

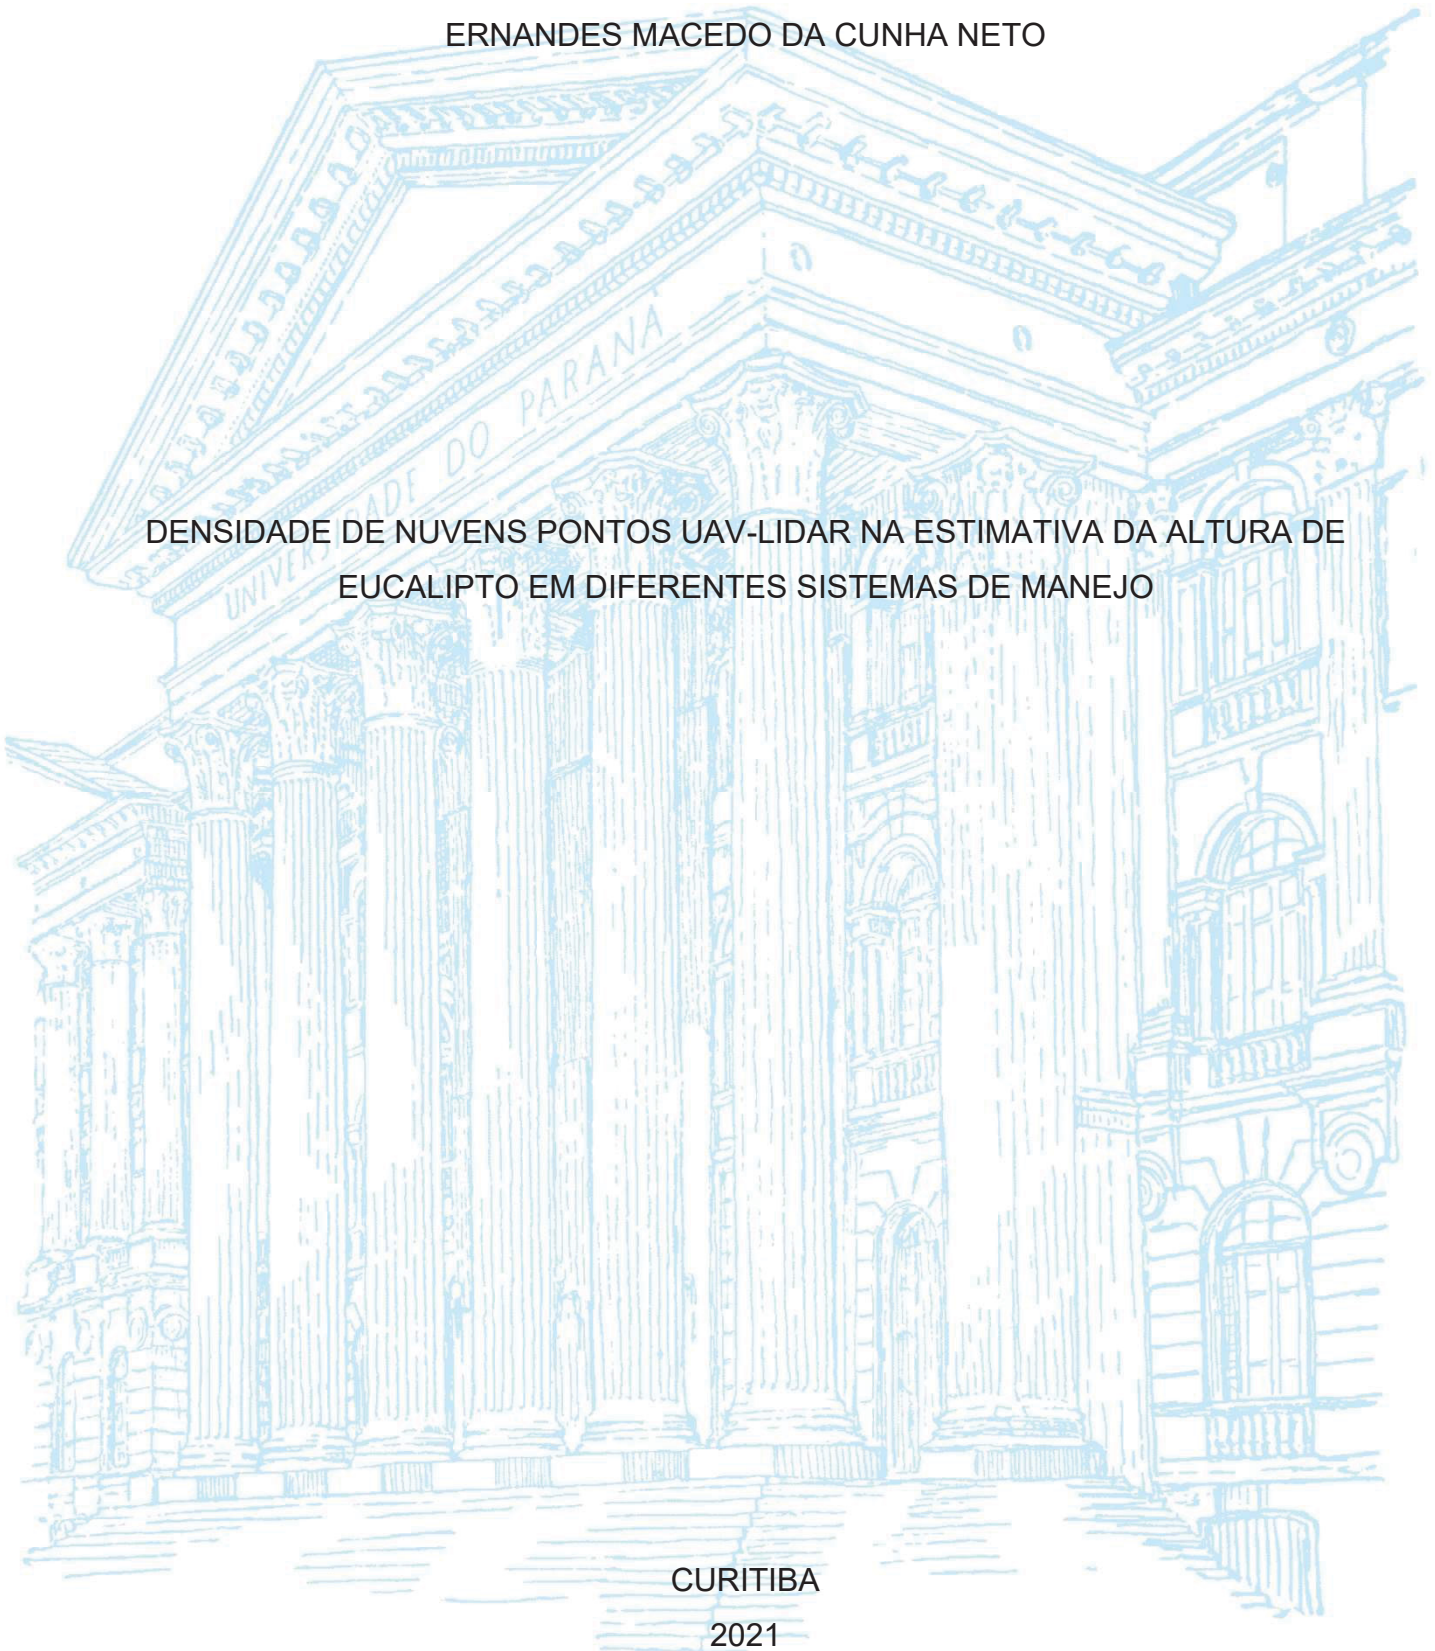
UNIVERSIDADE FEDERAL DO PARANÁ

ERNANDES MACEDO DA CUNHA NETO

DENSIDADE DE NUVENS PONTOS UAV-LIDAR NA ESTIMATIVA DA ALTURA DE
EUCALIPTO EM DIFERENTES SISTEMAS DE MANEJO

CURITIBA

2021



ERNANDES MACEDO DA CUNHA NETO

DENSIDADE DE NUVENS PONTOS UAV-LIDAR NA ESTIMATIVA DA ALTURA DE
EUCALIPTO EM DIFERENTES SISTEMAS DE MANEJO

Dissertação apresentada ao curso de Pós-Graduação em Engenharia Florestal, Setor de Ciências agrárias, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Mestre em Engenharia Florestal.

Orientador: Prof. Dr. Carlos Roberto Sanquetta

Coorientadora: Prof^a. Dr^a. Ana Paula Dalla Corte

CURITIBA

2021

Ficha catalográfica elaborada pela
Biblioteca de Ciências Florestais e da Madeira - UFPR

Cunha Neto, Ernandes Macedo da

Densidade de nuvens de pontos UAV-Lidar na estimativa da altura de eucalipto em diferentes sistemas de manejo / Ernandes Macedo da Cunha Neto. – Curitiba, 2021.

55 f. : il.

Orientador: Prof. Dr. Carlos Roberto Sanquetta
Coorientadora: Profa. Dra. Ana Paula Dalla Corte

Dissertação (Mestrado) - Universidade Federal do Paraná, Setor de Ciências Agrárias, Programa de Pós-Graduação em Engenharia Florestal. Defesa: Curitiba, 23/02/2021.

Área de concentração: Manejo Florestal.

1. Fotogrametria aérea. 2. Sensoriamento remoto. 3. Eucalipto.
4. Árvores – Medição. 5. Levantamentos florestais. 6. Lasers. 7. Teses.
I. Sanquetta, Carlos Roberto. II. Dalla Corte, Ana Paula.
III. Universidade Federal do Paraná, Setor de Ciências Agrárias. IV. Título.

CDD – 634.9

CDU – 634.0.58

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA FLORESTAL da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **ERNADES MACEDO DA CUNHA NETO** intitulada: **DENSIDADE DE NUVENS PONTOS UAV-LIDAR NA ESTIMATIVA DA ALTURA DE EUCALIPTO EM DIFERENTES SISTEMAS DE MANEJO**, sob orientação do Prof. Dr. CARLOS ROBERTO SANQUETTA, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa. A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 23 de Fevereiro de 2021.

Assinatura Eletrônica

24/02/2021 13:39:12.0

CARLOS ROBERTO SANQUETTA

Presidente da Banca Examinadora (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica

24/02/2021 14:00:15.0

CARINE KLAUBERG SILVA

Avaliador Externo (UNIVERSIDADE FEDERAL DE SÃO JOÃO DEL REI)

Assinatura Eletrônica

24/02/2021 13:05:16.0

VERALDO LIESENBERG

Avaliador Externo (UNIVERSIDADE DO ESTADO DE SANTA CATARINA)

AGRADECIMENTOS

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e ao Programa de Pós-graduação em Engenharia Florestal da Universidade Federal do Paraná (UFPR) pela bolsa de estudos e recursos necessários para o desenvolvimento deste trabalho.

Ao meu orientador, Professor Dr^o. Carlos Roberto Sanquetta pelas oportunidades, confiança e auxílio no decorrer deste mestrado, além de compartilhar seu conhecimento.

À minha coorientadora, Professora Dr^a. Ana Paula Dalla Corte pelas oportunidades e por favorecer o aperfeiçoamento deste trabalho.

Aos professores do Programa de Pós-graduação em Engenharia Florestal por compartilhar conhecimento, experiências e favorecer uma especialização na mensuração e manejo florestal, em especial ao professor Allan Pelissari que nos apresentou, ensinou e converteu a linguagem R.

Aos amigos e colegas de laboratório, pelas conversas, apoio, compartilhamento de conhecimento e sobretudo por serem parte da minha família fora de casa, em especial todos que auxiliaram nas coletas de campo: Manu, Marks, Tchê, Vinícius, Guilherme, André, Franciel e Letícia.

À minha família pelo dom da vida, suporte e apoio, em especial meus pais Ernandes Júnior e Cristina Macedo, minha irmã Cássia Macedo, bem como meus avós Ernandes e Elizete, Joaquim e Maria. Amo vocês.

À Tia Eliani que instigou a leitura e pensar por escrito, além de compreender melhor o mundo. Obrigado por dividir teu curso de redação por três anos e mostrar o caminho para evoluir profissionalmente sem evoluir como ser humano.

À Jade que juntos nos aventuramos por terras distantes para alcançar o título de mestres, nestes dois anos compartilhando cada momento desta jornada. Obrigado pelo companheirismo, apoio, confiança e bravura, sobretudo nos momentos de dificuldade.

*Preciso saber, se saber demais foi o melhor que eu fiz
Talvez nem saber de nada me faça bem mais feliz
Me diz, quando souber o que até hoje ainda não sei
Só levo aprendizado dos momentos que eu falhei. (Canção de 3030, 2016)*

RESUMO

O manejo florestal evoluiu para a fronteira 4.0, a qual utiliza tecnologias a seu favor, destas, destacam-se os *Lasers scanners*, os quais podem mensurar a floresta. Contudo, essa ferramenta é onerosa, de modo que uma alternativa mais barata e de alta densidade de pontos é a união destes sensores com veículos aéreos não tripulados (UAV-Lidar). Logo, deve-se verificar a influência da densidade de pontos na acurácia das métricas da floresta. Neste sentido, objetivou-se avaliar o desempenho de diferentes densidades de nuvens de pontos UAV-Lidar na estimativa da altura individual de *Eucalyptus benthamii* em sistemas agrosilvipastoris, implantados em 2012. O estudo foi conduzido na fazenda Canguiri, Pinhais, Paraná, na qual foi realizado o censo das árvores, medindo-se o diâmetro e altura. Os dados UAV-Lidar foram coletados com o sistema GatorEye. A nuvem de pontos foi pré-processada no LASTOOLS, onde foi unida e recortada para a área de estudo. Posteriormente, em linguagem de programação R, esta foi homogeneizada em nove diferentes densidades: 2.000, 1.500, 1.000, 500, 250, 100, 50, 25 e 5 pts/m². Estas nove nuvens de pontos foram classificadas quanto ao solo e normalizadas, favorecendo a determinação dos modelos digitais de terreno, superfície e copas. Foi extraído a altura máxima das árvores, com base no pixel mais alto presente no modelo digital de copas e na nuvem de pontos normalizada. As alturas derivadas foram avaliadas em relação as alturas medidas em campo pelo coeficiente de correlação de Pearson, raiz quadrada do erro médio, viés, análise gráfica e teste t pareado. A densidade de 2.000 pts/m² melhor representou o perfil da árvore e o solo, obtendo maior correlação (0,79) e menor RMSE (14,55 %). Em todas as densidades, as alturas derivadas e mensuradas foram estatisticamente semelhantes. A redução da densidade de pontos ocasionou divergências no perfil da árvore e modelo de copas, não havendo grandes diferenças no modelo digital do terreno. O sistema GatorEye foi acurado para derivar a altura total do *Eucalyptus benthamii*. Até 100 pts/m² não há perda de acurácia na derivação da altura.

Palavras-chave: GatorEye. *Eucalyptus*. Manejo Florestal. Sensoriamento Remoto.

ABSTRACT

The 4.0 frontier has arrived in the forest management, employing technologies in its benefit, among them, Lasers scanners, which measure the forest. However, this tool is expensive, so a cheaper and high point density alternative is the union of these sensors with unmanned aerial vehicles (UAV-Lidar). Therefore, the point density influence on the forest metrics' accuracy should be verified. We evaluate the performance of UAV-Lidar's different point cloud densities in the individual height of the *Eucalyptus benthamii* estimates on different Crop-Livestock-Forest systems, implemented in 2012. It was conducted at Canguiri Farm, Pinhais, Paraná, where the census of the trees was performed, measuring the diameter and height. The UAV-Lidar data were collected with the GatorEye system. The Point Cloud was pre-processing in the LASTOOLS software, where it was merged and clipped into the study area. Then in R programming language, it was thinned in nine densities: 2,000, 1,500, 1,000, 500, 250, 100, 50, 25 and 5 pts/m². The point clouds were classified in ground and normalized, improving the digital models of terrain, surface, and crown. The highest tree height was extracted, based on the highest pixel on the digital crown model and the normalized point cloud. Heights were evaluated by Pearson's correlation, root-square-mean error, bias, graphic analysis, and paired t-test. The processing was performed in R language. The tree's profile and the soil were better represented by 2,000 returns.m⁻², obtaining higher correlation (0.79) and lower RMSE (14.55 %). At all densities, the derived and measured heights were statistically similar. The point cloud density's reduction produced variances in tree profile and CHM, with few differences in DTM. The GatorEye system was accurate to derive the *Eucalyptus benthamii*'s total height. There is no accuracy decrease in the height's derivation until 100 returns.m⁻².

Keywords: GatorEye. *Eucalyptus*. Forest Management. Remote Sensing.

LISTA DE FIGURAS

Figura 1: Projeto NITA, localizado na fazenda experimental Canguiri, Pinhais, Paraná, Brasil.....	25
Figura 2: Fluxograma do processamento de dados UAV-Lidar no projeto NITA, Pinhais, Paraná, Brasil.....	27
Figura 3: Distribuição das alturas mensuradas no inventário florestal e derivadas da nuvem de pontos Lidar no projeto NITA, Pinhais, Paraná, Brasil.....	30
Figura 4: Representação tridimensional de um indivíduo de <i>E. benthamii</i> sob diferentes densidades de pontos no projeto NITA, Pinhais, Paraná, Brasil.....	31
Figura 5: Modelos digitais do terreno de cada densidade de pontos Lidar do projeto NITA, Pinhais, Paraná, Brasil.....	32
Figura 6: Aproximação dos modelos digitais do terreno de cada densidade de pontos Lidar do projeto NITA, Pinhais, Paraná, Brasil.....	33
Figura 7: Modelos digitais de copa para cada densidade de pontos Lidar do projeto NITA, Pinhais, Paraná, Brasil.....	34
Figure 8: Aproximação dos modelos digitais de copa para cada densidade de pontos Lidar do projeto NITA, Pinhais, Paraná, Brasil.....	35
Figura 9: Medidas estatísticas entre as alturas derivadas e medidas em campo por classe diamétrica no projeto NITA, Pinhais, Brasil. a representa a Raiz quadrada do erro médio e b representa o Viés.....	36
Figura 10: Dispersão dos resíduos de <i>E. benthamii</i> para cada densidade de pontos no projeto NITA, Pinhais, Paraná, Brasil.....	37
Figura 11: Dispersão da altura de <i>E. benthamii</i> para cada densidade de pontos no projeto NITA, Pinhais, Paraná, Brasil.....	37
Figura 12: Teste de Tukey para as densidades de pontos UAV-Lidar na derivação da altura de <i>E. benthamii</i> no projeto NITA, Pinhais, Paraná, Brasil.....	38

LISTA DE TABELAS

Tabela 1: Estatísticas descritivas das alturas individuais de <i>E. benthamii</i> no projeto NITA, Pinhais, Paraná, Brasil.....	29
Tabela 2: Quantidade de indivíduos identificados pelo UAV-Lidar para cada classe de altura no projeto NITA, Pinhais, Paraná, Brasil.....	30
Tabela 3: Métricas estatísticas para cada densidade de pontos da derivação de altura de <i>E. benthamii</i> do projeto NITA, Pinhais, Paraná, Brasil	35
Tabela 4: Inferência das alturas nos estoques volumétricos de <i>E. benthamii</i> no projeto NITA, Pinhais, Paraná, Brasil.....	39

LISTA DE ABREVIATURAS OU SIGLAS

3D – Tridimensional

ALS – *Airborne laser scanner*

CAP – Circunferência a 1,30 metros do solo

CHM - *Canopy Heigh Model*

CV – Coeficiente de variação

DAP - Diâmetro a 1,30 metros do solo

DP – Desvio padrão

DSM - *Digital Surface Model*

DTM - *Digital Terrain Model*

EP – Erro Padrão

GNSS – *Global Navigation Satellite System*

ha - hectares

IF – Inventário florestal

INS – *Inertial Navigation System*

Lidar - *Light Detection and Ranging*

m – metro

max - máximo

min - mínimo

n – número de árvores

pts/m² - Pontos/metro quadrado

SR – Sensoriamento remoto

TLS – *Terrestrial laser scanner*

UAV - *Unmanned aerial vehicle*

UAV-Lidar – Sensor Lidar aerotransportado em UAV

V – Volume (m³)

VANT – Veículo aéreo não tripulado

Vmi – Volume médio individual

SUMÁRIO

1 INTRODUÇÃO	13
1.1 JUSTIFICATIVA	15
1.2 OBJETIVOS	15
1.2.1 Objetivo geral	15
1.2.2 Objetivos específicos.....	15
2 REVISÃO DE LITERATURA	16
2.1 SISTEMAS AGROSILVIPASTORIS.....	16
2.2 MÉTODOS TRADICIONAIS DE ESTIMATIVA DE ALTURA DE ÁRVORES	17
2.3 SENSORIAMENTO REMOTO	18
2.4 LIDAR.....	19
2.5 LIDAR NA ENGENHARIA FLORESTAL	20
2.6 TIPOS DE PLATAFORMA PARA O SISTEMA LIDAR.....	21
2.6.1 <i>Airborne Laser Scanner</i> (ALS)	21
2.6.2 <i>Terrestrial laser scanners</i> (TLS).....	22
2.6.3 <i>UAV-Lidar</i>	22
2.6.4 Densidade de pontos.....	23
3 MATERIAL E MÉTODOS	25
3.1 ÁREA DE ESTUDO.....	25
3.2 AQUISIÇÃO DOS DADOS	26
3.2.1 Inventário florestal e UAV-Lidar.....	26
3.3 PROCESSAMENTO DOS DADOS	26
3.3.1 Estimativa da altura para cada densidade da nuvem de pontos	26
3.4 COMPARAÇÃO ENTRE AS ALTURAS DERIVADAS DA NUVEM E MENSURADAS EM CAMPO.....	27
4 RESULTADOS	29
5 DISCUSSÃO	39
6 CONCLUSÕES	43
7 RECOMENDAÇÕES	43
REFERÊNCIAS	44

1 INTRODUÇÃO

A demanda de madeira como fonte de matéria-prima tem exigido modificações nas formas tradicionais de manejo e inventário florestal, uma vez que há necessidade de adquirir informações precisas e com maior abrangência da floresta em um curto intervalo de tempo e com custos reduzidos (HAYASHI; WEISKITTEL; KERSHAW, 2016). Tal exigência permitiu a evolução do manejo florestal para a fronteira 4.0, a qual utiliza técnicas de internet das coisas (IoT, em inglês), *big data*, e sensores remotos como ferramentas que favorecem o incremento da produtividade operacional na aquisição de informações de toda a floresta (CORTE et al., 2020; CUNHA NETO et al., 2020; DOMB; BONCHEK-DOKOW; LESHEM, 2017; FAN et al., 2018; PARTHIBAN et al., 2019; SAIKUMAR; SRIRAMYA, 2019; YU et al., 2014; YUNJIE, 2019).

A resolução espacial dessas técnicas é um dos grandes diferenciais para o manejo e inventário florestal, pois permitem mensurar toda a floresta, enquanto as técnicas convencionais utilizam unidades amostrais para representar a floresta (HAYASHI; WEISKITTEL; KERSHAW, 2016). Dentre estas ferramentas, o sensoriamento remoto ativo, o tal como *Light Detection And Ranging* (Lidar), em especial o *Airborne laser scanning* (ALS) tem sido aplicado constantemente para mensurar grandes áreas florestais, de tal maneira que este sensor tem favorecido a mensuração de diversas métricas da floresta, bem como representação tridimensional, tanto a nível de árvore individual como para todo o povoamento (CAMPBELL et al., 2018; CORTE et al., 2020; KRAMER et al., 2016; KÜKENBRINK et al., 2017; KUKUNDA et al., 2018; REX et al., 2019; RUIZ et al., 2014; VASTARANTA et al., 2013; YOGA et al., 2017).

Apesar de sua versatilidade, o ALS ainda é uma tecnologia onerosa, o que limita a sua aplicação em grandes áreas e em inventários florestais contínuos, os quais possuem escala multitemporal (WALLACE et al., 2012). Dessa forma, uma alternativa menos onerosa seria o uso de veículos aéreos não tripulados (UAVs) com uma câmera fotográfica acoplada, favorecendo o monitoramento periódico da floresta (BIRDAL; AVDAN; TÜRK, 2017; DEMPEWOLF et al., 2017; MOHAN et al., 2017; NEVALAINEN et al., 2017; OTA et al., 2017; PANAGIOTIDIS; ABDOLLAHNEJAD; SUROVÝ, 2016; SUROVÝ; RIBEIRO; PANAGIOTIDIS, 2018; TORRES-SÁNCHEZ et al., 2015; ZARCO-TEJADA et al., 2014).

Contudo, o sistema UAVs + câmera fotográfica não proporcionam a mesma acurácia que o ALS, uma vez que os sensores passivos não captam com precisão informações do solo, bem como do interior da floresta, pois, diferente do Lidar, não penetram as estruturas vegetais para retornar informações (DANDOIS; ELLIS, 2013; OTA et al., 2015; SIMPSON; SMITH; WOOSTER, 2017; VASTARANTA et al., 2013; WHITE et al., 2013). Por este motivo, recentemente os sensores Lidar foram acoplados em UAVs, a fim de contornar essa problemática e reduzir os custos de aquisição dos dados (CORTE et al., 2020; RUIZ et al., 2014; SANKEY et al., 2017; WALLACE et al., 2012; WALLACE; LUCIEER; WATSON, 2014).

Diferentemente do sensor ALS, o UAV-Lidar proporciona uma alta densidade de pontos, o que permite informações mais detalhadas da árvore (CORTE et al., 2020; JAAKKOLA et al., 2010; LIN; HYYPPÄ; JAAKKOLA, 2011). No entanto, ainda não é conhecida a influência dessa alta densidade na derivação das métricas da floresta, de tal modo que existe a hipótese que altas densidades geram métricas mais acuradas (JAKUBOWSKI; GUO; KELLY, 2013).

Dessa forma, é imprescindível verificar a influência da densidade de pontos na acurácia das métricas da floresta, sobretudo para árvores individuais, a fim de conhecer os limites, no qual pode-se reduzir a densidade de pontos, sem perdas de acurácia, uma vez que a densidade de pontos tem ligação direta com os custos de aquisição dos dados, pois exigem maior sobreposição de faixas de voo, além de menor densidade e altitude, tornando a operação mais demorada, assim, a redução da densidade diminuiria o tempo de voo, conseqüentemente minimiza os custos operacionais para adquirir dados UAV-Lidar (GUO et al., 2017; SANKEY et al., 2017; WATT et al., 2014).

Alguns estudos, utilizaram ALS para averiguar a relação entre densidade de pontos e aquisição de variáveis dendrométricas em povoamentos florestais, contudo, grande parte desses estudos utilizaram baixas densidades: observaram que a densidade poderia ser reduzida de 1,13 para 0,25 pts/m² sem inferir na acurácia da altura de três espécies florestais, enquanto em uma floresta mista de coníferas, Jakubowski; Guo; Kelly (2013) reduziram a densidade de 9 para 1 pts/m², de tal modo que a acurácia altura das árvores, diâmetro e área basal não foram afetadas.

1.1 JUSTIFICATIVA

Como os sistemas ALS dificilmente atingem altas densidades (> 10 pts/m²), faz-se necessário avaliar a influência da densidade de pontos em sistemas UAV-lidar, os quais geralmente resultam em dados de densidade extremamente alta (> 800 pts/m²) (CORTE et al., 2020), a fim de reduzir os custos operacionais na aquisição de dados, bem como proporcionar acurácia nas mensurações da floresta, fomentando o desenvolvimento da fronteira 4.0 no manejo e inventário florestal. Neste contexto, a hipótese deste estudo é que existe uma densidade reduzida da nuvem de pontos UAV-Lidar que proporcione acurácia semelhante a máxima densidade da nuvem.

1.2 OBJETIVOS

1.2.1 Objetivo geral

Avaliar o desempenho de diferentes densidades de nuvens de pontos UAV-Lidar na estimativa da altura individual de *Eucalyptus benthamii* Maiden et Cambage em sistemas agrosilvipastoris.

1.2.2 Objetivos específicos

- Gerar as estimativas de alturas individuais para cada densidade de pontos;
- Verificar o desempenho das densidades da nuvem de pontos UAV-Lidar para derivar a altura total das árvores por classe de altura;
- Definir uma densidade ideal da nuvem de pontos UAV-Lidar que favoreça a estimativa precisa e acurada da altura dos indivíduos de *E. benthamii*.

2 REVISÃO DE LITERATURA

2.1 SISTEMAS AGROSILVIPASTORIS

A necessidade de produzir alimentos, energia, fibras, produtos madeireiros e não madeireiros em grande escala, bem como a intensificação de políticas de sustentáveis e de preservação ambiental trouxeram a necessidade de readaptar os modelos produtivos (monoculturas), a fim de maximizar a produtividade da área, possibilitando agregar multiprodutos e mitigar os impactos ambientais no sistema (BALBINO et al., 2019). Neste contexto, merece destaque os sistemas integrados de produção, os quais agregam na mesma área atividades agrícolas, pecuária e de silvicultura, em caráter temporal e/ou espacial, favorecendo efeito sinérgico entre as culturas, consequentemente a adequação ambiental e valoração do capital (BALBINO; BARCELLOS; STONE, 2011).

No Brasil, os primeiros registros desse sistema foi a partir da década de 90, a partir da revolução verde (CORREA; REICHARDT, 1995), se expandindo no Planaltos do Paraná, Rio Grande do Sul e Santa Catarina, devido principalmente as ao solo pouco propício a compactação, pois utilizavam o sistema de plantio direto (CONTE et al., 2011). Com o tempo, houve grande disseminação dos sistemas integrados de produção por todo o país, com enfoque principalmente na produção de fibra, energia, grãos, bovinos, ovinos, caprinos e florestas (BALBINO et al., 2019).

Vale ressaltar que os sistemas de produção, quando administrados corretamente são empreendimentos sustentáveis, pois consideram princípios para sua implantação, tais como: manejo e conservação do solo; manejo integrado de pragas, invasoras e doenças; respeito da capacidade da terra; redução da abertura de novas áreas; redução da emissão de gases estufa; sequestro de carbono; respeito a regularização das reservas legais e áreas de preservação permanente e certificação da produção (BALBINO et al., 2019). Além disso, os sistemas integrados proporcionam redução da erosão do solo; redução dos custos de produção; aumento da produtividade e bem-estar animal (BALBINO; BARCELLOS; STONE, 2011).

De maneira geral, existem quatro tipos de sistemas integrados de produção: Integração lavoura-pecuária (ILP), o qual integra o componente agrícola e pecuário em consórcio ou intercalados; Integração lavoura-floresta (ILF), que consiste na união de espécies florestais com culturas agrícolas; Integração pecuária-floresta (IPF), a qual mantém a floresta em conjunto com animais; e a Integração lavoura-pecuária-

floresta (ILPF), que é o sistema com componentes agrícolas, pecuário e de floresta, de tal maneira que o agrícola e o pecuário podem estar dispostos em consórcio, sucessão ou rotação (BALBINO; BARCELLOS; STONE, 2011).

2.2 MÉTODOS TRADICIONAIS DE ESTIMATIVA DE ALTURA DE ÁRVORES

A altura das árvores é uma variável que pode ser mensurada diretamente (abate do indivíduo), ou indiretamente, por meio de estimativas, de tal maneira que esta variável é imprescindível para o planejamento, bem como determinação do volume, biomassa, funções de afilamento e quantificação da capacidade produtiva do local (BINOTI; BINOTI; LEITE, 2013; DA SILVA et al., 2012a; MARTINS et al., 2016). Apesar da sua importância, essa variável é de difícil obtenção, uma vez que, geralmente, a aquisição direta da altura é inviável, ao passo que as estimativas indiretas estão sujeitos a erro, pois há dificuldades para visualização da base e topo da árvore (MACHADO; FIGUEIREDO FILHO, 2003).

Para a mensuração indireta dessa variável, existem instrumentos específicos, denominados hipsômetros, os quais podem ser baseados em princípios geométricos ou trigonométricos (BATISTA, 2001; CAMPOS; LEITE, 2006). Os aparelhos fundamentados no princípio geométrico mensuram a altura pela semelhança de triângulos, enquanto o trigonométrico usa os ângulos formados nas visadas da base e topo da árvore, bem como sua distância para o observador para determinar a altura (BATISTA, 2001).

Dentre os instrumentos baseados no método geométrico, destacam-se: prancheta dendrométrica; Hipsômetro de Weise e Hipsômetro de Christen, enquanto o princípio trigonométrico, por ser mais utilizado, possui mais representantes: nível de Abney; Hipsômetro Blume-Leiss; Hipsômetro de Haga; Hipsômetro de Suunto, além de outros aparelhos digitais (BATISTA, 2001; CAMPOS; LEITE, 2006). Além disso, em florestas homogêneas, é comum o emprego de modelos de regressão para estimar a altura das árvores, de modo que mede-se a altura de poucas árvores para ajustar o modelo hipsométrico, sendo que essa técnica possibilita a redução do esforço para obtenção da altura, com precisão moderada (CUNHA NETO et al., 2018; MACHADO; FIGUEIREDO FILHO, 2003; MENDONÇA et al., 2018; VENDRUSCOLO et al., 2015).

Com o advento das tecnologias, os hipsômetros florestais evoluíram, de tal maneira que hoje esses equipamentos são digitais e possuem maior acurácia na determinação da altura. Os principais equipamentos utilizados pelas empresas são: clinômetro digital ECII-R e Vertex IV, ambos da marca Hagöf® (GASPAROTO, 2017). Apesar disso, mensurar altura das árvores ainda é um desafio, uma vez que é um processo sujeito a erros (LARJAVAARA; MULLER-LANDAU, 2013; MUNROE; NAGENDRA; SOUTHWORTH, 2007; SOUTHWORTH; TUCKER, 2001; TEIXEIRA et al., 2009).

2.3 SENSORIAMENTO REMOTO

O sensoriamento remoto (SR) é a ciência que estuda a obtenção de informações de um determinado elemento, sem contato direto com o objeto, sendo esta aquisição por meio de câmeras, escâneres, lasers, dispositivos lineares e/ou matriciais localizados em plataformas como aeronaves, satélites ou Veículo aéreo não tripulado (VANT) (JENSEN, 2011; MOREIRA, 2011).

Esta ciência tem como base a relação entre a radiação eletromagnética (REM) e os objetos da superfície terrestre, tais como: solo, vegetação e água, que refletem, absorvem e transmitem a REM, de tal modo que os sensores remotos captam essa energia e possibilitam a identificação do objeto, a partir do comprimento de onda refletido, com base em suas características biofísicas-químicas (FLORENZANO, 2011). Contudo, com os avanços tecnológicos, surgiram os sensores que possuem a sua própria fonte de energia, logo, não dependem da luz solar para emitir REM (INMAN et al., 2007). Assim, no sensoriamento remoto, há dois tipos de sensores, os passivos que dependem da energia solar, e os ativos, que não dependem.

Vale ressaltar que a REM é a propagação da energia, através da propagação dos campos elétrico e magnético no tempo, sendo o sol a principal fonte natural da REM, sendo esta energia refletida ou absorvida e depois reemitida (SCHOWENGERDT, 2006). Esta ciência tem como base a relação entre a radiação eletromagnética (REM) e os objetos da superfície terrestre, tais como: solo, vegetação e água, que refletem, absorvem e transmitem a REM, de tal modo que os sensores remotos captam essa energia e possibilitam a identificação do objeto, a partir do

comprimento de onda refletido, com base em suas características biofísicas-químicas (FLORENZANO, 2011).

Os sensores passivos estão em atividade apenas enquanto há luz solar, enquanto os sensores ativos, podem operar tanto de dia como a noite, pois esse sistema direciona a energia que produz ao objeto e capta parte desta que voltou (MOREIRA, 2011). Os sensores de passivos, são representados pelos satélites e câmeras fotográficas. Os ativos se encontram os radares e os sistemas de escaneamento a laser. Embora ambos sejam sensores ativos, estes representam dois fundamentos de sensoriamento remoto distintos: os radares se baseiam na percepção de microondas, enquanto os lasers são sensores ópticos que atuam na porção visível do espectro eletromagnético (BAKKER et al., 2009).

2.4 LIDAR

O *Light Detection and Ranging* (Lidar) é um sensor ativo da categoria de laser escâner que emite pulsos laser e mensura o tempo que este pulso gasta para atingir o alvo e retornar ao sensor, de tal forma que este tempo pode ser convertido em medida de distância, o que possibilita aplicação destes sensores para produzir modelos digitais do terreno, de superfície e de copa das árvores (POPESCU, 2007; BAKKER et al., 2009).

Os pulsos emitidos pelo Lidar geram coordenadas tridimensionais (3D) de pontos do seu alvo, formando uma nuvem de pontos 3D (com coordenadas x, y e z), que possibilita visualizar com precisão a forma dos alvos do sensor (BAKKER et al., 2009; ZHAO; POPESCU; NELSON, 2009). Essa precisão se dá devido a integração do posicionamento global por satélite (GNSS – *Global Navigation Satellite System*) e o sistema inercial (INS – *Inertial Navigation System*), que juntos aloca o sensor e seus pulsos de forma precisa no espaço (MALTAMO; NAESSET; VAUHKONEN, 2014). De maneira geral, o Lidar possui precisão de 0,15 m em altimetria e 1 m em planimetria, de tal modo que a aquisição destes dados não é afetada pelas condições luminosas e climáticas (BALTSAVIAS, 1999a; RAZAK et al., 2011).

O primeiro registro de um sensor Lidar foi após a II Guerra Mundial, de tal maneira que este foi produzido para gerar modelos digitais de terreno (DTM) em áreas de difícil acesso (WAGNER et al., 2004; GIONGO et al., 2010; CARTER et al., 2012). Porém, como o Lidar coleta vários pontos do seu alvo, uma vez gerado o DTM, pode-

se obter os modelos digitais de superfície (DSM) e de altura dos alvos, possibilitando a sua mensuração e visualização tridimensional dos objetos-alvo (CHEN et al., 2013).

Diversas são as aplicações dos sensores Lidar, tais como: mapeamento de áreas suscetíveis a inundação, linhas de transmissão de energia, aquedutos, áreas de mineração, bem como áreas costeiras, desertos e florestas (BAKKER et al., 2009). Nas ciências florestais o Lidar demonstrou-se eficaz para caracterizar a estrutura da vegetação e do sub-bosque, uma vez que os pulsos laser interagem com as estruturas da árvore, que refletem de volta ao sensor e transforma as árvores em objetos tridimensionais (CLARK; CLARK; ROBERTS, 2004; CHASMER; HOPKINSON; TREITZ, 2006; ESTORNELL et al., 2011; KORPELA; HOVI; MORSDORF, 2012; ALEXANDER et al., 2013; KRAMER et al., 2016; CAMPBELL; DENNISON; BUTLER, 2017; HAMRAZ; CONTRERAS; ZHANG, 2017; KÜKENBRINK et al., 2017).

2.5 LIDAR NA ENGENHARIA FLORESTAL

Os primeiros relatos de aplicação de sensores Lidar nas ciências florestais, foi registrado por pesquisadores soviéticos, no ano de 1976, os quais passaram a observar as árvores não mais como ruídos aos DTMs e DSMs, mas sim como objeto de estudo (NELSON, 2013). Contudo, apenas em 1986, os pesquisadores Maclean e Krabill observaram o potencial dos lasers aerotransportados para estimar o volume de madeira no solo (MACLEAN; KRABILL, 1986).

Com o avanço dessa tecnologia, o uso de sensores Lidar está em evolução, de tal maneira que pode-se mensurar a floresta em nível de povoamento ou árvores individuais (NELSON, 2013). Em manejo de florestas tropicais, sistemas Lidar evidenciaram as trilhas de arraste, pequenas estradas, altura das árvores e clareiras no dossel (D'OLIVEIRA et al., 2012; HUNTER et al., 2015).

Em alguns países nórdicos e em florestais pouco acessíveis, tais como o Alasca e Canadá, o Lidar já substitui o inventário florestal, de tal maneira que a vegetação é efetivamente caracterizada, obtendo com acurácia a altura média e dominante, quantidade de árvores, área basal e volume (ANDERSEN; STRUNK; TEMESGEN, 2011; KAARTINEN et al., 2012; LEITOLD et al., 2015; SILVA et al., 2017a; WULDER et al., 2012).

Além dessas métricas, em estudos recentes, o Lidar foi eficaz para estimar o diâmetro à 1,30 do solo (DAP) das árvores (CORTE et al., 2020), biomassa acima do

solo (RAHMAN et al., 2017; REX et al., 2019; SILVA et al., 2017b; SILVA; VIERLING; KLAUBERG, 2016), identificação de copas (REX et al., 2018), detecção e contagem de árvores (KAARTINEN et al., 2012; LIU et al., 2013; PONT et al., 2015), favorecendo a acurácia e rapidez nas estimativas (DUNCANSON; ROURKE; DUBAYAH, 2015).

Apesar do custo de aquisição de dados Lidar, a acurácia obtida em nível de povoamento torna os custos de um sistema Lidar equiparável ao inventário florestal tradicional, favorecendo a aplicação desta técnica (HUDAK et al., 2009). Além disso, o desenvolvimento de sensores Lidar com menor dimensão, favoreceu a implementação do sistema em diversos tipos de plataformas, o que tornou o emprego dessa técnica mais acessível, de tal maneira que existem diversos tipos de sistemas associados com sensores Lidar (SANKEY et al., 2017; WATT et al., 2014).

2.6 TIPOS DE PLATAFORMA PARA O SISTEMA LIDAR

Historicamente há uma evolução dos sistemas Lidar, de tal modo que isto refletiu consideravelmente no peso e tamanho destes equipamentos. Em 2005, um sistema com Laser, GNSS e INS pesava cerca de 150 kg. Em 2008, há registros de sistemas semelhantes com 48 kg (BAKKER et al., 2009), enquanto hoje é possível acoplar um sistema Lidar completo em um UAV (CORTE et al., 2020; JAAKKOLA et al., 2010; SANKEY et al., 2017).

2.6.1 *Airborne Laser Scanner* (ALS)

Airborne Laser Scanner (ALS) são sistemas Lidar aerotransportados, geralmente em um helicóptero ou em avião, sendo que grande parte desses sistemas são utilizados em aviões de pequeno porte (BAKKER et al., 2009). Apesar de ser um sensor ativo, este sistema não penetra as nuvens, de tal maneira que o laser penetrará o dossel, porém, se o sub-bosque estiver denso, não terá uma boa visualização do solo (VOSELMAN; MAAS, 2010).

Apesar disso, o ALS demonstrou-se eficaz para gerar mapas topográficos com alta resolução espacial (pixel ≤ 1 m), possibilitando o mapeamento preciso e detalhado de grandes áreas com agilidade e qualidade (JAMES; WATSON; HANSEN, 2007; NOTEBAERT et al., 2009; PERROY et al., 2010; VOSELMAN; MAAS, 2010). Isso foi comprovado em diversos estudos, nos quais os DTMs provindos de ALS

obtiveram raiz quadrada do erro médio (RMSE) inferior a 0,5 m (BURNS et al., 2010; PERROY et al., 2010).

Assim, o sistema ALS possui como principais vantagens a precisão dos dados, rápida aquisição destes, possibilidade de varrer grandes áreas, penetração do dossel e redução dos trabalhos em campo (VOSSELMAN; MAAS, 2010). Para tanto, faz-se necessário definir alguns parâmetros, tais como: altura e velocidade de voo; planejamento de rotas, largura de faixa, sobreposição, frequência e energia dos pulsos, número de retornos, pontos de controle em campo com alta precisão, bem como densidade de pontos (SITHOLE; VOSSELMAN, 2004; GOODWIN; COOPS; CULVENOR, 2006; HERITAGE et al., 2009; MALLET; BRETAR, 2009; MENG et al., 2009; VOSSELMAN; MAAS, 2010; TINKHAM et al., 2012; GOULDEN et al., 2016).

Entretanto, para sistemas ALS, a densidade de pontos é considerada baixa, uma vez que dificilmente atinge mais de 30 pts/m². Geralmente a densidade de um sensor ALS está entre 2 e 10 pontos/m², de tal modo que a altura e velocidade de voo, bem como a sobreposição e o modelo do sensor são os principais limitantes para que o ALS atinja altas densidades de pontos (VOSSELMAN; MAAS, 2010; WANNASIRI et al., 2013; SILVA et al., 2017).

2.6.2 *Terrestrial laser scanners (TLS)*

Há locais e necessidades que inviabilizam o uso de ALS, sendo o Terrestrial laser scanners (TLS) uma alternativa para esses casos. Um fator limitante do TLS é o seu raio de varredura, com distância variável de 1 a 200 m, em contrapartida podem captar até 1000 pontos por segundo, com precisão de 2 a 6 mm (BAKKER et al., 2009).

Semelhante ao ALS, muitos TLS possuem uma câmera acoplada, as quais podem colorir as nuvens de pontos, facilitando a sua interpretação (SCHNEIDER; MAAS, 2007). Vale ressaltar que o TLS é mais preciso que o ALS, porém é restrito a pequenas áreas ou estudos que necessitam de alta precisão das informações, tais como encostas e riscos de desabamento (BREMER; SASS, 2012).

2.6.3 *UAV-Lidar*

Nos últimos anos o uso de veículos aéreos não tripulados (UAV) têm crescido, de tal maneira que essa ferramenta permitiu avanços significativos para o

sensoriamento remoto (ANDERSON; GASTON, 2013; VIVONI et al., 2014). Um dos destaques desta tecnologia é sua união com sensores remotos ativos, tal como o Lidar (SANKEY et al., 2017), favorecendo a mensuração de características da floresta (CORTE et al., 2020).

Em relação ao ALS, o UAV-Lidar pode reduzir os custos de aquisição dos dados, uma vez que o custo operacional e de aquisição desse sistema é menor (WATT et al., 2014). Inúmeros sistemas foram construídos e testados para derivar as métricas de inventário florestal: o primeiro sistema UAV-Lidar, provavelmente foi construído por Jaakkola et al. (2010), o qual produziu nuvens de pontos com densidade variando de 100 a 1500 pts/m². Wallace et al. (2012) obtiveram uma densidade média de 50 pts/m², com seu sistema em um voo de 5 minutos, conseguindo derivar a altura e volume das árvores Wallace; Musk; Lucieer (2014). Com o sistema Gator-Eye, Corte et al. (2020), alcançaram a densidade de 1400 pts/m², possibilitando a mensuração do diâmetro das árvores.

2.6.4 Densidade de pontos

A aquisição e processamento de dados Lidar está intimamente relacionada com a densidade de pontos, de tal maneira que é imprescindível conhecer o impacto da redução dessa densidade sobre a performance dos modelos digitais (Modelo digital de terreno-DTM e modelo digital de superfície-DSM) (ANDERSON; THOMPSON; AUSTIN, 2005; JAKUBOWSKI; GUO; KELLY, 2013; MANURI et al., 2017; YOGA et al., 2017). Vale ressaltar que o DTM descreve o terreno, mostrando seu relevo, enquanto o DSM representa a superfície alvo do mapeamento, de tal maneira que a subtração entre esses modelos resulta no modelo de alturas de copa (CHM), do qual são derivadas as métricas da floresta (ROSETTE et al., 2012). Dessa maneira, investigar a relação entre densidade de pontos e estes modelos, implica diretamente na influência da densidade de pontos na acurácia da derivação de variáveis dendrométricas.

Além disso, a densidade de pontos implica nos custos de aquisição dos dados Lidar, uma vez que maiores densidades exigem maior sobreposição entre linhas de voo, bem como menor velocidade e altitude, o que afeta o tempo de voo (BALTSAVIAS, 1999b; JAKUBOWSKI; GUO; KELLY, 2013; LOVELL et al., 2005; WATT et al., 2014). Assim, é imprescindível conhecer o limiar, pelo qual pode-se

reduzir a densidade de pontos, sem comprometer a acurácia das derivações de variáveis dendrométricas (WATT et al., 2014).

Há uma especulação entre os pesquisadores, que a maior densidade de pontos, melhorará a acurácia das variáveis de interesse (JAKUBOWSKI; GUO; KELLY, 2013). Porém, estudos com baixas densidades da nuvem de pontos (< 10 pts/m²) se demonstraram eficazes para derivar biomassa (REX et al., 2019), altura (GOBAKKEN; NÆSSET, 2008; JAKUBOWSKI; GUO; KELLY, 2013), volume (HYYPPÄ et al., 2001) e área basal (HUNTER et al., 2015).

3 MATERIAL E MÉTODOS

3.1 ÁREA DE ESTUDO

O estudo foi conduzido no projeto Núcleo de Inovação Tecnológica em Agropecuária (NITA), localizado na estação experimental Canguiri, município de Pinhais, Paraná, com coordenada central 25°23'30" S e 49°07'30" W. O município é caracterizado por clima do tipo subtropical úmido-Cfb, segundo classificação de Köppen, com precipitação média anual de 1550 mm, temperatura média de 17°C e altitude de 935 m (ALVARES et al., 2013). Os solos predominantes na região são: Cambissolos, Latossolos, bem como Organossolos e Gleissolos (SANTOS et al., 2018). O NITA compreende 35 ha, contudo, neste estudo foram utilizados como objeto apenas 15,79 ha, nos quais estão inseridos três sistemas de manejo, contendo o componente florestal: Pecuária-Floresta (PF), Lavoura-Floresta (LF), e Lavoura-Pecuária-Floresta (LPF) (Figura 1).

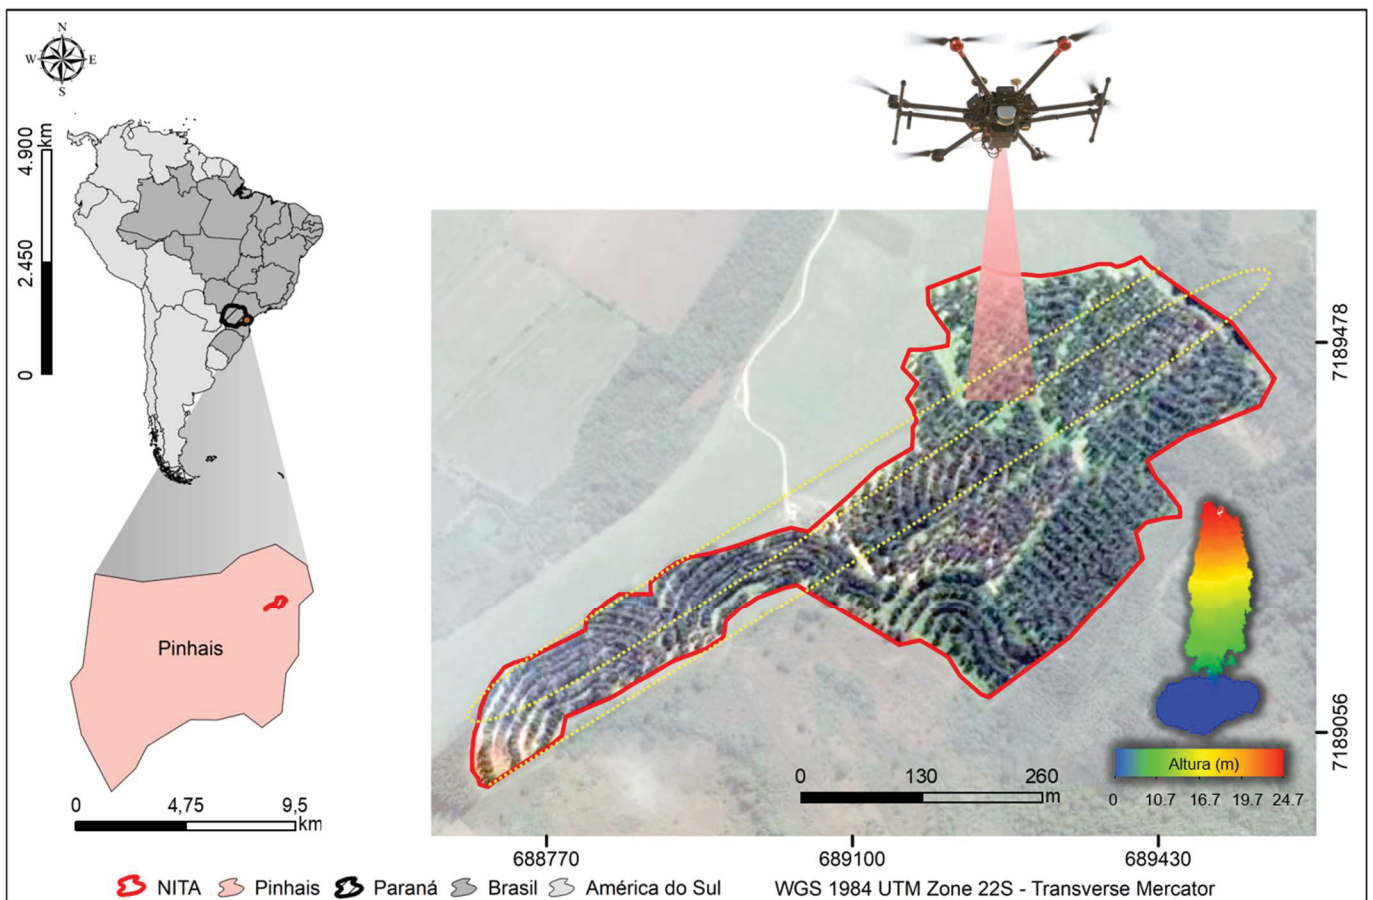


Figura 1: Projeto NITA, localizado na fazenda experimental Canguiri, Pinhais, Paraná, Brasil.

Nesses sistemas três sistemas, o componente florestal compreende a espécie *Eucalyptus benthamii* Maiden et Cambage, os quais foram plantados em curva de nível no ano de 2012, com arranjo de linhas simples, com espaçamento inicial de 14 m entre linhas e 2 m entre plantas (357 indivíduos.ha⁻¹) (MORAES et al., 2018). Vale ressaltar que o povoamento foi desbastado.

3.2 AQUISIÇÃO DOS DADOS

3.2.1 Inventário florestal e UAV-Lidar

Foi realizado o inventário censitário da área, pelo qual todas 1.869 árvores foram mensuradas quanto a circunferência a 1,30 metros do solo (CAP) e altura total. O CAP foi mensurado com fita centimétrica, enquanto para altura utilizou-se o hipsômetro Haglöf Vertex IV[®], a distância de 20 m da árvore. Além disso, a posição geográfica das árvores foi coletada com o GPS Garmin 62CSX.

Os dados UAV-Lidar foram coletados em setembro de 2019, com o sistema GatorEye. Tal sistema consiste em um UAV DJI M600 pro, sensor Lidar Velodyne 32c Ultra Puck, sistema inercial STIM300, Receptor L1/L2 e um SSD. O sensor Lidar possui 32 *lasers*, com alcance de até 220 m (CORTE et al., 2020; WILKINSON et al., 2019). O voo foi realizado a velocidade de 8 m.s⁻¹, com distância de 15 m entre as linhas (90% de sobreposição) e altura de 45 m, o qual gerou 120,66 milhões de pontos, com densidade máxima de 2.000 pts/m².

3.3 PROCESSAMENTO DOS DADOS

O pré-processamento da nuvem de pontos foi realizado no *software* LASTOOLS, onde a nuvem foi unida e recortada para área de estudo, com auxílio das funções LASMERGE e LASCLIP (ISENBURG, 2019). Posteriormente, os dados foram processados em linguagem R (R CORE TEAM, 2019), com auxílio dos pacotes lidR (ROUSSEL; AUTY, 2019) e rLiDAR (SILVA et al., 2017c).

3.3.1 Estimativa da altura para cada densidade da nuvem de pontos

A nuvem de pontos foi homogeneizada aleatoriamente em nove diferentes densidades: 2.000, 1.500, 1.000, 500, 250, 100, 50, 25 e 5 pts/m², para tanto, utilizou-

se a função *lasfilterdecimate*. Os pontos destas nove nuvens foram classificados e separados quanto ao relevo e superfície, a fim de gerar o DTM e normalizar a nuvem. Posteriormente foi gerado o DSM e CHM, no qual foi aplicado um filtro de suavização do tipo gaussiano, com sigma 0,5. Após esse processo foi extraído a altura máxima das árvores, com base no pixel mais alto presente no CHM e na nuvem normalizada, favorecendo também a contagem dos indivíduos. Vale ressaltar que as etapas de processamento e suas respectivas funções estão descritas na Figura 2.




Figura 2: Fluxograma do processamento de dados UAV-Lidar no projeto NITA, Pinhais, Paraná, Brasil.

3.4 COMPARAÇÃO ENTRE AS ALTURAS DERIVADAS DA NUVEM E MENSURADAS EM CAMPO

A precisão e acurácia entre as alturas derivadas pelo UAV-Lidar e mensuradas no campo foram avaliadas com base nas métricas estatísticas: coeficiente de correlação de Pearson (r), raiz quadrada do erro médio (RMSE), viés, análise gráfica e teste t pareado. O teste t foi aplicado para testar as seguintes hipóteses: H_0 = as alturas derivadas pelo sistema UAV-Lidar são estatisticamente semelhantes as alturas mensuradas no campo, H_1 = as alturas derivadas pelo sistema UAV-Lidar são estatisticamente diferentes as alturas mensuradas no campo. Para

avaliação do desempenho das alturas derivadas da nuvem de pontos por classe de altura, aplicou-se as métricas: viés e RMSE.

O teste de Tukey ao nível de 5% de significância foi aplicado para verificar se há diferenças entre as alturas derivadas nas diferentes densidades de pontos, possibilitando a definição de uma densidade ideal. Além disso, para verificar a influência das alturas derivadas das nuvens de pontos, estas foram inseridas na fórmula de volume individual das árvores, possibilitando verificar a inferência dessa variável no estoque volumétrico da floresta. Para tanto, utilizou-se fator de forma de 0,45.

4 RESULTADOS

A altura mínima mensurada no inventário florestal foi de 11,10 m, enquanto a máxima foi 26,20 m. As alturas derivadas pelo Lidar apresentaram valores semelhantes ao inventário florestal (Tabela 1). Os desvios padrões (DP) das alturas derivadas variaram entre 3,66 e 4,45, com erro padrão (EP) entre 0,088 e 0,017. O maior coeficiente de variação (CV) foi evidenciado para a densidade de 25 pts/m², enquanto 2.000 e 1.500 pts/m² obtiveram CV semelhante ao Campo (Tabela 1).

Tabela 1: Estatísticas descritivas das alturas individuais de *E. benthamii* no projeto NITA, Pinhais, Paraná, Brasil.

Cenários	Altura (m)			Estatísticas		
	Min	$\bar{X} \pm DP$	Max	EP	CV (%)	
Campo	11,10	19,92 ± 2,65	26,20	0,0630	17,75	
Densidade da nuvem de pontos (pts/m ²)	2.000	11,76	21,39 ± 3,66	28,06	0,1048	17,47
	1.500	11,76	21,62 ± 3,82	27,97	0,1047	17,67
	1.000	11,35	21,64 ± 3,99	28,30	0,1044	18,43
	500	11,18	21,65 ± 4,02	28,30	0,1041	18,54
	250	11,25	21,55 ± 4,15	28,38	0,1044	19,26
	100	11,10	21,44 ± 4,17	28,44	0,1041	19,44
	50	10,95	21,12 ± 4,40	28,38	0,1077	20,85
	25	10,91	20,90 ± 4,45	28,30	0,1088	21,30
5	11,23	20,12 ± 4,16	27,92	0,0886	20,65	

Min é a altura mínima, \bar{X} é a altura média, Max é a altura máxima, DP é o desvio padrão, EP é o erro padrão, CV é o coeficiente de variação.

De maneira geral, todas as densidades subestimaram alturas nas classes com centro de classe 17,5 m e 22,5 m, enquanto superestimaram as classes 7,5 m, 12,5 m e 27,5 m, com exceção apenas para 2.000 pts/m², a qual subestimou a frequência dos indivíduos na classe 7,5 m (Figura 3).




Figura 3: Distribuição das alturas mensuradas no inventário florestal e derivadas da nuvem de pontos Lidar no projeto NITA, Pinhais, Paraná, Brasil.

A densidade com menor erro na quantidade total de indivíduos foi a de 25 pts/m², seguida por 1.000 pts/m², contudo, existe superestimativas nas classes 7,5 m e 27,5 m, bem como subestimativas nas classes 12,5 m, 17,5 m e 22,5 m (Tabela 2). De maneira geral, o UAV-Lidar conseguiu identificar mais de 90% dos indivíduos de *E. benthamii*.

Tabela 2: Quantidade de indivíduos identificados pelo UAV-Lidar para cada classe de altura no projeto NITA, Pinhais, Paraná, Brasil.

Centro da classe de altura (m)	Campo	Frequências								
		Densidade de pontos (pts/m ²)								
		2.000	1.500	1.000	500	250	100	50	25	5
7,5	13	4	18	20	20	20	23	21	32	60
12,5	87	208	206	214	207	211	225	248	281	438
17,5	788	395	401	404	391	386	400	392	394	646
22,5	974	623	632	642	642	670	691	703	708	1004
27,5	7	468	478	475	452	428	405	381	342	231
Total	1869	1698	1735	1755	1712	1715	1744	1745	1757	2379

Centro da classe de altura (m)	Frequências									
	Campo	Densidade de pontos (pts/m ²)								
		2.000	1.500	1.000	500	250	100	50	25	5
Diferença (%)	9,15	7,17	6,10	8,40	8,24	6,69	6,63	5,99	-27,29	

Verificou-se que 2.000 pts/m² representou detalhadamente a forma da árvore e o relevo, de modo que ao reduzir a densidade de pontos, perde-se informação do formato do fuste, copa e altura da árvore, bem como retornos que favorecem a representação do relevo (Figura 4).

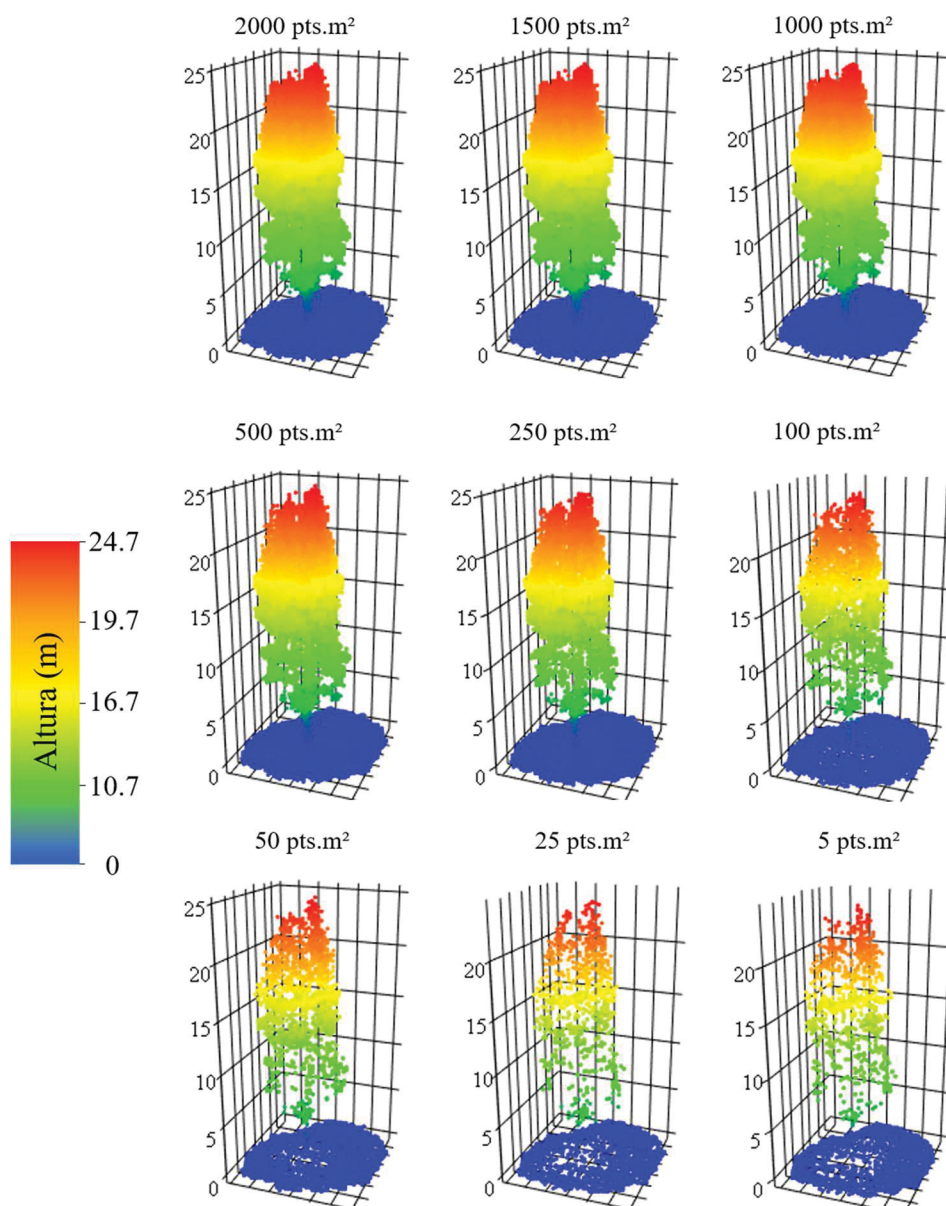


Figura 4: Representação tridimensional de um indivíduo de *E. benthamii* sob diferentes densidades de pontos no projeto NITA, Pinhais, Paraná, Brasil.

Além da representação da árvore, a densidade de pontos ocasionou poucas diferenças no modelo digital de terreno (Figura 5), havendo discrepâncias de até 0.06% entre a elevação da maior densidade (2.000 pts/m²) e as demais. Entre 2.000 e 1.500 pts/m² as diferenças se mantêm próximas a 0%, enquanto 1.000, 500, 250 e 100 pts/m² próximas a 0,003% (Figura 6), as quais estão localizadas a sudoeste da área de estudo. Para 50, 25 e 5 pts/m² as diferenças estão a cerca de -0,007%, localizadas no sudoeste do projeto.

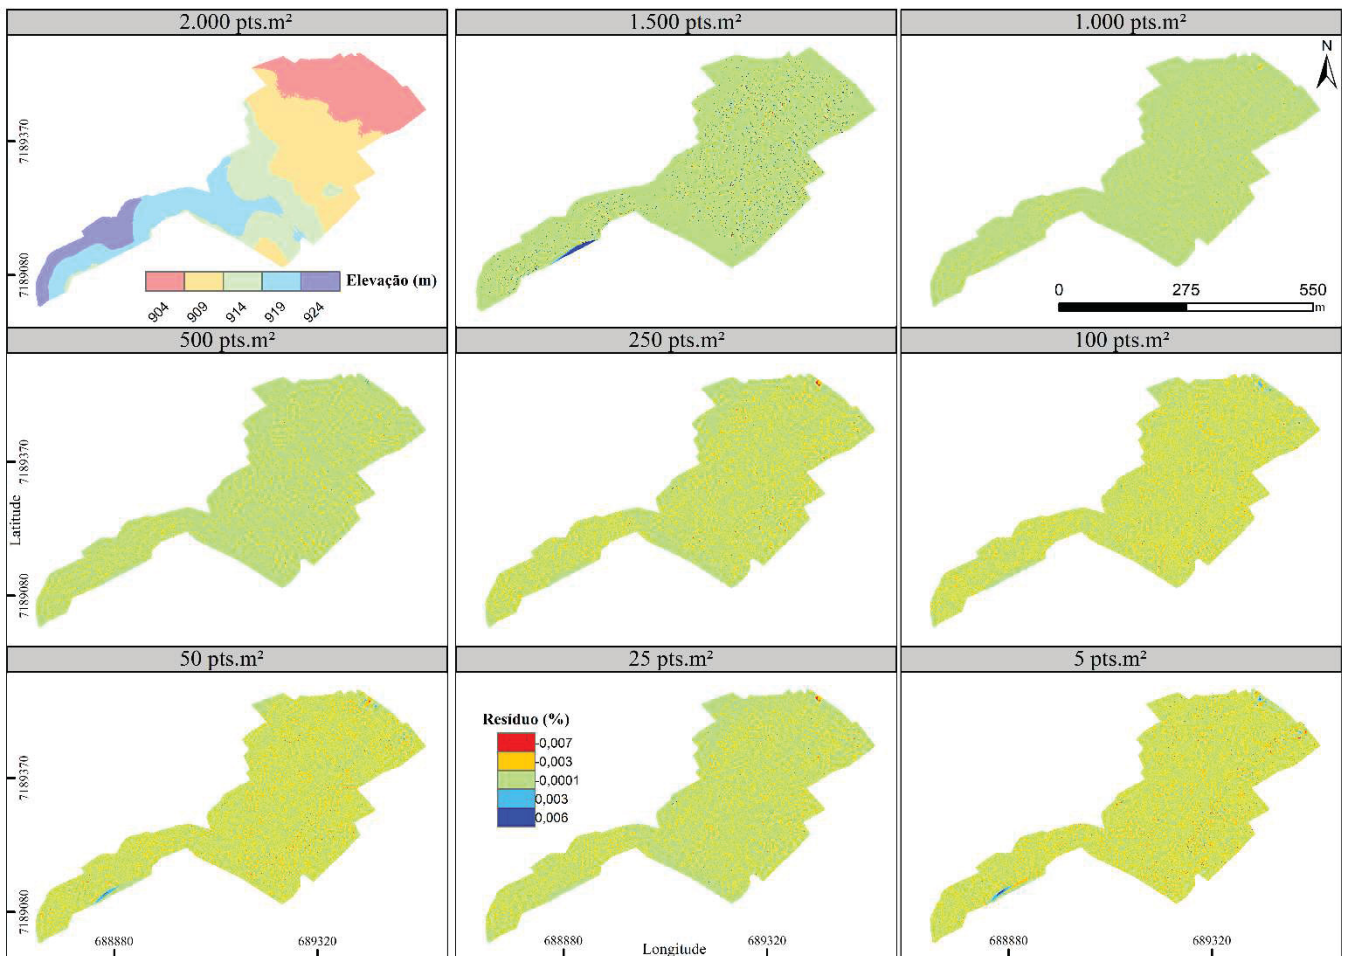


Figura 5: Modelos digitais do terreno de cada densidade de pontos Lidar do projeto NITA, Pinhais, Paraná, Brasil.

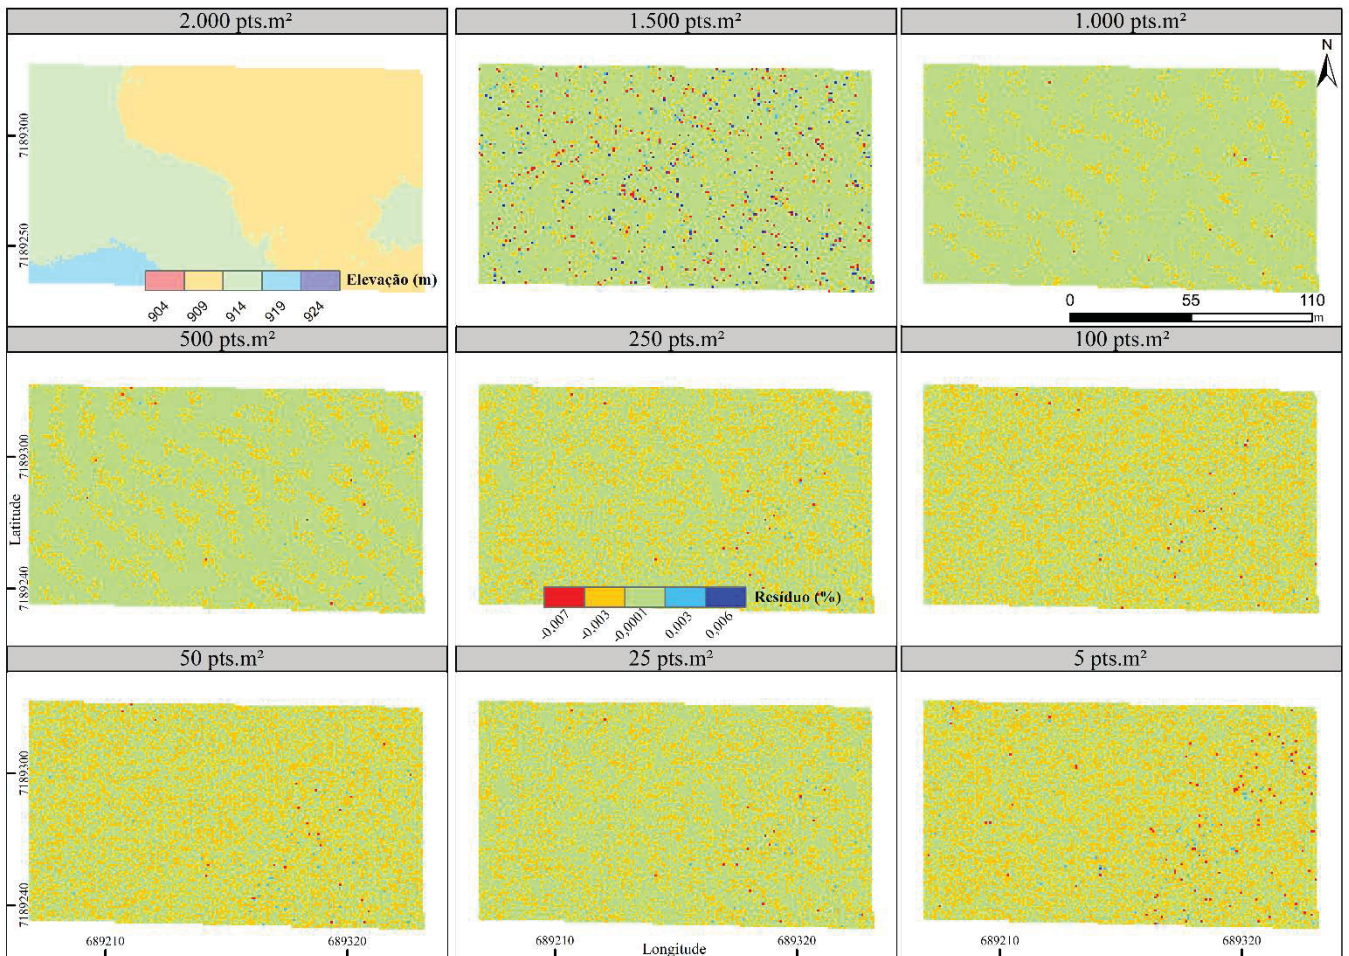


Figura 6: Aproximação dos modelos digitais do terreno de cada densidade de pontos Lidar do projeto NITA, Pinhais, Paraná, Brasil

No modelo digital de copas, a densidade de 2.000 pts/m² evidenciou alturas até 30 m (Figura 7), de tal maneira que até 25 pts/m² há predomínio de erros próximos na classe -11,9%, havendo alguns pixels com maior diferença distribuídos ao longo da área, enquanto 5 pts/m² evidenciou diferenças predominantes de -52,2% em relação à densidade de 2.000 pts/m² (Figura 8).

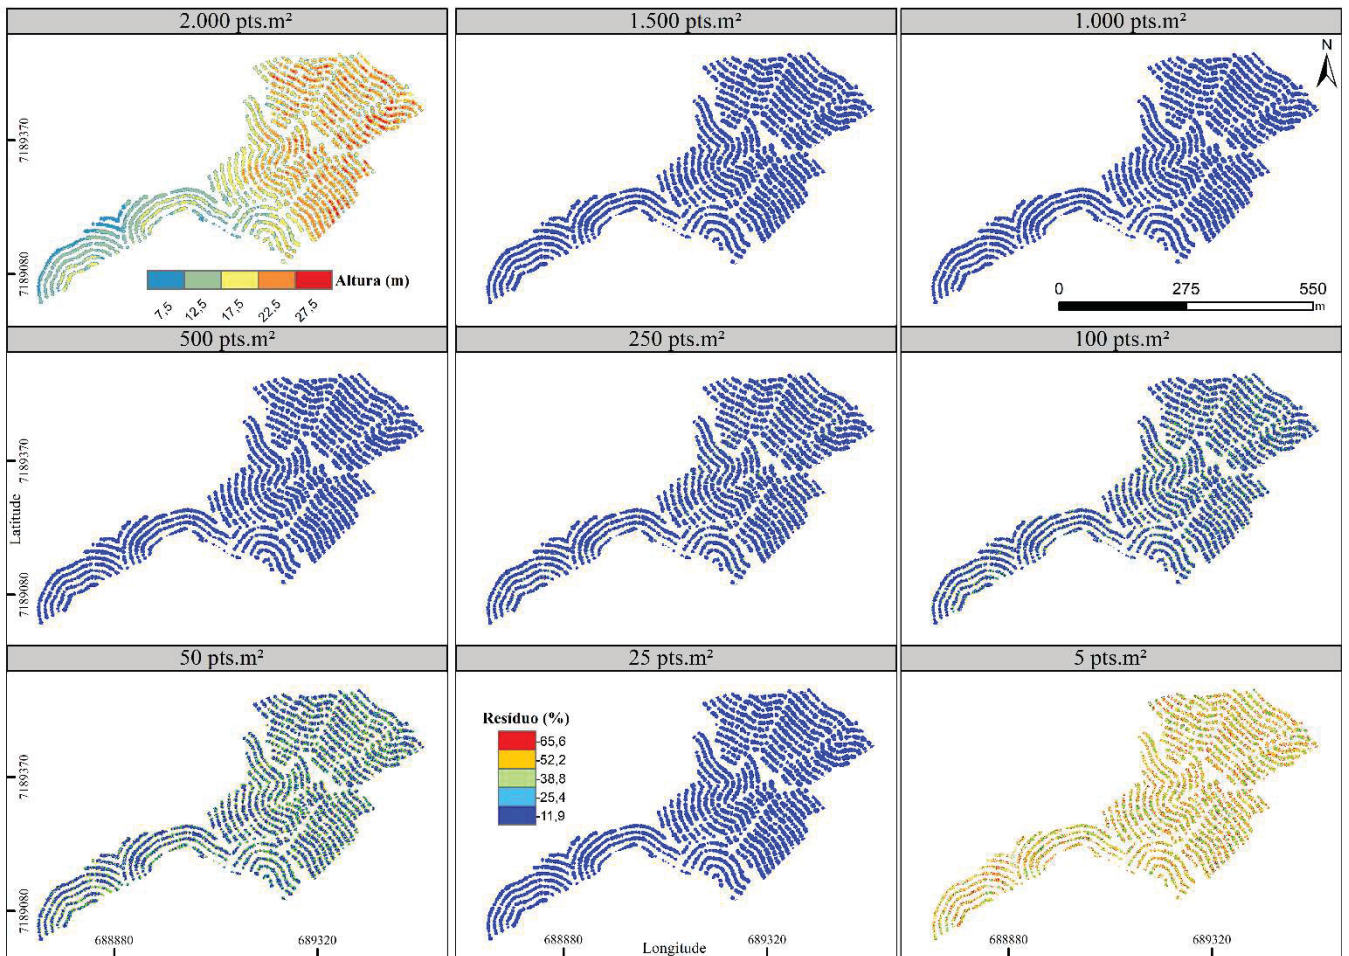


Figura 7: Modelos digitais de copa para cada densidade de pontos Lidar do projeto NITA, Pinhais, Paraná, Brasil

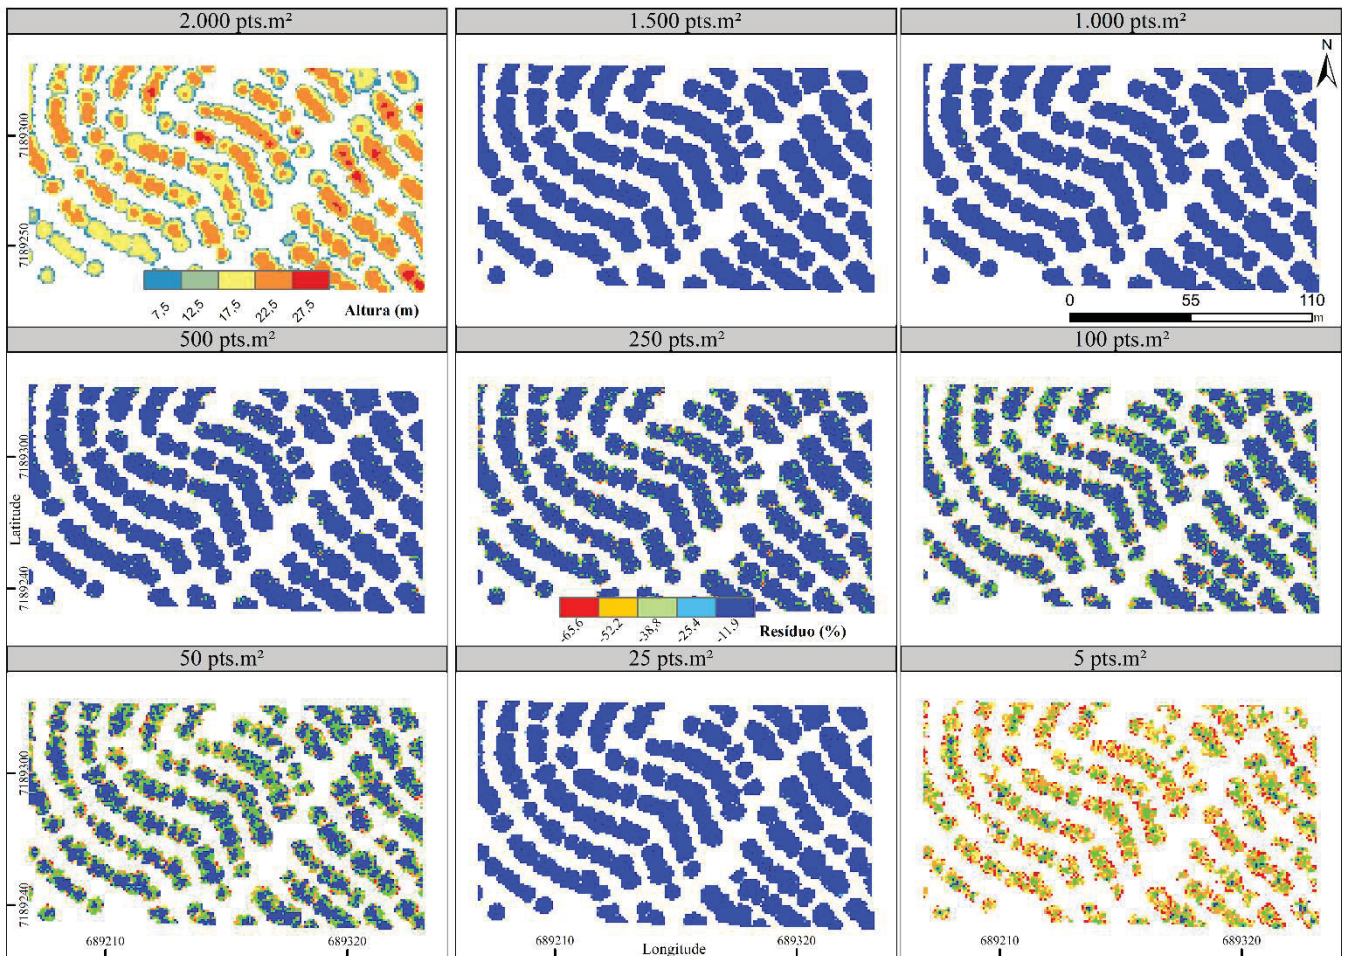


Figure 8: Aproximação dos modelos digitais de copa para cada densidade de pontos Lidar do projeto NITA, Pinhais, Paraná, Brasil

A maior correlação entre as alturas mensuradas no IF e derivadas pelo UAV-Lidar foi evidenciada para a densidade de 2.000 pts/m², de tal maneira que quanto menor a densidade, menor a correlação. O menor RMSE foi de 14,55% para a densidade de 2.000 pts/m², com a redução da densidade houve aumento do RMSE. Todas as densidades tenderam a superestimar as alturas. Apesar disso, em todas as densidades, as alturas derivadas e mensuradas foram estatisticamente semelhantes (Tabela 3).

Tabela 3: Métricas estatísticas para cada densidade de pontos da derivação de altura de *E. benthamii* do projeto NITA, Pinhais, Paraná, Brasil

Densidade (pts/m ²)	<i>r</i>	RMSE (m)	RMSE (%)	Viés (m)	Viés (%)	<i>t</i> (<i>p</i> - value)
2.000	0,792	2,904	14,547	-1,675	-8,389	0,839 ^{ns}
1.500	0,787	2,922	14,660	-1,681	-8,433	0,874 ^{ns}
1.000	0,757	3,141	15,763	-1,713	-8,598	0,891 ^{ns}
500	0,736	3,241	16,270	-1,737	-8,720	0,849 ^{ns}

Densidade (pts/m ²)	<i>r</i>	RMSE (m)	RMSE (%)	Viés (m)	Viés (%)	<i>t</i> (<i>p</i> – value)
250	0,690	3,440	17,315	-1,673	-8,418	0,846 ^{ns}
100	0,690	3,405	17,129	-1,568	-7,889	0,869 ^{ns}
50	0,617	3,693	18,609	-1,277	-6,433	0,868 ^{ns}
25	0,598	3,726	18,791	-1,073	-5,412	0,878 ^{ns}
10	0,578	3,724	18,811	-0,484	-2,447	0,297 ^{ns}
5	0,579	3,426	17,314	-0,334	-1,688	0,839 ^{ns}

r é o coeficiente de correlação de Pearson, RMSE é a raiz quadrada do erro médio, ns é não significativo pelo teste t ao nível de 5% de significância.

De maneira geral, todas as densidades obtiveram maiores RMSE e Viés para as classes de altura 7,5 m e 27,5 m, enquanto nas classes centrais essas medidas estatísticas apresentaram valores moderados. As maiores densidades (2.000 pts/m², 1.500 pts/m² e 1.000 pts/m²) obtiveram menores valores para as métricas RMSE e Viés nas classes de altura (Figura 9).

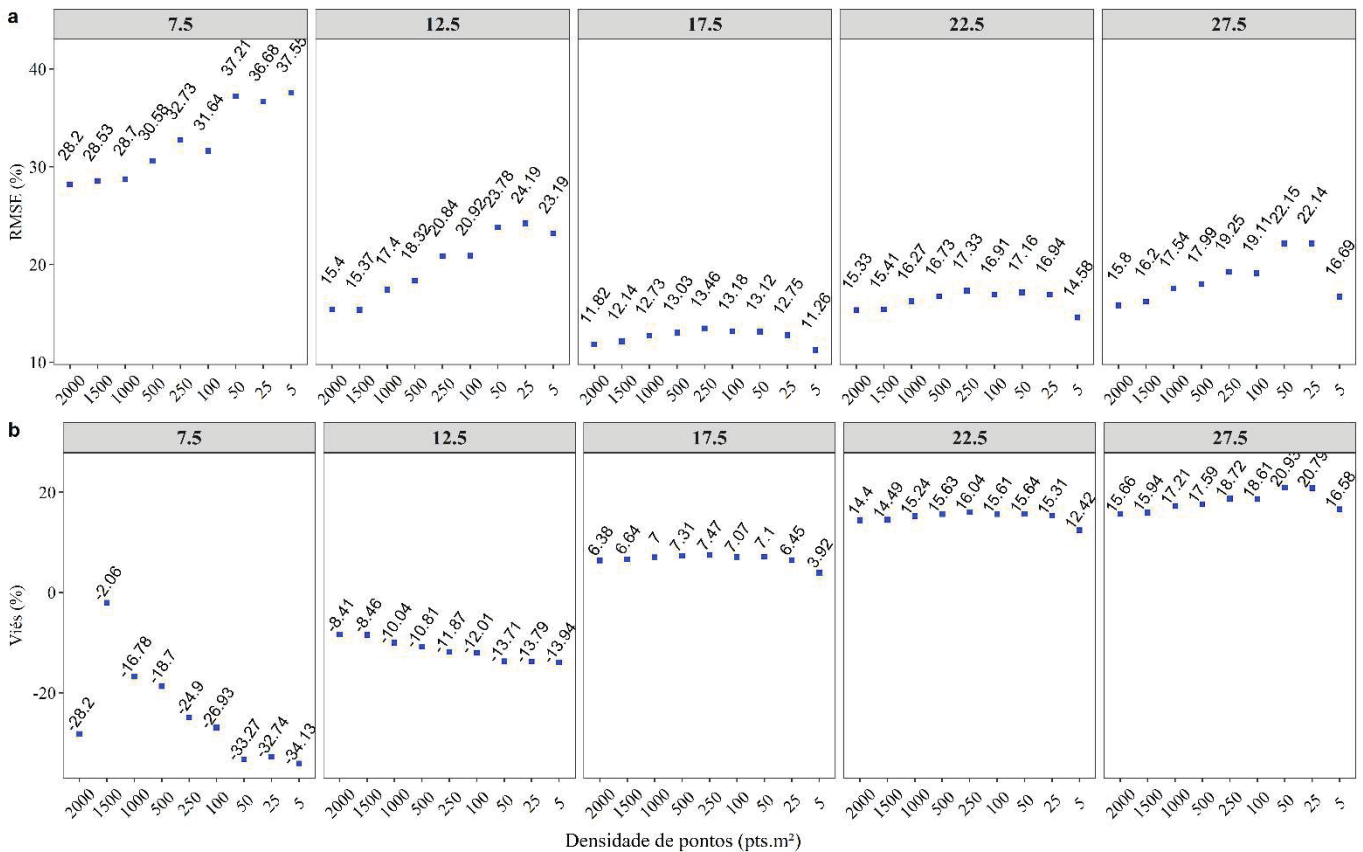


Figura 9: Medidas estatísticas entre as alturas derivadas e medidas em campo por classe diamétrica no projeto NITA, Pinhais, Brasil. a representa a Raiz quadrada do erro médio e b representa o Viés.

De maneira geral, os resíduos apresentaram dispersão homocedástica, se concentrando entre -3 e 3 desvios (Figura 10). Contudo, para as menores densidades

(50, 25 e 5 pts/m²) há tendências nas estimativas. A dispersão das alturas denota a acurácia das densidades 2.000, 1.500 e 1.000 pts/m², bem como estimativas tendenciosas para as densidades 50, 25 e 5 pts/m² (Figura 11).

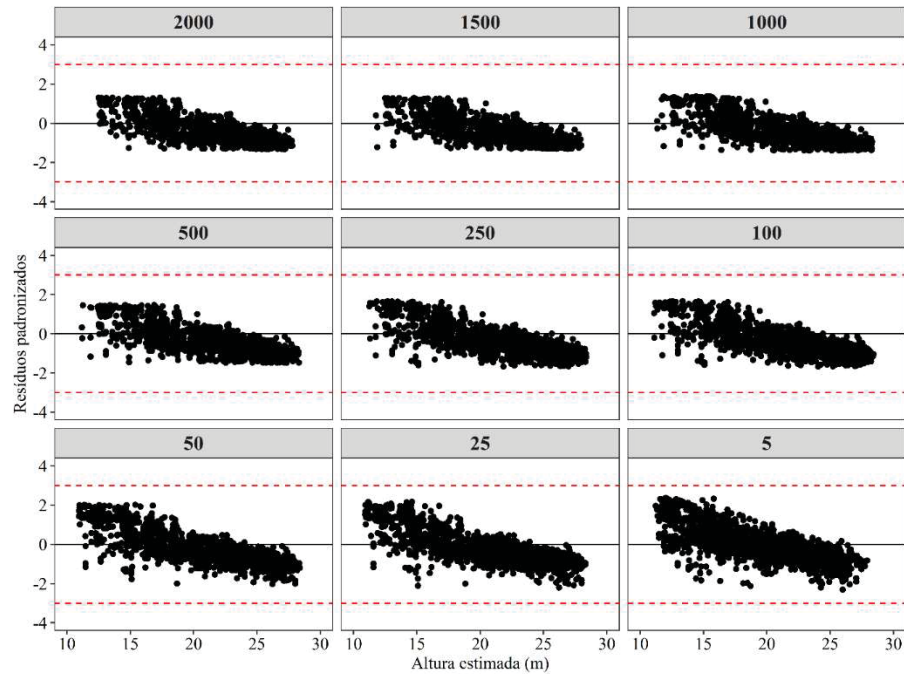


Figura 10: Dispersão dos resíduos de *E. benthamii* para cada densidade de pontos no projeto NITA, Pinhais, Paraná, Brasil.




Figura 11: Dispersão da altura de *E. benthamii* para cada densidade de pontos no projeto NITA, Pinhais, Paraná, Brasil.

Pelo teste de Tukey, a 95 % de probabilidade, as densidades de 2.000 até 100 pts/m² derivaram alturas semelhantes entre si, as quais diferiram das demais. As densidades de 50 e 25 pts/m² também são semelhantes, enquanto 5 pts/m² difere das demais (Figura 12). As alturas derivadas, apesar de superestimar as alturas do campo, possuem distribuição semelhante, com mediana próxima ao centro e distribuição assimétrica negativa (Figura 12).

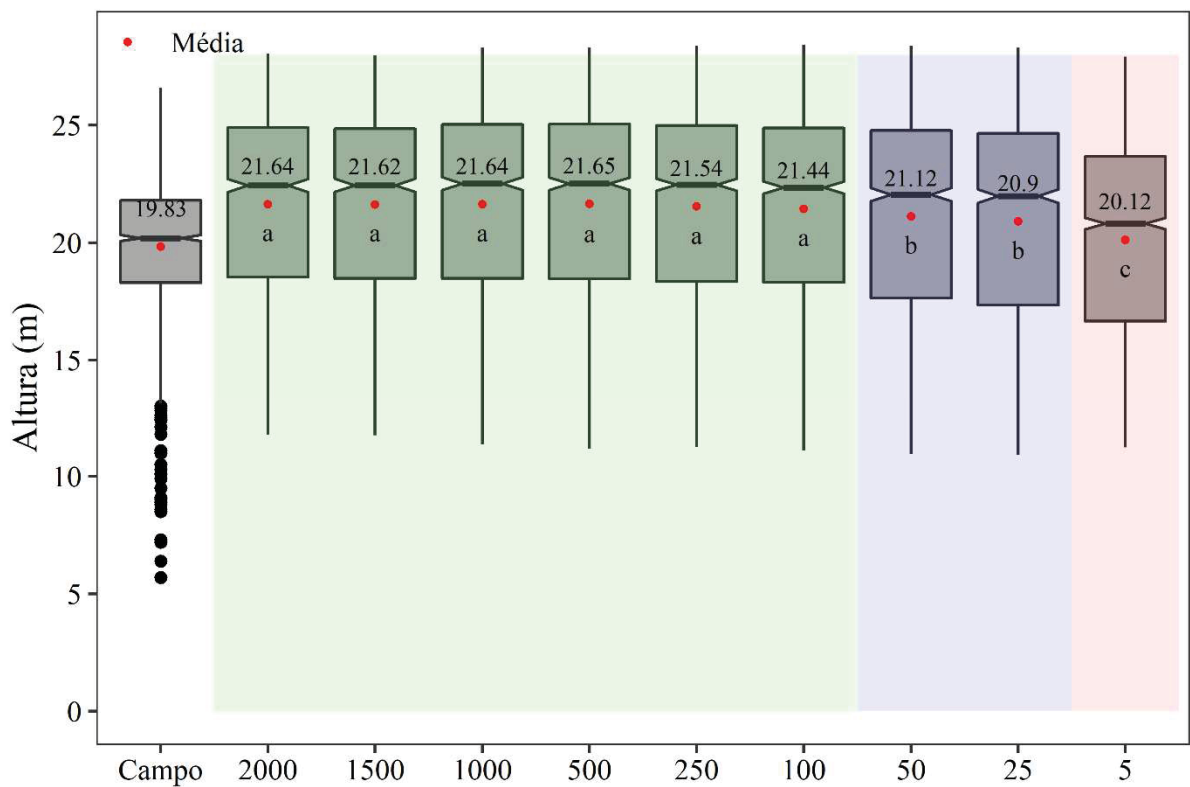


Figura 12: Teste de Tukey para as densidades de pontos UAV-Lidar na derivação da altura de *E. benthamii* no projeto NITA, Pinhais, Paraná, Brasil.

Letras iguais não diferem entre si pelo teste de Tukey ao nível de 5% de significância.

As alturas derivadas pelo UAV-Lidar tenderam a superestimar o volume médio individual das árvores (V_{mi}), exceto para a densidade de 5 pts/m², a qual subestimou o V_{mi} . As diferenças variaram entre 1,21% para 5 pts/m² e -9,38% para 2.000 pts/m². Apesar disso, devido ao número de indivíduos contabilizados por cada densidade da nuvem de pontos, há baixa variação entre os estoques de volume calculados com a altura derivada do UAV-Lidar e com os dados de campo, sendo a maior divergência (-25,75%) obtida pela densidade de 5 pts/m², a qual superestimou a quantidade de

indivíduos da área. Os estoques das densidades 2.000 e 100 pts/m² são os que mais se aproximam do estoque quantificado com os dados de campo (Tabela 4).

Tabela 4: Inferência das alturas nos estoques volumétricos de *E. benthamii* no projeto NITA, Pinhais, Paraná, Brasil.

Cenário	Variáveis do povoamento				Diferença (%)		
	Vmi (m ³ .árvore ⁻¹)	n	V (m ³ .ha ⁻¹)	Estoque (m ³)	Vmi	Estoque	
Campo	0,6963	1869	82,42	1301,38	-	-	
Densidade da nuvem de pontos (pts/m ²)	2.000	0,7616	1698	81,90	1293,24	-9,38	0,63
	1.500	0,7595	1735	83,45	1317,70	-9,07	-1,25
	1.000	0,7546	1755	83,87	1324,32	-8,37	-1,76
	500	0,7551	1712	81,87	1292,72	-8,44	0,67
	250	0,7517	1715	81,64	1289,16	-7,96	0,94
	100	0,7452	1744	82,31	1299,62	-7,02	0,14
	50	0,7388	1745	81,64	1289,16	-6,10	0,94
	25	0,7228	1757	80,43	1269,99	-3,81	2,41
5	0,6879	2379	103,64	1636,48	1,21	-25,75	

Vmi é o volume médio individual, n é o número total de árvores, V é o volume da área em m³.ha⁻¹.

5 DISCUSSÃO

A redução da densidade de pontos ocasionou maiores divergências na representação do perfil da árvore, sobretudo no topo (Figura 4), contudo, apesar da menor quantidade de pontos, não há grandes diferenças no modelo de elevação (Figuras 5 e 6), de tal maneira que a redução da densidade de pontos influencia diretamente no modelo digital de copas (Figura 7 e 8), o que ocasionou as diferenças na altura derivada para cada densidades (CAMPBELL et al., 2018; HAMRAZ; CONTRERAS; ZHANG, 2017; KATO et al., 2009; KÜKENBRINK et al., 2017; THOMAS et al., 2006).

Neste sentido, não houve alterações na nuvem de pontos que descaracterizasse a classificação do relevo, portanto, em todas as densidades o DTM é de alta qualidade, com baixa incidência de erros, o que favorece que a densidade da nuvem de pontos seja reduzida, sem inferir na precisão e acurácia das alturas derivadas (ANDERSON; THOMPSON; AUSTIN, 2005; WATT et al., 2014). Adicionalmente, a nuvem com menor densidade (5 pts/m²), em muitos estudos, equivale a máxima densidade obtida pelos autores, ou seja, apesar dessa densidade

ser considerada baixa para as condições deste estudo, esta foi eficaz para identificar espécies florestais, mensurar altura e biomassa em outras pesquisas (JAKUBOWSKI; GUO; KELLY, 2013; REX et al., 2018, 2019; SILVA et al., 2017d; WANNASIRI et al., 2013).

O sistema GatorEye obteve alturas acuradas com correlação forte até a densidade de 100 pts/m² e moderada para as demais densidades (Tabela 3), de tal forma que com o mesmo sistema, Corte et al. (2020), obtiveram correlação semelhante para a derivação da altura (0,77) sob uma densidade de 1.400 pts/m², porém, para uma quantidade menor de árvores. Em estudos com menor densidade de pontos, as correlações mantêm-se entre moderada e forte (POPESCU; WYNNE; NELSON, 2003; RIAÑO et al., 2007; SANKEY et al., 2013, 2010), o que explica densidades baixas apresentar correlação entre 0,5-0,7.

As derivações de altura obtidas neste estudo podem ser consideradas acuradas, uma vez que o RMSE se manteve entre 14% e 18%, enquanto o viés variou entre -1% e 8% (Tabela 3), o que ratifica os resultados obtidos em outros estudos. Wannasiri et al. (2013) reportaram RMSE de 19,4% e viés de -5,7% sob uma densidade de 2,7 pontos.m², Guo et al. (2017) reportaram RMSE de 38,57%, utilizando um sensor UAV-Lidar com densidade de 293,4 pontos.m², Sankey et al. (2017) utilizaram uma nuvem de pontos de 35 pts/m² e obtiveram RMSE de 2,3 m, Yin; Wang (2019) com um UAV-Lidar de densidade de 91 pontos.m² reportaram viés entre -3,5% e -9,4%, além de RMSE variando de 6,3% e 14,3%. Tais resultados ressaltam a acurácia das alturas derivadas neste estudo.

As maiores divergências nas classes de altura 7,5 m e 27,5 m (Figuras 3 e 9) podem estar relacionadas ao fato que as mensurações de altura em campo apresentam o viés do equipamento e do operador, o que afeta a acurácia na determinação dessa variável (LARJAVAARA; MULLER-LANDAU, 2013; MUNROE; NAGENDRA; SOUTHWORTH, 2007; SOUTHWORTH; TUCKER, 2001; TEIXEIRA et al., 2009). Adicionalmente, aparelhos digitais para a mensuração de altura, tal como o Vertex IV, apresentam desempenho ruim para a mensuração de árvores mais altas, tais como as pertencentes a classe 27,5 m (Tabela 2), o que pode ter ocorrido nas condições deste estudo, pois oscilações mínimas na visada da árvore acarretam grandes erros na estimativa da altura total (DA SILVA et al., 2012a, 2012b; LAURO et al., 2018). Possivelmente, esses erros poderiam ser minimizados caso fosse realizada a mensuração direta de algumas árvores para ajuste de uma equação hipsométrica.

Vale ressaltar a importância da variável altura para o manejo florestal, sendo utilizada para determinar a capacidade produtiva do local, modelar o volume, biomassa e carbono, bem como a produção da floresta (BREDE et al., 2019; CASTRO et al., 2013; DUBE et al., 2015; FELDPAUSCH et al., 2012; FU et al., 2012; OLIVEIRA et al., 2008; RAHMAN et al., 2017; SANQUETTA et al., 2018; SILVA et al., 2016; SKOVSGAARD; VANCLAY, 2008), de modo está variável é de difícil mensuração e sujeita a diversos erros (LARJAVAARA; MULLER-LANDAU, 2013; MUNROE; NAGENDRA; SOUTHWORTH, 2007; TEIXEIRA et al., 2009). Assim, os resultados obtidos pelo sensor UAV-Lidar utilizado neste estudo se demonstraram satisfatórios para coletar a altura das árvores de forma mais rápida e com menor influência de erros (BREDE et al., 2017, 2019; CORTE et al., 2020; LIU; NOGUCHI; LIANG, 2019; SANKEY et al., 2017; WANG et al., 2020).

Usando sistema UAV-Lidar com 160 pts/m², Liu et al. (2018) obtiveram acurácia de 86% para identificação das árvores, enquanto para 150 pts/m² Oliveira et al. (2021) conseguiram identificar 96% dos indivíduos. Com densidade de 2.000 pts/m², Slavík et al. (2020) identificaram 86% das árvores. Tais resultados evidenciam que a determinação do número de árvores foi acurada, uma vez que conseguiu identificar cerca de 90% dos indivíduos de *E. benthamii* (Tabela 2). Vale ressaltar que a densidade superior a 100 pts/m² pode ser um fator determinante para obter acurácia na identificação dos indivíduos arbóreos. A determinação acurada do número de indivíduos, bem como da altura é essencial para quantificar os estoques da floresta, uma vez que nas densidades de 2.000 a 50 pts/m², apesar das diferenças no Vmi, o número acurado dos indivíduos favoreceu baixa divergência no estoque total de madeira em relação aos dados de campo (Tabela 4), denotando acurácia dos dados derivados do sistema UAV-Lidar.

A maior densidade de pontos obtiveram derivações mais acuradas, o que corrobora com os resultados reportados por Li; Hu; Noland (2013) e Silva et al. (2017d). Apesar disso, as derivações com densidades entre 2.000 pts/m² e 100 pts/m² são estatisticamente semelhantes (Figura 12), o que denota que se pode reduzir a nuvem de pontos até esta densidade, sem prejudicar a acurácia das derivações. Este fenômeno corrobora com os resultados reportados por García et al., (2010), González-Ferreiro; Diéguez-Aranda; Miranda (2012), Treitz et al., (2012), Ruiz et al. (2014) e Liu et al. (2018), nos quais foi possível reduzir a densidade da nuvem de pontos sem perdas de acurácia nas estimativas de variáveis da floresta.

Tal redução é viável, pois é possível planejar o voo para aquisição de dados com menor densidade, favorecendo o aumento de velocidade e altitude do sensor, conseqüentemente, redução do gasto de bateria (RUIZ et al., 2014), possibilitando o processamento mais ágil e com menor custo computacional (AJI et al., 2013; HONGCHAO; WANG, 2011; WERDER; KRÜGER, 2009). Conseqüentemente, a redução da densidade de pontos reduz os custos inerentes a aquisição dos dados UAV-Lidar, pois, uma vez aumentada a velocidade e a altitude, o sistema ganha em autonomia, podendo realizar voos em maiores áreas em um intervalo de tempo semelhante ao necessário para gerar uma nuvem de pontos de alta densidade em uma área menor.

Apesar de apresentar vários benefícios, o UAV-Lidar ainda é um sistema novo e possui alguns obstáculos (YIN; WANG, 2019). A necessidade de uma plataforma extremamente estável para coleta de dados Lidar é uma destas, de tal maneira que as rajadas de vento podem gerar densidades de pontos diferentes em um mesmo local (YANG et al., 2017), portanto, a homogeneização da nuvem de pontos é uma etapa de processamento imprescindível. Contudo, o UAV DJI M600 pro, por se tratar de uma plataforma multi-rotor, reduz a vibração durante o plano de voo, favorecendo a aquisição dos dados Lidar (WALLACE et al., 2012). Portanto, a alta densidade de pontos e os custos de aquisição de dados, torna o UAV-Lidar uma alternativa viável para mensuração de variáveis florestais em áreas pequenas (< 50 ha), possibilitando derivações acuradas da altura das árvores (GUO et al., 2017; JAAKKOLA et al., 2010; WALLACE et al., 2012; WANG et al., 2020).

6 CONCLUSÕES

O sistema GatorEye utilizado neste estudo demonstrou-se eficaz para derivar a altura total do *Eucalyptus benthamii* em sistemas agrosilvipastoris com precisão e acurácia. O sistema demonstrou melhor desempenho para derivar as classes centrais de altura (12,5 m – 22,5 m). A densidade da nuvem de pontos pode ser reduzida até 100 pts/m² sem perda de acurácia, sendo esta a densidade ideal para a derivação da altura neste estudo.

7 RECOMENDAÇÕES

Em estudos futuros, recomenda-se a avaliação da influência da densidade de pontos do sensor GatorEye em florestas homogêneas (puras), a fim de averiguar se o comportamento apresentado em sistemas agrosilvipastoris, onde a densidade das árvores é menor, se assemelha em locais com maior densidade de indivíduos.

REFERÊNCIAS

- AJI, A. et al. Hadoop gis: A high performance spatial data warehousing system over mapreduce. **Proceedings of the VLDB Endowment**, v. 6, n. 11, p. 1009–1020, 2013.
- ALEXANDER, C. et al. Airborne laser scanner (LiDAR) proxies for understory light conditions. **Remote Sensing of Environment**, v. 134, p. 152–161, 2013.
- ALVARES, C. A. et al. Köppen’s climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013.
- ANDERSEN, H.; STRUNK, J.; TEMESGEN, H. Sampling Tool for Estimating Forest Biomass Interior Alaska. v. 26, n. cm, p. 157–164, 2011.
- ANDERSON, E. S.; THOMPSON, J. A.; AUSTIN, R. E. LIDAR density and linear interpolator effects on elevation estimates. **International Journal of Remote Sensing**, v. 26, n. 18, p. 3889–3900, 2005.
- ANDERSON, K.; GASTON, K. J. Lightweight unmanned aerial vehicles will revolutionize spatial ecology. **Frontiers in Ecology and the Environment**, v. 11, n. 3, p. 138–146, 2013.
- BAKKER, W. H. et al. **Principles of Remote Sensing**. [s.l.] The International Institute for Geo-Information Science and Earth Observation, 2009.
- BALBINO, L. C. et al. Sistemas de integração: conceitos, considerações, contribuições e desafios. In: BUNGENSTAB, D. J. et al. (Eds.). . **ILPF: inovação com integração de lavoura, pecuária e floresta**. Brasília: Embrapa, 2019. p. 31–48.
- BALBINO, L. C.; BARCELLOS, A. O.; STONE, L. F. **Marco referencial : integração lavoura-pecuária-floresta**. Brasília: Embrapa, 2011.
- BALTSAVIAS, E. P. A comparison between photogrammetry and laser scanning. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, n. 2–3, p. 83–94, 1999a.
- BALTSAVIAS, E. P. Airborne laser scanning: Basic relations and formulas. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, n. 2–3, p. 199–214, 1999b.
- BATISTA, J. L. F. **Mensuração de árvores: Uma introdução à dendrometria**. 1. ed. Piracicaba: Escola Superior de Agricultura “Luiz de Queiroz”, 2001.
- BINOTI, M. L. M. DA S.; BINOTI, D. H. B.; LEITE, H. G. Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de eucalipto. **Revista Arvore**, v. 37, n. 4, p. 639–645, 2013.

- BIRDAL, A. C.; AVDAN, U.; TÜRK, T. Estimating tree heights with images from an unmanned aerial vehicle. **Geomatics, Natural Hazards and Risk**, v. 8, n. 2, p. 1–14, 2017.
- BREDE, B. et al. Comparing RIEGL RiCOPTER UAV LiDAR derived canopy height and DBH with terrestrial LiDAR. **Sensors (Switzerland)**, v. 17, n. 10, p. 1–16, 2017.
- BREDE, B. et al. Non-destructive tree volume estimation through quantitative structure modelling: Comparing UAV laser scanning with terrestrial LIDAR. **Remote Sensing of Environment**, v. 233, n. January, p. 111355, 2019.
- BREMER, M.; SASS, O. Combining airborne and terrestrial laser scanning for quantifying erosion and deposition by a debris flow event. **Geomorphology**, v. 138, n. 1, p. 49–60, 2012.
- BURNS, W. J. et al. Analysis of elevation changes detected from multi-temporal LiDAR surveys in forested landslide terrain in western Oregon. **Environmental and Engineering Geoscience**, v. 16, n. 4, p. 315–341, 2010.
- CAMPBELL, M. J. et al. Quantifying understory vegetation density using small-footprint airborne lidar. **Remote Sensing of Environment**, v. 215, n. December 2017, p. 330–342, 2018.
- CAMPBELL, M. J.; DENNISON, P. E.; BUTLER, B. W. A LiDAR-based analysis of the effects of slope, vegetation density, and ground surface roughness on travel rates for wildland firefighter escape route mapping. **International Journal of Wildland Fire**, v. 26, n. 10, p. 884–895, 2017.
- CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: perguntas e respostas. Viçosa, MG: UFV, 2006.**
- CARTER, J. et al. **An Introduction to Lidar Technology , Data , and Applications.** [s.l.] NOAA Coastal Services Center, 2012.
- CASTRO, R. V. O. et al. Crescimento e produção de plantios comerciais de eucalipto estimados por duas categorias de modelos. **Pesquisa Agropecuaria Brasileira**, v. 48, n. 3, p. 287–295, 2013.
- CHASMER, L.; HOPKINSON, C.; TREITZ, P. Investigating laser pulse penetration through a conifer canopy by integrating airborne and terrestrial lidar. **Canadian Journal of Remote Sensing**, v. 32, n. 2, p. 116–125, 2006.
- CHEN, C. et al. A multiresolution hierarchical classification algorithm for filtering airborne LiDAR data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 82, p. 1–9, 2013.
- CLARK, M. L.; CLARK, D. B.; ROBERTS, D. A. Small-footprint lidar estimation of sub-canopy elevation and tree height in a tropical rain forest landscape. **Remote Sensing of Environment**, v. 91, n. 1, p. 68–89, 2004.

CONTE, O. et al. Evolução de atributos físicos de solo em sistema de integração lavoura-pecuária. **Pesquisa Agropecuaria Brasileira**, v. 46, n. 10, p. 1301–1309, 2011.

CORREA, J. C.; REICHARDT, K. Efeito do tempo de uso das pastagens sobre as propriedades de um latossolo amarelo da Amazônia Central. **Pesquisa Agropecuaria Brasileira**, v. 30, n. 1, p. 107–114, 1995.

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, 2020.

CUNHA NETO, E. M. DA et al. Redes neurais artificiais e regressão na estimativa da altura em povoamento experimental misto e equiâneo. **Caderno de ciências agrárias**, v. 10, n. 3, p. 60–68, 2018.

CUNHA NETO, E. M. DA et al. Silvicultura 4.0. In: **Avanços científicos e tecnológicos nas ciências agrárias**. Ponta Grossa: Editora Atena, 2020. p. 148–156.

D'OLIVEIRA, M. V. N. et al. Estimating forest biomass and identifying low-intensity logging areas using airborne scanning lidar in Antimary State Forest, Acre State, Western Brazilian Amazon. **Remote Sensing of Environment**, v. 124, p. 479–491, 2012.

DA SILVA, G. F. et al. Avaliação de métodos de medição de altura em florestas naturais. **Revista Arvore**, v. 36, n. 2, p. 341–348, 2012a.

DA SILVA, G. F. et al. Influência de diferentes fontes de erro sobre as medições de alturas de árvores. **Cerne**, v. 18, n. 3, p. 397–405, 2012b.

DANDOIS, J. P.; ELLIS, E. C. High spatial resolution three-dimensional mapping of vegetation spectral dynamics using computer vision. **Remote Sensing of Environment**, v. 136, n. January 2015, p. 259–276, 2013.

DEMPEWOLF, J. et al. Measurement of Within-Season Tree Height Growth in a Mixed Forest Stand Using UAV Imagery. **Forests**, v. 231, n. 8, p. 1–15, 2017.

DOMB, M.; BONCHEK-DOKOW, E.; LESHEM, G. Lightweight adaptive Random-Forest for IoT rule generation and execution. **Journal of Information Security and Applications**, v. 34, p. 218–224, 2017.

DUBE, T. et al. Predicting Eucalyptus spp. stand volume in Zululand, South Africa: an analysis using a stochastic gradient boosting regression ensemble with multi-source data sets. **International Journal of Remote Sensing**, v. 36, n. 14, p. 3751–3772, 2015.

DUNCANSON, L.; ROURKE, O.; DUBAYAH, R. Small Sample Sizes Yield Biased Allometric Equations in Temperate Forests. **Scientific Reports**, v. 5, p. 1–13, 2015.

ESTORNELL, J. et al. Estimation of shrub biomass by airborne LiDAR data in small forest stands. **Forest Ecology and Management**, v. 262, n. 9, p. 1697–1703, 2011.

FAN, Y. et al. Estimating tree position, diameter at breast height, and tree height in real-time using a mobile phone with RGB-D SLAM. **Remote Sensing**, v. 10, n. 11, 2018.

FELDPAUSCH, T. R. et al. Tree height integrated into pantropical forest biomass estimates. **Biogeosciences**, v. 9, n. 8, p. 3381–3403, 2012.

FLORENZANO, T. G. **Imagens de satélite para estudos ambientais**. 3. ed. São Paulo: Oficina de textos, 2011.

FU, L. Y. et al. Using linear mixed model and dummy variable model approaches to construct compatible single-tree biomass equations at different scales - A case study for Masson pine in Southern China. **Journal of Forest Science**, v. 58, n. 3, p. 101–115, 2012.

GARCÍA, M. et al. Estimating biomass carbon stocks for a Mediterranean forest in central Spain using LiDAR height and intensity data. **Remote Sensing of Environment**, v. 114, n. 4, p. 816–830, 2010.

GASPAROTO, E. A. G. **O Panorama do inventário florestal de florestas plantadas no Brasil**. [s.l.] Universidade Federal do Paraná, 2017.

GIONGO, M. et al. LiDAR: princípios e aplicações florestais. **Pesquisa Florestal Brasileira**, v. 30, n. 63, p. 231–244, 2010.

GOBAKKEN, T.; NÆSSET, E. Assessing effects of laser point density, ground sampling intensity, and field sample plot size on biophysical stand properties derived from airborne laser scanner data. **Canadian Journal of Forest Research**, v. 38, n. 5, p. 1095–1109, 2008.

GONZÁLEZ-FERREIRO, E.; DIÉGUEZ-ARANDA, U.; MIRANDA, D. Estimation of stand variables in *Pinus radiata* D. Don plantations using different LiDAR pulse densities. **Forestry**, v. 85, n. 2, p. 281–292, 2012.

GOODWIN, N. R.; COOPS, N. C.; CULVENOR, D. S. Assessment of forest structure with airborne LiDAR and the effects of platform altitude. **Remote Sensing of Environment**, v. 103, n. 2, p. 140–152, 2006.

GOULDEN, T. et al. Sensitivity of DEM, slope, aspect and watershed attributes to LiDAR measurement uncertainty. **Remote Sensing of Environment**, v. 179, p. 23–35, 2016.

GUO, Q. et al. An integrated UAV-borne lidar system for 3D habitat mapping in three forest ecosystems across China. **International Journal of Remote Sensing**, v. 00, n. 00, p. 1–19, 2017.

HAMRAZ, H.; CONTRERAS, M. A.; ZHANG, J. Forest understory trees can be segmented accurately within sufficiently dense airborne laser scanning point clouds. **Scientific Reports**, v. 7, n. 1, p. 1–9, 2017.

HAYASHI, R.; WEISKITTEL, A.; KERSHAW, J. A. Influence of Prediction Cell Size on LiDAR-Derived Area-Based Estimates of Total Volume in Mixed-Species and

Multicohort Forests in Northeastern North America. **Canadian Journal of Remote Sensing**, v. 42, n. 5, p. 473–488, 2016.

HERITAGE, G. L. et al. Influence of survey strategy and interpolation model on DEM quality. **Geomorphology**, v. 112, n. 3–4, p. 334–344, 2009.

HONGCHAO, M.; WANG, Z. Distributed data organization and parallel data retrieval methods for huge laser scanner point clouds. **Computers and Geosciences**, v. 37, n. 2, p. 193–201, 2011.

HUDAK, A. T. et al. LiDAR Utility for Natural Resource Managers. **Remote Sensing**, v. 1, p. 934–951, 2009.

HUNTER, M. O. et al. Structural dynamics of tropical moist forest gaps. **PLoS ONE**, v. 10, n. 7, p. 1–19, 2015.

HYYPPÄ, J. et al. A segmentation-based method to retrieve stem volume estimates from 3-D tree height models produced by laser scanners. **IEEE Transactions on Geoscience and Remote Sensing**, v. 39, n. 5, p. 969–975, 2001.

INMAN, D. et al. Active remote sensing and grain yield in irrigated maize. **Precision Agriculture**, v. 8, n. 4–5, p. 241–252, 2007.

ISENBURG, M. **Lastools—efficient lidar processing software**, 2019. Disponível em: <<http://rapidlasso.com/LAStools>>

JAAKKOLA, A. et al. A low-cost multi-sensoral mobile mapping system and its feasibility for tree measurements. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, n. 6, p. 514–522, 2010.

JAKUBOWSKI, M. K.; GUO, Q.; KELLY, M. Tradeoffs between lidar pulse density and forest measurement accuracy. **Remote Sensing of Environment**, v. 130, p. 245–253, 2013.

JAMES, L. A.; WATSON, D. G.; HANSEN, W. F. Using LiDAR data to map gullies and headwater streams under forest canopy: South Carolina, USA. **Catena**, v. 71, n. 1, p. 132–144, 2007.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres**. 2. ed. São José dos Campos: (Tradução da Segunda Edição), 2011.

KAARTINEN, H. et al. An international comparison of individual tree detection and extraction using airborne laser scanning. **Remote Sensing**, v. 4, n. 4, p. 950–974, 2012.

KATO, A. et al. Capturing tree crown formation through implicit surface reconstruction using airborne lidar data. **Remote Sensing of Environment**, v. 113, n. 6, p. 1148–1162, 2009.

KORPELA, I.; HOVI, A.; MORSDORF, F. Understory trees in airborne LiDAR data - Selective mapping due to transmission losses and echo-triggering mechanisms. **Remote Sensing of Environment**, v. 119, p. 92–104, 2012.

KRAMER, H. et al. Estimating Ladder Fuels: A New Approach Combining Field Photography with LiDAR. **Remote Sensing**, v. 8, n. 9, p. 766, 2016.

KÜKENBRINK, D. et al. Quantification of hidden canopy volume of airborne laser scanning data using a voxel traversal algorithm. **Remote Sensing of Environment**, v. 194, p. 424–436, 2017.

KUKUNDA, C. B. et al. Ensemble classification of individual Pinus crowns from multispectral satellite imagery and airborne LiDAR. **International Journal of Applied Earth Observation and Geoinformation**, v. 65, n. September 2017, p. 12–23, 2018.

LARJAVAARA, M.; MULLER-LANDAU, H. C. Measuring tree height : a quantitative comparison of two common field methods in a moist tropical forest. **Methods in Ecology and Evolution**, v. 4, n. 9, p. 793–801, 2013.

LAURO, A. C. et al. Operacionalidade de instrumentos na obtenção da altura total de árvores em sistema agrossilvipastoril. **Advances in Forestry Science**, v. 5, n. 4, p. 445–451, 2018.

LEITOLD, V. et al. Airborne lidar-based estimates of tropical forest structure in complex terrain: Opportunities and trade-offs for REDD+. **Carbon Balance and Management**, v. 10, n. 1, 2015.

LI, J.; HU, B.; NOLAND, T. L. Classification of tree species based on structural features derived from high density LiDAR data. **Agricultural and Forest Meteorology**, v. 171–172, p. 104–114, 2013.

LIN, Y.; HYYPPÄ, J.; JAAKKOLA, A. Mini-UAV-borne LIDAR for fine-scale mapping. **IEEE Geoscience and Remote Sensing Letters**, v. 8, n. 3, p. 426–430, 2011.

LIU, J. et al. Extraction of individual tree crowns from airborne LiDAR data in human settlements. **Mathematical and Computer Modelling**, v. 58, n. 3–4, p. 524–535, 2013.

LIU, K. et al. Estimating forest structural attributes using UAV-LiDAR data in Ginkgo plantations. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 146, n. May, p. 465–482, 2018.

LIU, Y.; NOGUCHI, N.; LIANG, L. Development of a positioning system using UAV-based computer vision for an airboat navigation in paddy field. **Computers and Electronics in Agriculture**, v. 162, n. April, p. 126–133, 2019.

LOVELL, J. L. et al. Simulation study for finding optimal lidar acquisition parameters for forest height retrieval. **Forest Ecology and Management**, v. 214, n. 1–3, p. 398–412, 2005.

MACHADO, S. .; FIGUEIREDO FILHO, A. **Dendrometria**. Curitiba: [s.n.].

- MACLEAN, G. A.; KRABILL, W. B. Gross-merchantable timber volume estimation using an airborne lidar system. **Canadian Journal of Remote Sensing**, v. 12, n. 1, p. 7–18, 1986.
- MALLET, C.; BRETAR, F. Full-waveform topographic lidar: State-of-the-art. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 64, n. 1, p. 1–16, 2009.
- MALTAMO, M.; NAESSET, E.; VAUHKONEN, J. **Forestry Applications of Airborne Laser Scanning: Concepts and Case Studies**. [s.l.] Springer, 2014.
- MANURI, S. et al. Assessing the influence of return density on estimation of lidar-based aboveground biomass in tropical peat swamp forests of Kalimantan, Indonesia. **International Journal of Applied Earth Observation and Geoinformation**, v. 56, p. 24–35, 2017.
- MARTINS, E. DOS R. et al. Configuração de redes neurais artificiais para estimação da altura total de árvores de eucalipto. **Revista Brasileira de Ciências Agrárias**, v. 11, n. 2, p. 117–123, 2016.
- MENDONÇA, A. R. DE et al. Estimação Da Altura Total De Árvores De Ipê Felpudo Utilizando Modelos De Regressão E Redes Neurais. **Revista Brasileira De Biometria**, v. 36, n. 1, p. 128, 2018.
- MENG, X. et al. A multi-directional ground filtering algorithm for airborne LIDAR. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 64, n. 1, p. 117–124, 2009.
- MOHAN, M. et al. Individual tree detection from unmanned aerial vehicle (UAV) derived canopy height model in an open canopy mixed conifer forest. **Forests**, v. 8, n. 9, p. 1–17, 2017.
- MORAES, A. DE et al. Apresentação geral da área experimental do NITA. In: DOMINSCHKE, R. et al. (Eds.). . **Sistemas integrados de produção agropecuária na promoção da intensificação sustentável**. 1. ed. [s.l.] Universidade Federal do Paraná, 2018. p. 54–67.
- MOREIRA, M. A. **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação**. 4. ed. Viçosa: Universidade Federal de Viçosa, 2011.
- MUNROE, D. K.; NAGENDRA, H.; SOUTHWORTH, J. Monitoring landscape fragmentation in an inaccessible mountain area: Celaque National Park, Western Honduras. **Landscape and Urban Planning**, v. 83, n. 2–3, p. 154–167, 2007.
- NELSON, R. How did we get here? An early history of forestry lidar. **Canadian Journal of Remote Sensing**, v. 39, n. SUPPL.1, 2013.
- NEVALAINEN, O. et al. Individual Tree Detection and Classification with UAV-Based Photogrammetric Point Clouds and Hyperspectral Imaging. **Remote Sensing**, v. 9, n. 3, p. 185–196, 2017.

- NOTEBAERT, B. et al. Qualitative and quantitative applications of LiDAR imagery in fluvial geomorphology. **Earth Surface Processes and Landforms**, v. 34, p. 217–231, 2009.
- OLIVEIRA, L. F. R. DE et al. Moving to Automated Tree Inventory: Comparison of UAS-Derived Lidar and Photogrammetric Data with Manual Ground Estimates. **Remote Sensing**, v. 13, n. 1, p. 72, 2021.
- OLIVEIRA, M. L. R. DE et al. Classificação da capacidade produtiva de povoamentos não desbastados de clones de eucalipto. **Pesquisa Agropecuaria Brasileira**, v. 43, n. 11, p. 1559–1567, 2008.
- OTA, T. et al. Aboveground biomass estimation using structure from motion approach with aerial photographs in a seasonal tropical forest. **Forests**, v. 6, n. 11, p. 3882–3898, 2015.
- OTA, T. et al. Forest Structure Estimation from a UAV-Based Photogrammetric Point Cloud in Managed Temperate Coniferous Forests. p. 1–11, 2017.
- PANAGIOTIDIS, D.; ABDOLLAHNEJAD, A.; SUROVÝ, P. Determining tree height and crown diameter from high-resolution UAV imagery. **International Journal of Remote Sensing**, v. 00, n. 00, p. 1–19, 2016.
- PARTHIBAN, M. et al. IOT based anti-poaching sensor system for trees in forest. **International Journal of Innovative Technology and Exploring Engineering**, v. 8, n. 6 Special Issue 4, p. 172–176, 2019.
- PERROY, R. L. et al. Comparison of gully erosion estimates using airborne and ground-based LiDAR on Santa Cruz Island, California. **Geomorphology**, v. 118, n. 3–4, p. 288–300, 2010.
- PONT, D. et al. Tree counts from airborne LiDAR. **N.Z. Journal of Forestry**, v. 60, n. 1, p. 38–43, 2015.
- POPESCU, S. C. Estimating biomass of individual pine trees using airborne lidar. **Biomass and Bioenergy**, v. 31, n. 9, p. 646–655, 2007.
- POPESCU, S. C.; WYNNE, R. H.; NELSON, R. F. Measuring individual tree crown diameter with lidar and assessing its influence on estimating forest volume and biomass. **Canadian Journal of Remote Sensing**, v. 29, n. 5, p. 564–577, 2003.
- R CORE TEAM. **R: A language and environment for statistical computing**. Vienna R Foundation for Statistical Computing, , 2019.
- RAHMAN, M. Z. A. et al. Non-destructive, laser-based individual tree aboveground biomass estimation in a tropical rainforest. **Forests**, v. 8, n. 3, 2017.
- RAZAK, K. A. et al. Airborne laser scanning of forested landslides characterization: Terrain model quality and visualization. **Geomorphology**, v. 126, n. 1–2, p. 186–200, 2011.

- REX, F. E. et al. Identificação e extração de copas de *Araucaria angustifolia* (Bertol .) Kuntze a partir de dados LiDAR. **Advances in Forestry Science**, v. 5, n. 2, p. 319–323, 2018.
- REX, F. E. et al. Estimating Above-Ground Biomass of *Araucaria angustifolia* (Bertol.) Kuntze Using LiDAR Data. **Floresta e Ambiente**, v. 26, n. 4, 2019.
- RIAÑO, D. et al. Estimation of shrub height for fuel-type mapping combining airborne LiDAR and simultaneous color infrared ortho imaging. **International Journal of Wildland Fire**, v. 16, n. 3, p. 341–348, 2007.
- ROSETTE, J. et al. Lidar Remote Sensing for Biomass Assessment. In: **Remote Sensing of Biomass - Principles and Applications**. Rijeka: Intech, 2012. p. 322.
- ROUSSEL, J.-R.; AUTY, D. **lidR: Airborne LiDAR data manipulation and visualization for forestry applications**. R package version, , 2019. Disponível em: <<https://cran.r-project.org/package=lidR>>
- RUIZ, L. A. et al. Analysis of the influence of plot size and LiDAR density on forest structure attribute estimates. **Forests**, v. 5, n. 5, p. 936–951, 2014.
- SAIKUMAR, S. T.; SRIRAMYA, P. IoT enabled forest fire detection and altering the authorities. **International Journal of Recent Technology and Engineering**, v. 7, n. 6, p. 429–433, 2019.
- SANKEY, T. et al. Lidar-derived estimate and uncertainty of carbon sink in successional phases of woody encroachment. **Journal of Geophysical Research: Biogeosciences**, v. 118, n. 3, p. 1144–1155, 2013.
- SANKEY, T. et al. Remote Sensing of Environment UAV lidar and hyperspectral fusion for forest monitoring in the southwestern USA. **Remote Sensing of Environment**, v. 195, p. 30–43, 2017.
- SANKEY, T. T. et al. Characterizing western juniper expansion via a fusion of Landsat 5 thematic mapper and lidar data. **Rangeland Ecology and Management**, v. 63, n. 5, p. 514–523, 2010.
- SANQUETTA, C. R. et al. Selection criteria for linear regression models to estimate individual tree biomasses in the Atlantic Rain Forest, Brazil 01 Mathematical Sciences 0104 Statistics. **Carbon Balance and Management**, v. 13, n. 1, 2018.
- SANTOS, H. G. et al. **Sistema brasileiro de classificação de solos**. 5. ed. Brasília: Embrapa, 2018.
- SCHNEIDER, D.; MAAS, H.-G. Integrated bundle adjustment of terrestrial laser scanner data and image data with variance component estimation. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XXXVI, n. 3, p. 373–378, 2007.
- SCHOWENGERDT, R. A. **Remote sensing: Models and methods for image processing: Second edition**. 3. ed. [s.l.] Elsevier, 2006.

SILVA, C. A. et al. A principal component approach for predicting the stem volume in Eucalyptus plantations in Brazil using airborne LiDAR data. **Forestry**, v. 89, n. 4, p. 422–433, 2016.

SILVA, C. A. et al. Predicting stem total and assortment volumes in an industrial Pinus taeda L. forest plantation using airborne laser scanning data and random forest. **Forests**, v. 8, n. 7, p. 1–17, 2017a.

SILVA, C. A. et al. Combined effect of pulse density and grid cell size on predicting and mapping aboveground carbon in fast-growing Eucalyptus forest plantation using airborne LiDAR data. **Carbon Balance and Management**, v. 12, n. 1, p. 1–16, 2017b.

SILVA, C. A. et al. **rLiDAR: LiDAR data processing and visualization**. R package, , 2017c. Disponível em: <<https://cran.r-project.org/package=rLiDAR>>

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, 2017d.

SILVA, C. A.; VIERLING, L. A.; KLAUBERG, C. Modeling aboveground biomass from individual tree LiDAR-derived metrics in tropical forest. n. November, 2016.

SIMPSON, J. E.; SMITH, T. E. L.; WOOSTER, M. J. Assessment of errors caused by forest vegetation structure in airborne LiDAR-derived DTMs. **Remote Sensing**, v. 9, n. 11, p. 1–18, 2017.

SITHOLE, G.; VOSSELMAN, G. Experimental comparison of filter algorithms for bare-Earth extraction from airborne laser scanning point clouds. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 59, n. 1–2, p. 85–101, 2004.

SKOVSGAARD, J. P.; VANCLAY, J. K. Forest site productivity: A review of the evolution of dendrometric concepts for even-aged stands. **Forestry**, v. 81, n. 1, p. 13–31, 2008.

SLAVÍK, M. et al. Uav laser scans allow detection of morphological changes in tree canopy. **Remote Sensing**, v. 12, n. 22, p. 1–15, 2020.

SOUTHWORTH, J.; TUCKER, C. The Influence of Accessibility, Local Institutions, and Socioeconomic Factors on Forest Cover Change in the Mountains of Western Honduras. **Mountain Research and Development**, v. 21, n. 3, p. 276–283, 2001.

SUROVÝ, P.; RIBEIRO, N. A.; PANAGIOTIDIS, D. Estimation of positions and heights from UAV-sensed imagery in tree plantations in agrosilvopastoral systems. **International Journal of Remote Sensing**, v. 00, n. 00, p. 1–15, 2018.

TEIXEIRA, A. M. G. et al. Modeling landscape dynamics in an Atlantic Rainforest region: Implications for conservation. **Forest Ecology and Management**, v. 257, n. 4, p. 1219–1230, 2009.

- THOMAS, V. et al. Mapping stand-level forest biophysical variables for a mixedwood boreal forest using lidar: An examination of scanning density. **Canadian Journal of Forest Research**, v. 36, n. 1, p. 34–47, 2006.
- TINKHAM, W. T. et al. Investigating the influence of LiDAR ground surface errors on the utility of derived forest inventories. **Canadian Journal of Forest Research**, v. 42, n. 3, p. 413–422, 2012.
- TORRES-SÁNCHEZ, J. et al. High-Throughput 3-D Monitoring of Agricultural-Tree Plantations with Unmanned Aerial Vehicle (UAV) Technology. p. 1–20, 2015.
- TREITZ, P. et al. LiDAR sampling density for forest resource inventories in Ontario, Canada. **Remote Sensing**, v. 4, n. 4, p. 830–848, 2012.
- VASTARANTA, M. et al. Airborne laser scanning and digital stereo imagery measures of forest structure: Comparative results and implications to forest mapping and inventory update. **Canadian Journal of Remote Sensing**, v. 39, n. 5, p. 382–395, 2013.
- VENDRUSCOLO, D. G. S. et al. Estimativa Da Altura De Eucalipto Por Meio De Regressão Não Linear E Redes Neurais Artificiais. **Revista Brasileira de Biometria**, v. 33, n. 4, p. 556–569, 2015.
- VIVONI, E. R. et al. Ecohydrology with unmanned aerial vehicles. **Ecosphere**, v. 5, n. 10, p. 1–14, 2014.
- VOSELMAN, G.; MAAS, H.-G. **Airborne and Terrestrial Laser Scanning**. Dunbeath: Whittles Publishing, 2010.
- WAGNER, W. et al. From Single-Pulse to Full-Waveform Scanners: Potential and Practical Challenges. **International Archives of Photogrammetry and Remote Sensing**, v. 35, p. 201–206, 2004.
- WALLACE, L. et al. Development of a UAV-LiDAR system with application to forest inventory. **Remote Sensing**, v. 4, n. 6, p. 1519–1543, 2012.
- WALLACE, L.; LUCIEER, A.; WATSON, C. S. Evaluating Tree Detection and Segmentation Routines on Very High Resolution UAV LiDAR Data. **IEEE Trans. Geosci. Remote Sens**, v. 52, n. 12, p. 7619–7628, 2014.
- WALLACE, L.; MUSK, R.; LUCIEER, A. An Assessment of the Repeatability of Automatic Forest Inventory Metrics Derived From UAV-Borne Laser Scanning Data. **IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING**, v. 52, n. 11, p. 7160–7169, 2014.
- WANG, D. et al. Estimating aboveground biomass of the mangrove forests on northeast Hainan Island in China using an upscaling method from field plots, UAV-LiDAR data and Sentinel-2 imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 85, n. October 2019, p. 101986, 2020.
- WANNASIRI, W. et al. Extraction of mangrove biophysical parameters using airborne LiDAR. **Remote Sensing**, v. 5, n. 4, p. 1787–1808, 2013.

- WATT, M. S. et al. The influence of LiDAR pulse density on the precision of inventory metrics in young unthinned Douglas-fir stands during initial and subsequent LiDAR acquisitions. **New Zealand Journal of Forestry Science**, v. 44, n. 1, p. 1–9, 2014.
- WERDER, S.; KRÜGER, A. Parallelizing geospatial tasks in grid computing. **GIS-Zeitschrift für Geoinformatik**, n. 3, p. 71–76, 2009.
- WHITE, J. C. et al. The utility of image-based point clouds for forest inventory: A comparison with airborne laser scanning. **Forests**, v. 4, n. 3, p. 518–536, 2013.
- WILKINSON, B. et al. Geometric targets for UAS lidar. **Remote Sensing**, v. 11, n. 24, 2019.
- WULDER, M. A. et al. Lidar plots — a new large-area data collection option: Context, concepts, and case study. **Canadian Journal of Remote Sensing**, v. 38, n. 5, p. 600–618, 2012.
- YANG, G. et al. Unmanned aerial vehicle remote sensing for field-based crop phenotyping: Current status and perspectives. **Frontiers in Plant Science**, v. 8, n. June, 2017.
- YIN, D.; WANG, L. Individual mangrove tree measurement using UAV-based LiDAR data: Possibilities and challenges. **Remote Sensing of Environment**, v. 223, n. May 2018, p. 34–49, 2019.
- YOGA, S. et al. Modeling the effect of the spatial pattern of airborne lidar returns on the prediction and the uncertainty of timber merchantable volume. **Remote Sensing**, v. 9, n. 8, p. 1–13, 2017.
- YU, Z. et al. IoT forest environmental factors collection platform based on ZIGBEE. **Cybernetics and Information Technologies**, v. 14, n. SpecialIssue, p. 51–62, 2014.
- YUNJIE, X. Wireless sensor monitoring system of Canadian Poplar Forests based on Internet of Things. **Artificial Life and Robotics**, v. 24, n. 4, p. 471–479, 2019.
- ZARCO-TEJADA, P. J. et al. Tree height quantification using very high resolution imagery acquired from an unmanned aerial vehicle (UAV) and automatic 3D photo-reconstruction methods. **European Journal of Agronomy**, v. 55, p. 89–99, 2014.
- ZHAO, K.; POPESCU, S.; NELSON, R. Lidar remote sensing of forest biomass: A scale-invariant estimation approach using airborne lasers. **Remote Sensing of Environment**, v. 113, n. 1, p. 182–196, 2009.