 2019: **7th International Scientific Conference on Hardwood Processing. Delft University of Technology**, 2019. p. 184-197.

YUN, Z. et al. Dynamic stratification for vertical forest structure using aerial laser scanning over multiple spatial scales. **International Journal of Applied Earth Observation and Geoinformation**, v. 114, p. 103040, 2022.

ZHANG, L. et al. Integrating Sentinel-1 and 2 with LiDAR data to estimate aboveground biomass of subtropical forests in northeast Guangdong, China. **International Journal of Digital Earth**, v. 16, n. 1, p. 158–182, 2023. Disponível em: https://www.tandfonline.com/doi/abs/10.1080/17538947.2023.2165180. Acesso em: 23 Jun. 2024.

ZHANG, Z.; CAO, L.; SHE, G. Estimating forest structural parameters using canopy metrics derived from airborne LiDAR data in subtropical forests. **Remote Sensing**, v. 9, n. 9, p. 940, 2017. Disponível em: https://www.mdpi.com/2072-4292/9/9/940/htm. Acesso em: 23 Jun. 2024.

ZHAO, Y. et al. Estimation of individual tree biomass in natural secondary forests based on ALS data and WorldView-3 Imagery. **Remote Sensing**, v. 14, n. 2, p. 271. 2022. Disponível em: https://www.mdpi.com/2072-4292/14/2/271/htm. Acesso em: 23 Jun. 2024.

ZIMBLE, D. A. et al. Characterizing vertical forest structure using small-footprint airborne LiDAR. **Remote Sensing of Environment**, v. 87, n. 2–3, p. 171–182, 2003. Acesso em: 29 Jun. 2024.

APÊNDICES

APÊNDICE A – Estoque de Biomassa Médio Acima do solo por Parcela

Parcela	Wt (t/parcela)	Fitofisionomia
1	22,2956	Médio
2	39,9823	Médio
3	22,1405	Médio
4	24,3852	Médio
5	58,1627	Avançado
6	144,9064	Avançado
7	78,0059	Avançado
8	23,5647	Médio
9	23,4330	Médio
10	16,1134	Médio
11	32,0830	Médio
12	36,1483	Médio
13	15,3061	Médio
14	21,0016	Médio
15	32,6279	Médio
16	37,3064	Médio
17	17,1909	Médio
18	18,2536	Médio
19	27,3937	Médio
20	21,6700	Médio
23	24,3947	Médio
24	17,0115	Médio
28	16,6026	Médio
31	13,4246	Médio
33	15,1650	Médio
34	12,9234	Inicial
35	15,4385	Médio
37	5,2798	Inicial
38	7,3606	Inicial
39	6,8242	Inicial
40	16,5549	Médio
43	7,9592	Inicial
52	12,8254	Médio
55	4,8511	Inicial
56	9,9043	Médio
58	21,1907	Médio
59	11,4169	Médio

60	20,1035	Médio
61	12,7219	Médio
62	46,4800	Médio
63	30,5920	Médio
64	12,1699	Médio
65	23,6534	Médio
66	8,6756	Médio
67	17,1163	Médio
68	13,5262	Médio
69	10,6592	Médio
70	23,0494	Médio
71	20,8204	Médio
72	13,0896	Médio
73	19,6500	Médio
74	12,1553	Médio
75	12,1553	Médio
76	18,5538	Médio
77	47,7768	Médio
78	8,0157	Inicial
79	10,0082	Inicial
80	6,6966	Inicial
81	14,0969	Médio
82	13,7811	Médio
83	6,3878	Médio
84	8,9565	Inicial
85	14,0393	Médio
86	15,7143	Médio
87	14,0963	Médio
88	11,8872	Médio
89	19,8103	Médio
90	7,3464	Médio
91	8,0471	Médio
92	3,4252	Inicial
93	2,1173	Inicial
94	4,3627	Médio
95	5,0518	Médio
96	2,0167	Inicial
97	7,6921	Médio
98	16,0662	Médio
99	25,5333	Médio
100	5,9133	Inicial

101	12,9823	Médio
102	16,1064	Médio
103	8,0137	Médio
122	26,1507	Médio
124	11,5100	Candeal
125	2,7690	Candeal
126	1,3291	Candeal
127	2,7574	Candeal
128	106,9810	Avançado
129	75,4940	Avançado
138	42,4226	Médio
161	25,4786	Médio
162	16,0794	Médio
165	14,0039	Médio
169	11,3269	Inicial
175	18,5293	Médio
176	24,7127	Médio
179	17,9725	Médio
180	21,7342	Médio
182	19,6292	Médio
185	32,9923	Médio
187	22,2987	Médio
188	50,4884	Avançado
189	24,5336	Médio
190	29,5292	Médio
192	17,2251	Médio
193	13,4099	Médio
194	6,8340	Inicial
198	20,5737	Médio
199	33,1437	Médio
200	21,0300	Médio
201	29,2758	Médio
203	24,8536	Médio
205	10,8308	Médio