

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

MIKAELY VASCONCELOS PAULO

DETECÇÃO INDIVIDUAL DE ÁRVORES E ESTIMATIVA DE
ALTURA TOTAL EM UM SISTEMA SILVIPASTORIL DE
EUCALIPTO E CAPIM MARANDU POR MEIO DA
FOTOGRAMETRIA AÉREA DIGITAL

JERÔNIMO MONTEIRO

ESPÍRITO SANTO

2023

MIKAELY VASCONCELOS PAULO

DETECÇÃO INDIVIDUAL DE ÁRVORES E ESTIMATIVA DE
ALTURA TOTAL EM UM SISTEMA SILVIPASTORIL DE
EUCALIPTO E CAPIM MARANDU POR MEIO DA
FOTOGRAMETRIA AÉREA DIGITAL

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

JERÔNIMO MONTEIRO

ESPÍRITO SANTO

2023

MIKAELY VASCONCELOS PAULO

DETECÇÃO INDIVIDUAL DE ÁRVORES E ESTIMATIVA DE
ALTURA TOTAL EM UM SISTEMA SILVIPASTORIL DE
EUCALIPTO E CAPIM MARANDU POR MEIO DA
FOTOGRAMETRIA AÉREA DIGITAL

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

Aprovada em 14 de julho de 2023.

COMISSÃO EXAMINADORA

Adriano Ribeiro de Mendonça

Prof. Dr. Adriano Ribeiro de Mendonça

Universidade Federal do Espírito Santo – UFES

Orientador

André Quintão de Almeida

Prof. Dr. André Quintão de Almeida

Universidade Federal de Sergipe – UFS

Examinador

Nívea Maria Mafra Rodrigues

Ma. Nívea Maria Mafra Rodrigues

Universidade Federal do Espírito Santo – UFES

Examinador

“O que sabemos é uma gota; o que ignoramos é um oceano”

(Isaac Newton)

AGRADECIMENTOS

Aos meus pais, Elci e Ana, e à minha irmã Elciany, por me darem amor, apoio e incentivo durante toda a minha vida. Sei o quanto abdicaram para que eu conquistasse este título, por isso, essa vitória é para vocês.

Ao meu parceiro de vida, Thiago, por todo amor, aconchego e apoio emocional durante todo o tempo, por isso, essa vitória também é sua.

A todos os amigos que a faculdade me deu, por todos os momentos vividos, fazendo com que esse período fosse mais leve e feliz. Em especial, a Marina e a Thuelem, pela amizade, companhia, cuidado, carinho e todos os ótimos momentos vividos. E também ao amigo que se tornou um irmão, Ricardo, por todo amor, apoio, companhia, amizade e boas risadas. Vocês ficarão para sempre em meu coração.

À minha amiga, Hevinny, que tanto me apoiou em momentos difíceis, por todo amor, ajuda e incentivo.

Aos amigos do LaMFlor, por todo apoio, paciência, ensinamentos e bons momentos juntos.

Ao grande professor André Quintão, por todo ensinamento, incentivo e conselhos durante a realização desta pesquisa, pela amizade e carinho comigo.

Ao professor Adriano Ribeiro, pela disponibilidade, apoio e importantes sugestões para melhoria deste trabalho.

A todos que direta ou indiretamente fizeram parte da minha trajetória.

Muito obrigada!

RESUMO

Uma das maneiras de se obter estimativas da produção florestal são os inventários florestais, entretanto, são muito onerosos, visto que demandam de grande quantidade de tempo e mão de obra qualificada. Neste pensamento, almejando reduzir os custos e o tempo da obtenção dos dados acerca dos estoques nos plantios, ferramentas de sensoriamento remoto podem ser utilizadas com acurácia, como a Fotogrametria Aérea Digital (FAD) obtidas por imagens coletadas por Aeronave Remotamente Pilotada (RPA). Este estudo teve como objetivo avaliar a acurácia da FAD para detecção de árvores individuais e estimar suas alturas em um sistema silvipastoril com 60 meses de idade em Jerônimo Monteiro, município localizado no sul do estado do Espírito Santo. A área de estudo consiste de um sistema silvipastoril composto por eucalipto (híbrido de *Eucalyptus grandis* x *Eucalyptus urophylla*) e capim marandu (*Urochloa brizantha* cv. marandu). No campo foram estimados os seguintes dados: número de árvores, diâmetro a 1,30 m do solo (D), altura total (H) e a localização (X e Y, em UTM) de todas as árvores. Para o inventário florestal por meio da FAD-RPA foi utilizada uma aeronave modelo MAVIC 2 PRO. O processamento da *Structure from Motion* foi realizado utilizando o software *Agisoft Metashape Professional Edition 1.6*. Após o processamento das imagens aéreas foi possível obter uma nuvem de pontos 3D, o modelo digital de superfície, o modelo digital do terreno e o ortomosaico RGB. O modelo digital do terreno gerado pelo sistema RTK (MDT_{RTK}) e o obtido pela FAD (MDT_{FAD}) obtiveram desempenhos bem semelhantes. Os algoritmos empregados foram capazes de identificar o topo das árvores com 68,8% de precisão, coerente com a idade e densidade do povoamento. O erro na detecção do topo das árvores foi menor que um metro, quando se comparou as coordenadas posicionais e as estimadas, sendo considerado baixo. Os valores de viés encontrados (0,06 m ou -0.65×10^{-6} %) mostraram que as estimativas das coordenadas não se mostraram viesadas. A qualidade da identificação das copas foi sustentada pelo baixo valor de RMSE encontrado ($< 0,001\%$). Além disso, os produtos obtidos pela FAD possibilitaram estimar as alturas das árvores de forma esperada, mostrando uma tendência a superestimação nas alturas, mesmo com baixo valor de viés. A superestimação de H_{FAD} provavelmente está

relacionada às dificuldades em reconstruir a parte superior das copas das árvores utilizando a FAD.

Palavras-chave: SAFs. Aeronave remotamente pilotada. Sensoriamento remoto. Manejo florestal.

SUMÁRIO

LISTA DE TABELAS	x
LISTA DE FIGURAS	xi
1. INTRODUÇÃO	12
1.1 OBJETIVOS	13
1.1.1 Objetivo Geral	13
1.1.2 Objetivos Específicos	13
2. REVISÃO DE LITERATURA.....	14
2.1 Inventário florestal.....	14
2.2 Sensoriamento remoto	15
2.3 Fotogrametria Aérea Digital.....	17
3. METODOLOGIA.....	22
3.1 Área de estudo	22
3.2 Coleta de dados.....	23
3.2.1 Inventário florestal tradicional – IFT.....	23
3.2.2 Inventário florestal aprimorado com a FAD	24
3.3 Processamento das imagens.....	25
3.3.1. Structure from Motion – SfM.....	25
3.3.2 Modelo digital do terreno e normalização da nuvem de pontos.....	25
3.3.3 Modelo digital de superfície e modelo de altura do dossel	26
3.3.4 Detecção de copa das árvores	26
3.4 Avaliação dos resultados da FAD	26
3.4.1 MDT	26
3.4.2 Detecção do topo da copa das árvores.....	27
3.4.3 Altura das árvores	28
4. RESULTADOS E DISCUSSÃO.....	29
4.1 Processamento da nuvem de pontos pelo algoritmo SfM e avaliação do MDT	29
4.2 Avaliação da detecção do topo das árvores	32
4.3 Avaliação das alturas das árvores	36

5. CONCLUSÃO.....	39
6. REFERÊNCIAS BIBLIOGRÁFICAS	40

LISTA DE TABELAS

Tabela 1. Descrição dos blocos implantados na área de estudo	23
Tabela 2. Estatísticas descritivas e de desempenho para altitudes coletadas em campo e as estimadas	31
Tabela 3. Métricas de detecção de copa das árvores	35
Tabela 4. Estatísticas para as diferenças entre as coordenadas posicionais e coordenadas estimadas	35
Tabela 5. Estatísticas de desempenho para as estimativas de altura total pela FAD.....	36

LISTA DE FIGURAS

Figura 1. Estereoscópico sobre par de fotos	18
Figura 2. Figura 2. Brasil (A), Estado Espírito Santo (B), Município Jerônimo Monteiro (C) e Área de estudo (D).....	22
Figura 3. Aeronave remotamente pilotada modelo MAVIC 2 PRO utilizada no sobrevoo da área de estudo	24
Figura 4. Representação do talhão gerada por nuvem de pontos: vista lateral (A), frontal (B) e superior (C).....	29
Figura 5. Classificação dos pontos do terreno (A); Modelo digital do terreno (B) e Nuvem de pontos normalizada (C).....	30
Figura 6. Modelo digital de superfície (A) e Ortomoisaco (B).....	31
Figura 7. Topos das árvores detectados: Vista frontal (A) e vista superior (B).....	33
Figura 8. Ortomosaico RGB do tratamento analisado indicando as copas das árvores detectadas por um buffer (polígonos contornados em preto), bases das árvores obtidas em campo com RTK (pontos em preto) e topos das árvores detectados na nuvem de pontos normalizada (NPC) (pontos em vermelho).....	34
Figura 9. Gráfico de dispersão das alturas totais observadas (campo) versus estimadas (FAD).....	38

1. INTRODUÇÃO

No Brasil, a área de florestas plantadas tem se expandido em resposta à crescente demanda por produtos florestais. Atualmente, essas florestas são responsáveis por uma produção significativa de 277,3 milhões de metros cúbicos de madeira para fins industriais (IBÁ, 2022). Para garantir o sucesso desse crescimento/expansão, é fundamental implementar um manejo florestal eficiente. O manejo florestal é uma das etapas fundamentais na indústria florestal, contudo, seu sucesso está relacionado a consistência dos dados coletados em campo, por meio do inventário florestal, e da exatidão nas estimativas de estoques de crescimento (BURKHART; TOMÉ, 2012).

O inventário florestal é uma das maneiras de se obter estimativas da produção florestal. Entretanto, os inventários florestais tradicionais (IFT) são onerosos, uma vez que demandam de grande quantidade de tempo e de mão de obra qualificada, principalmente em grandes áreas. Neste contexto, visando reduzir os custos e o tempo na obtenção dos dados acerca dos estoques nos plantios, ferramentas de sensoriamento remoto podem ser utilizadas.

Uma dessas ferramentas é o sensoriamento remoto tridimensional, como o *Light Detection and Ranging* (LiDAR), que possibilita a obtenção de informações com um alto grau de detalhamento, pois o feixe de luz atravessa o dossel e atinge o solo, trazendo informações do perfil vertical da floresta (DALLA CORTE, 2020a; GONÇALVES *et al.*, 2017). Este equipamento possibilita estimar indiretamente alguns atributos da floresta, como a altura total das árvores, o diâmetro e o volume de árvores individuais ou do povoamento. Entretanto, o custo de operação deste equipamento é muito elevado, tornando-o inviável economicamente em pequenas áreas de plantio.

Como alternativa, a Fotogrametria Aérea Digital (FAD), também conhecida como *Digital Aerial Photogrammetry*, tem recebido especial atenção devido ao menor custo operacional em comparação ao LiDAR. Esta é uma técnica de sensoriamento remoto que possibilita a aquisição de informações 3D, por meio de imagens digitais 2D, obtidas por Aeronaves Remotamente Pilotadas (RPA). Assim, é possível utilizá-la junto a outras ferramentas de sensoriamento remoto e também aos Sistemas de Informações Geográficas (SIGs) (TEMBA, 2000).

Devido ao grande potencial, qualidade dos produtos obtidos pelo sensoriamento remoto 3D (LiDAR e FAD) e dos recursos para processamento dos dados, trabalhos focados na identificação de árvores individuais (ITD) tem se tornado cada vez mais comuns (MOHD JAAFAR *et al.*, 2018; ALMEIDA *et al.*, 2021; YU *et al.*, 2011; BORTOLOTTI; WYNNE, 2005; BRANDTBERG, 2007). Entretanto, há uma carência na validação da detecção das árvores com os dados de localização obtidos pelo posicionamento cinemático em tempo real (RTK) ou pela estação total. A detecção das árvores no povoamento é o primeiro passo e um dos mais importantes na obtenção das variáveis dendrométricas por meio da FAD.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

⇒ Avaliar a acurácia da FAD na detecção individual de árvores e estimar suas alturas totais, em um sistema silvipastoril composto por eucalipto e capim marandu, com 60 meses de idade.

1.1.2 Objetivos Específicos

- ⇒ Analisar a acurácia do modelo digital do terreno (MDT) obtido via FAD;
- ⇒ Avaliar a qualidade da detecção de árvores individuais de eucalipto por meio da FAD;
- ⇒ Analisar a acurácia da estimativa da altura total das árvores obtidas pela FAD.

2. REVISÃO DE LITERATURA

2.1 Inventário florestal

Nas atividades florestais e avaliações ambientais referentes aos recursos florestais, o inventário é sempre uma técnica importante, talvez até mesmo imprescindível para se conhecer o potencial dos recursos existentes em uma área (SANQUETA *et al.*, 2009). Inventários florestais são procedimentos que tem como objetivo obter informações sobre a quantidade e a qualidade dos recursos florestais e de muitas características das áreas sobre as quais as árvores estão crescendo (KERSHAW *et al.*, 2017). São importantes ferramentas utilizadas para se avaliar estatisticamente as reais potencialidades e capacidades produtivas dos recursos florestais de determinada área (CUNHA, 2004).

Os inventários florestais podem fornecer muitas informações acerca da quantidade e qualidade dos recursos florestais e também de muitas características da área em que as árvores estão se desenvolvendo (SOARES *et al.*, 2011). Os inventários florestais podem ser classificados em razão dos objetivos, da abrangência, da maneira em que os dados são obtidos, da abordagem da população no tempo e no grau de detalhamento dos resultados (PELLÍCO NETTO; BRENNNA, 1997).

De acordo com o interesse do manejador e as técnicas estatísticas de amostragem, é possível realizar a coleta de dados, que pode ser do tipo censo, em que todos os indivíduos são amostrados e se obtém o parâmetro da população; ou uma amostragem, na qual é medida uma parte da população distribuindo-se as parcelas na área, obtendo-se uma estimativa dos parâmetros da população (CAMPOS; LEITE, 2017).

O procedimento de amostragem é aplicado à maioria dos inventários florestais, visto que as populações geralmente são extensas e de difícil acesso (SANQUETTA *et al.*, 2009). Entretanto, mesmo utilizando-se o processo de amostragem, há um alto custo de execução e uma demanda elevada de tempo na coleta de dados, principalmente na medição de altura e cubagem rigorosa, o que pode não corresponder à velocidade necessária na obtenção de resultados para a tomada de decisão por parte de empresas e órgãos públicos (KERSHAW JR. *et al.*, 2017; SANQUETTA *et al.*, 2014).

Todavia, os inventários florestais são complexos, onerosos e dispendiosos (SANQUETA *et al.*, 2014; ZHAO *et al.* 2019). Dessa forma, existe uma crescente demanda em melhorar a qualidade e a agilidade na obtenção de informações sobre os povoamentos florestais, logo, novas técnicas vêm sendo empregadas no inventário florestal (BARROS, 2015). Dentre essas técnicas está o sensoriamento remoto passivo por meio de dados multiespectrais (REIS, 2018), o escaneamento a laser aerotransportado (*Airbone Laser Scanning – ALS*) (DALLA CORTE *et al.*, 2020a) e a fotogrametria aérea digital (*Digital aerial Photogrammetry*) (GOODBODY *et al.*, 2019).

2.2 Sensoriamento remoto

O sensoriamento remoto (SR) é a utilização conjunta de sensores e equipamentos para processamento e transmissão de dados colocados a bordo de plataformas como aeronaves e satélites, com a intenção de estudar a superfície terrestre com base no registro e na análise das interações entre a radiação eletromagnética (REM) e as substâncias que as compõe (FIGUEIREDO, 2005). Diferentes sensores operam em diferentes regiões do espectro eletromagnético e, dependendo de sua estrutura, o sensor capta dados de uma ou mais regiões do espectro (FLORENZANO, 2002). Dessa forma, o SR permite a aquisição de medidas nas quais o ser humano não é parte fundamental do processo de detecção e registro dos dados (FLORENZANO, 2011).

Segundo Novo (2010), o SR pode ser dividido em dois subsistemas para a aquisição de informações, o de coleta de dados e o de produção de informações. O subsistema de coleta de dados é formado pela fonte de radiação, a plataforma (satélite, aeronave), o sensor e o centro de dados (estação de recepção e processamento de dados de satélite e aeronave). Já o subsistema de análise de dados é composto por: pré-processamento (correções radiométricas e geométricas); processamento de realce (filtros e manipulações de histogramas); fotointerpretação; interpretação automática e modelagem.

O SR pode ser dividido em ativo e passivo, que se diferem quanto à sua fonte de REM (MORAES, 2002). Sensores passivos, como a FAD, dependem de fontes externas

de REM e detectam a radiação refletida ou emitida por um objeto, como nos sistemas imageadores. Já os sensores ativos, emitem sua própria radiação e medem o retorno da mesma após ser modificada pelos objetos, como nos lasers e radares (NOVO, 2010).

Assim como qualquer atividade, a obtenção dos dados por SR também requer o uso de energia. A energia que os sensores remotos operam pode ser proveniente de uma fonte natural, como a luz do sol e o calor emitido pela superfície da Terra; ou pode ser proveniente de uma fonte artificial como a do *flash* usado em uma câmera fotográfica e o sinal produzido por um radar. Os sistemas de SR são conjuntos compostos de plataformas e sensores que captam essa REM emitida e/ou refletida pelos objetivos da superfície terrestre (FORMAGGIO; SANCHES, 2017).

Segundo Formaggio e Sanches (2017), em tempos passados, o SR era realizado com base em dados de câmeras, dependentes da existência de filmes fotográficos. Entretanto, em meados do século XX, surgiram os satélites que não dependiam dos filmes fotográficos e podiam ter maior número de bandas espectrais. Enquanto a tecnologia das câmeras fotográficas pode ser chamada de pancromática, a tecnologia dos imageadores corresponde a multiespectral. Os mesmos autores relatam que em 1980, houve uma evolução da tecnologia multiespectral, que possibilitou os imageadores de obter imagens em centenas de bandas estreitas, os denominados sensores hiperespectrais.

Nos últimos anos, as ferramentas de SR avançaram consideravelmente devido ao desenvolvimento de sensores mais potentes, capazes de gerar imagens com melhores resoluções, associadas às técnicas de extração de informações provenientes do processamento de imagens (RIBEIRO *et al.*, 2019). Em virtude disso, o SR pode ser aplicado a diversas áreas do conhecimento, bem como o levantamento de recursos ambientais, geologia, agricultura, estudos urbanos, análise ambiental e outros (CARVALHO, 2021). Lechner *et al.* (2020) afirmam que o SR tem sido usado com a finalidade de mapear a distribuição dos ecossistemas florestais, as flutuações globais na produtividade das plantas com as mudanças nas estações do ano, e a estrutura tridimensional das florestas.

No campo das ciências florestais, o SR contribui para quantificar recursos e monitorar as florestas, servindo de base no processo de tomada de decisões (SOUZA *et*

al., 2007). Tais avanços tecnológicos em relação as imagens originadas dos sensores remotos em conjunto com o avanço no processamento das imagens, possibilitam a caracterização da estrutura das florestas e a associação entre os dados coletados com o local de refletância originados das imagens de satélite (WAGNER, 2013). Segundo Boyd e Danson (2005), utilizar técnicas de SR é um método indireto e não destrutivo para estimar os parâmetros biofísicos das florestas, demonstrando um grande potencial para monitorar ou detectar as mudanças na cobertura florestal sobre áreas geográficas grandes.

A utilização de algoritmos de visão computacional automatizada, como o *Structure from Motion*, permite um avanço significativo na observação tridimensional e multiespectral das copas das árvores. Isso é especialmente importante para o SR, pois esses algoritmos são de fácil utilização e as RPAs reduziram as dificuldades relacionadas aos traços estruturais e espectrais de cores da vegetação (DANDOIS *et al.*, 2017; ANDERSON; GASTON, 2013). O LiDAR também é uma tecnologia de varredura a laser utilizada no SR, que utiliza o laser emitido para mensurar um objeto ou ambiente, que é refletido pela superfície e retorna ao receptor, disponibilizando informações de intensidade de retorno, distância e ângulos. Possibilitando, a partir dessas informações, mensurar uma série de variáveis dentro de diversas áreas (DUBAYAH; DRAKE, 2000). Essa forma de SR possibilita observações sob demanda e de alta resolução da vegetação para estimar a estrutura do dossel, a biomassa, a fenologia (DANDOIS; ELLIS, 2013), a estrutura de árvores isoladas (MORGENROTH; GOMEZ, 2014) e outras diversas aplicações.

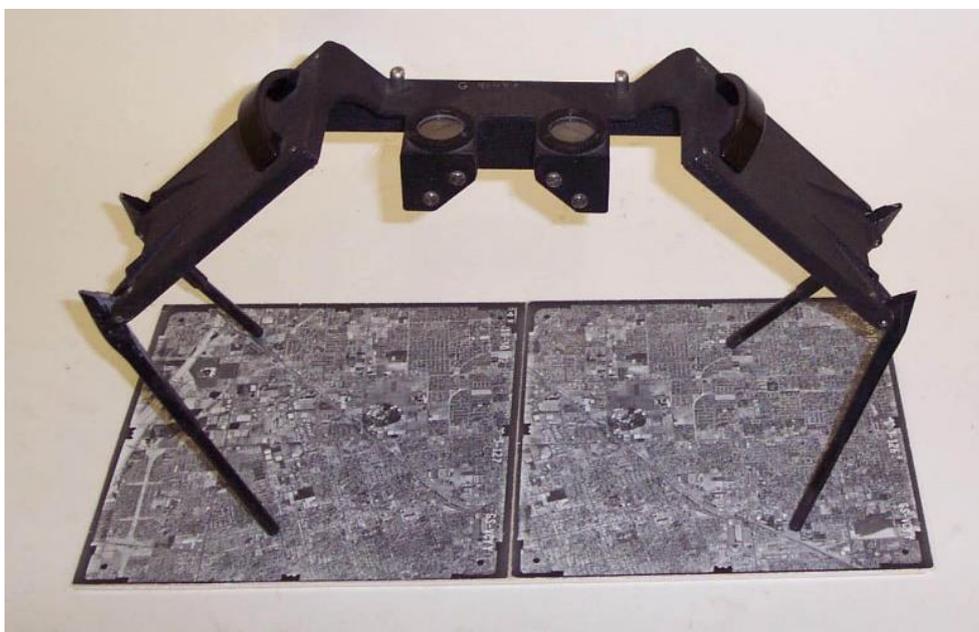
2.3 Fotogrametria Aérea Digital

A *American Society of Photogrammetry* - ASP (1996) conceitua a fotogrametria como:

“Fotogrametria é a arte, ciência e tecnologia de obter informações de confiança sobre objetos e do meio ambiente com o uso de processos de registro, medição e interpretação de imagens fotográficas e padrões de energia eletromagnética radiante e outras fontes”

No início, as imagens eram obtidas por meio de câmeras a bordo de aeronaves e posteriormente analisadas por um equipamento chamado estereoscópio (Figura 1). Este equipamento é composto por dois eixos ópticos posicionados paralelamente sobre um par estereoscópico e simula o que ocorre biologicamente para dar uma noção de profundidade na visão humana. Cada eixo ótico incide de forma direta em um mesmo ponto de cada uma das fotografias, dessa forma, os nervos óticos conduzem a um só ponto do cérebro as imagens do ponto e ocorre uma sensação de profundidade da imagem, ou seja, uma percepção tridimensional (DURRIEU *et al.*, 2015).

Figura 1 - Estereoscópio sobre par de fotos.



Fonte: USGS Museum Staff, U.S. Geological Survey.

A fotogrametria possibilita uma percepção tridimensional dos objetos a partir de duas imagens planas de uma mesma cena, tomadas de posições diferentes, chamadas de pares estereoscópicos (WOLF *et al.*, 2014). Por meio de softwares é possível alinhar as imagens de forma tridimensional, a partir da detecção de sobreposição de pontos, sendo possível determinar a posição e orientação da câmera em relação ao objeto, permitindo realizar a triangulação do objeto pelas nuvens de pontos ou malha tridimensional (ALENCASTRO *et al.*, 2019).

A sobreposição desses pares é calculada em relação a porcentagem da dimensão da fotografia, nos sentidos lateral e longitudinal, sendo que a lateral é aquela entre as

linhas de voo e funcionam como margem de segurança para evitar lacunas entre as linhas; e a longitudinal é aquela entre fotos sucessivas na linha de voo que permite a visualização 3D e a restituição estereoscópica (GRANSHAW, 2016; REDWEIK, 2007). Para que se tenha uma cobertura completa da área de estudo, é recomendado realizar um planejamento de voo adequado, assegurando que haja sobreposição suficiente para a modelagem do terreno (GRANSHAW, 2016). Além disso, recomenda-se que se tenha pelo menos 60% de sobreposição longitudinal e 30% de sobreposição lateral para garantir o recobrimento total da área e alcançar a percepção estereoscópica (REDWEIK, 2007; WOLF *et al.*, 2014).

A fotogrametria pode ser classificada de acordo com o método de obtenção das fotografias, sendo dividida em: fotogrametria aérea, em que as fotografias são tiradas a partir de uma câmera acoplada a um veículo aéreo; fotogrametria terrestre, em que as fotografias são obtidas a partir de um ponto fixo no solo; fotogrametria espacial, que abrange todos os casos de fotografias ou imagens capturas fora da Terra, como satélites ou sondas espaciais, seguidas de medições subsequentes; e fotogrametria a curta distância, que envolve a captura de imagens de objetos próximos à câmera, presumindo-se uma proximidade entre a câmera e o objeto a ser fotografado (TOMMASELLI *et al.*, 1999).

Além das classificações mencionadas, a fotogrametria também pode ser dividida em de acordo com o grau de participação dos equipamentos na medição e redução dos dados. Essas categorias são: fotogrametria analógica, na qual eram utilizados equipamentos analógicos devido à ausência de computadores; fotogrametria analítica, que permitiu uma redução significativa da participação dos equipamentos no processo fotogramétrico devido à incorporação dos computadores possibilitando a aplicação de modelos matemáticos mais avançados; fotogrametria digital, que trouxe consigo a redução da participação dos equipamentos apenas na etapa de digitalização das fotografias por meio de scanners. No entanto, com advento das câmeras digitais modernas e o uso de computadores poderosos, a fase instrumental foi praticamente eliminada (TOMMASELLI, 2009).

De acordo com Goodbody *et al.* (2019), algoritmos computacionais foram criados para simular uma percepção tridimensional das características da floresta em

ambiente virtual por meio de operações matemáticas que utilizam a posição e o ângulo de obtenção das imagens (pares estereoscópicos), esses algoritmos são chamados de *Structure from Motion* (SfM). Além disso, nesse processamento são encontrados *pixels* análogos em todas as fotos da área para se produzir uma nuvem de pontos, esse procedimento é denominado *Digital Aerial Photogrammetry*, traduzido como Fotogrametria Aérea Digital (FAD). A FAD utiliza de princípios da estereoscopia similar a fotogrametria clássica e, quando aliados a técnica de processamento computacional SfM, possibilitam a geração de uma nuvem de pontos tridimensional similar às nuvens de pontos obtidas pelo LiDAR. A principal diferença entre a nuvem de pontos da FAD e do LiDAR, é que o LiDAR possibilita a obtenção de informações do solo até o topo das árvores, permitindo a geração de um modelo digital do terreno (MDT) em diversos tipos de floresta. Enquanto isso, a FAD tem sua nuvem de pontos obtida pelas fotografias, e suas informações se limitam as copas das árvores, já que o tipo de radiação eletromagnética não penetra no dossel da floresta (GOODBODY *et al.*, 2019, WHITE *et al.*, 2016).

A FAD é uma tecnologia que permite gerar informações geométricas, radiométricas e de semântica sobre objetos 3D (tridimensional), a partir de imagens 2D (planas) (TEMBA, 2000; HEIPKE, 1995). Durante o processamento das imagens, o software realiza o alinhamento tridimensional das imagens capturadas com base na detecção de sobreposições e pontos equivalentes, determinando, dessa maneira, a posição e orientação da câmera relativa ao objeto fotografado (ALENCASTRO *et al.*, 2019). Assim, é possível utilizá-la junto a outras ferramentas de sensoriamento remoto e também ao Sistemas de Informações Geográficas (SIGs), uma vez que a fotogrametria digital fornece a acurácia e a integridade métrica necessários para edificação de suas estruturas (TEMBA, 2000).

A FAD pode ser aplicada a diversas áreas e possui uma série de vantagens sobre os processos direto de medição, como a rápida aquisição dos dados; o objeto medido não precisa ser tocado, pode-se medir a qualquer momento e quantas vezes se desejar; a precisão pode ser aumentada de acordo com as necessidades de cada projeto; os movimentos e deformações podem ser medidos, além de diversas outras vantagens (TOMMASELLI, 2009). A nível de floresta, a FAD pode ser aplicada na detecção de

árvores e estimativas de altura, diâmetro de copa, volume, tanto para árvores individuais quanto a nível de parcela (ALMEIDA, 2020; DANDOIS; ELIS, 2013; GIANNETTI *et al.*, 2017).

Apesar do grande potencial, esta técnica pode apresentar limitações em áreas com vegetação em estágio avançado, podendo comprometer seus resultados. Geralmente, nos modelos digitais de terreno obtidos, ocorre a superestimação da elevação da floresta, conseqüentemente, levando a subestimação das alturas das árvores. Isso ocorre devido a sua limitação de penetrar no dossel da floresta e descrever o perfil vertical da mesma com detalhes, uma vez que a capacidade de visualizar o perfil vertical depende do tipo de vegetação, idade, estrutura do dossel, espaçamento, características do terreno e outras variáveis (ALMEIDA *et al.*, 2021; SWINFIELD *et al.*, 2019; YU *et al.*, 2011).

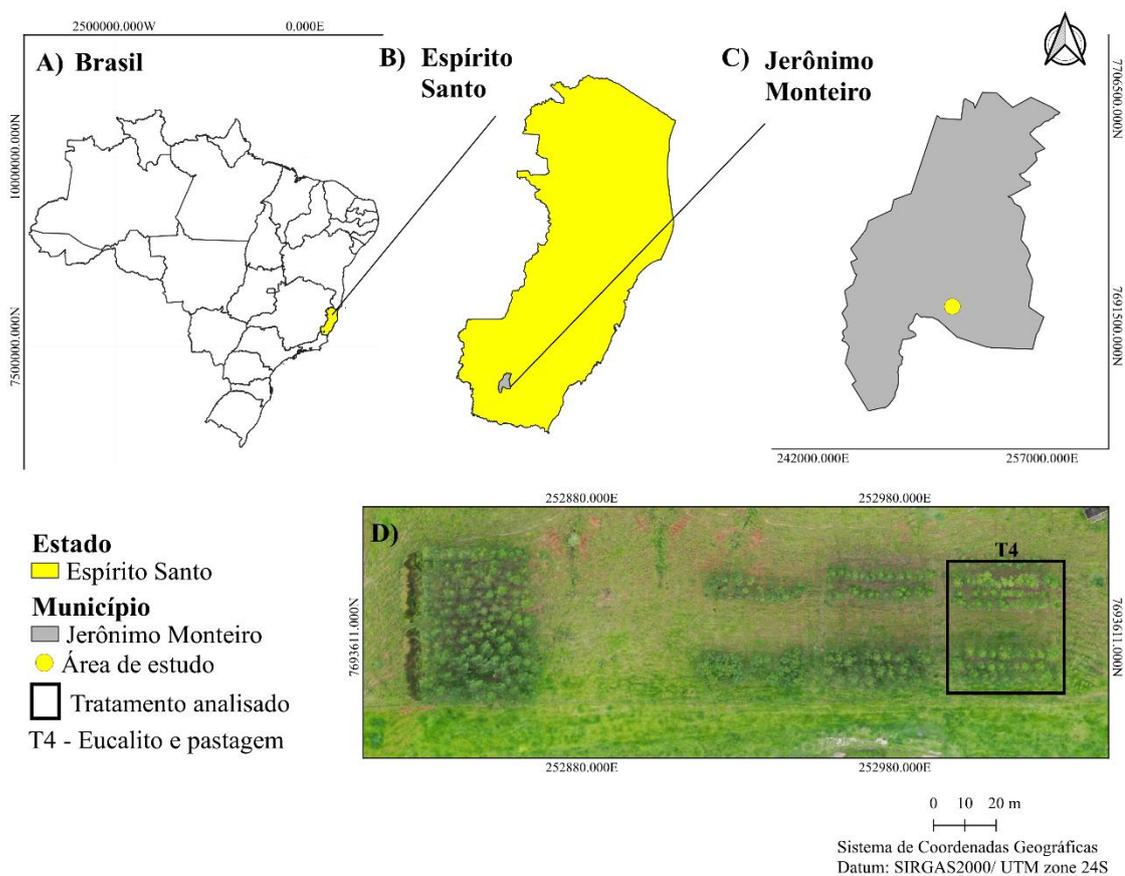
Outro fator importante é que a FAD depende da SfM utilizada, a densidade do ponto e a classificação da nuvem de pontos 3D. Uma vez que os pontos do terreno são classificados, podem ser interpolados para gerar um MDT. Assim, é possível estimar as características da vegetação a partir dos produtos obtidos pelo sensoriamento remoto 3D e os dados coletos em campo, utilizando, para isto, a abordagem de detecção de árvores individuais (ITD) (ALMEIDA *et al.*, 2021). Nessa abordagem, cada árvore é considerada uma unidade de análise, e as estimativas derivadas de suas características são determinadas por métricas extraídas da nuvem de pontos de cada árvore identificada (MOHD JAAFAR *et al.*, 2018).

3. METODOLOGIA

3.1 Área de estudo

A área de estudo está localizada no município de Jerônimo Monteiro, ES, nas coordenadas centrais aproximadas de latitude 20° 50' 26.999" S e longitude 41° 22' 21.99" O, e altitude variando de 120 a 147 m (Figura 2). O clima tipo "Cwa", apresentando inverno seco e verão chuvoso, com temperatura média anual de 23,1 °C e precipitação média anual de 1.341 mm (CAIADO; SILVA, 2011). O solo da região é caracterizado como Latossolo Vermelho-Amarelo Distrófico (SILVA *et al.*, 2021).

Figura 2 - Brasil (A), Estado Espírito Santo (B), Município Jerônimo Monteiro (C) e Área de estudo (D).



Fonte: A autora (2023).

Em dezembro de 2017, foram implantados diferentes modelos de sistemas silvipastoris, conduzidos sob delineamento em blocos casualizados (Tabela 1). Os modelos de sistemas implantados foram: T1) Monocultivo de capim marandu (*Urochloa brizantha* cv. marandu); T2) Monocultivo de eucalipto (híbrido de *Eucalyptus grandis* x *Eucalyptus urophylla*); T3) Sistema silvipastoril de capim marandu e eucalipto; T4) Sistema silvipastoril com capim marandu, eucalipto e leucena (*Leucaena leucocephala*) e T5) Sistema silvipastoril com capim marandu e araribá (*Centrolobium tomentosum* Guillemim ex Benth.). Entretanto, após uma visita na área em dezembro de 2022, observou-se que devido ao clima e a um intenso ataque de formigas, as espécies arbóreas restantes foram somente eucalipto e araribá.

As mudas de eucalipto foram plantadas em dois grupos de três fileiras, sob espaçamento de 3 m x 2 m, onde foram distanciados por uma faixa de 17 m entre si coberta por capim marandu, totalizando 633 árvores/ha. Cada parcela possui área de 1.750 m² (50 m x 35 m), para cada tratamento. Neste estudo, foi analisado o tratamento quatro (T4) do bloco II, composto por um total de 90 árvores.

Tabela 1 - Descrição dos blocos implantados na área de estudo

Bloco	Encosta	Orientação	Inclinação(°)
I	Norte	345	16
II	Sul	180	22
III	Sudoeste	208	22
IV	Nordeste	45	17,5

Fonte: Firmino (2020).

3.2 Coleta de dados

3.2.1 Inventário florestal tradicional – IFT

Um censo das 90 árvores no tratamento quatro (T4), do bloco II, foi realizado em dezembro de 2022, mês em que as árvores completaram 60 meses de idade. Neste inventário foram coletados os seguintes dados: número de árvores, diâmetro a 1,30 m do solo (*D*), altura total (*H*) e a localização de todas as árvores. O *D* das árvores foi

medido com auxílio da fita diamétrica. Para a medição de H das árvores, utilizou-se o clinômetro suunto. Além disso, um Trimble® R8s Integrate GNSS System com receptor cinemático em tempo real (RTK) de dupla frequência (TRIMBLE, SUNNYVALE, CA, EUA) (<https://geospatial.trimble.com>) foi utilizado para a coleta da localização de cada árvore. As coordenadas da base das árvores (X_{RTK} , Y_{RTK} e Z_{RTK}) foram registradas seguindo a projeção UTM (zona 24S), com o Datum SIRGAS2000.

3.2.2 Inventário florestal aprimorado com a FAD

No dia 14 de dezembro de 2022 (15h no horário local) foi realizado o sobrevoo na área de estudo utilizando-se uma RPA, modelo MAVIC 2 PRO, que possui sensor de 1" CMOS de 20 milhões de pixels (Figura 3) (DJI, 2021). Para abranger toda a área de forma mais segura e precisa, o voo com a RPA foi planejado por meio do aplicativo *DroneDeploy*, com as seguintes configurações padrões: sobreposição frontal e lateral de 85%, sobrevoando a área à 120 m de altura utilizando o método *visual line of sight* (VLOS), conforme determinado pelas normas brasileiras de pilotagem de Veículo aéreo não tripulado (VANT) (<https://www.anac.gov.br>).

As condições meteorológicas não eram tão favoráveis para o voo, pois estava nublado com cobertura de nuvens 100%, vento de 12 km/h e 2% de probabilidade de precipitação. Dandois *et al.* (2015), sugere que os levantamentos aéreos sejam realizados quando a velocidade do vento for inferior a 8 m/s.

Figura 3 - Aeronave remotamente pilotada modelo MAVIC 2 PRO utilizada no sobrevoo da área de estudo.



Fonte: DJI.

3.3 Processamento das imagens

3.3.1. Structure from Motion – SfM

O processamento da SfM foi realizado utilizando o software *Agisoft Metashape Professional Edition 1.6*. Para o alinhamento das 63 fotografias, o parâmetro de precisão foi definido como “Highest”, com pré-seleção dos pares como “generic”, limites de 40.000 “key-points” e 7.000 “tie points”. Quatro pontos de controle foram utilizados para georreferenciar as fotografias aéreas e três pontos de validação foram utilizados para determinar a precisão da localização. Esses pontos foram distribuídos de forma aleatória pelo talhão e medidos pelo sistema RTK, seguido da projeção UTM (zona 24S) com Datum SIRGAS2000. Para criar a nuvem densa de pontos do T4, os parâmetros foram definidos como “Ultra high” para a qualidade e “Mild” para o modo de filtragem de profundidade, e ao final do processamento foram exportadas no formato LAS.

3.3.2 Modelo digital do terreno e normalização da nuvem de pontos

Para gerar o modelo digital do terreno, foi utilizada a função *rasterize_terrain*, que utiliza o algoritmo de classificação *Adaptive Triangulate Irregular Network* (TIN), disponível no pacote lidR (ROUSSEL; GOODBODY; TOMPALSKI, 2022) da linguagem de programação R (R CORE TEAM, 2019). Esse algoritmo segrega a nuvem de pontos em grades retangulares e, em cada célula, o ponto mais baixo na nuvem de pontos é detectado e triangulado para produzir o primeiro TIN.

Feito isso, os demais pontos são classificados em relação à distância linear à face do triângulo mais próximo e ao ângulo formado com os vértices das faces triangulares iniciais TIN. Os pontos são classificados como terreno quando a distância e o ângulo formados forem menores que o estabelecido pelo usuário. Esse processo é repetido até que não haja mais pontos a serem verificados (ALMEIDA *et al.*, 2021).

A fim de compensar os efeitos do terreno, a nuvem de pontos passou por um processo de normalização, que forneceu uma linha de base de elevação, deixando-a plana. Dessa forma, todas as elevações são relativas à superfície do solo. A normalização foi feita subtraindo as elevações do terreno no MDT das elevações de cada ponto dentro da nuvem de pontos.

3.3.3 Modelo digital de superfície e modelo de altura do dossel

O modelo digital de superfície (MDS) e o modelo de altura do dossel (CHM) são camadas raster que representam a maior elevação obtida. Como a nuvem de pontos foi normalizada, a superfície derivada representa a altura do dossel, sendo assim, é referida como CHM. O algoritmo *point-to-raster* (p2r) consiste em estabelecer uma grade de resolução definida e atribuir a elevação do ponto mais alto a cada pixel. Neste estudo utilizou-se o algoritmo p2r e o tamanho do pixel como 0,15.

3.3.4 Detecção de copa das árvores

A detecção individual de árvores (ITD) é a etapa de localizar as árvores espacialmente e, posteriormente, extrair informações de altura. Sendo assim, o topo das árvores e suas alturas totais (H) foram identificadas em cada nuvem de pontos normalizada (NPC) utilizando o algoritmo *Local Maximum Filter*, por meio das funções *lmf* e *Locate_trees*, implementado no pacote *lidR* (ROUSSEL; GOODBODY; TOMPALSKI, 2022). O número de árvores detectadas é correlacionado ao argumento *Windows sizes* (WS) utilizado, sendo assim, WS menores geralmente favorecem maior quantidade de árvores, enquanto WS maiores podem não detectar árvores menores que porventura estão escondidas por árvores grandes. O WS utilizado neste estudo foi de 1,5 (pequeno), para que maior quantidade de árvores fossem detectadas. Para validar a etapa da detecção das árvores, um mapa das copas das árvores foi gerado por meio de um ortomosaico RGB da área de estudo.

3.4 Avaliação dos resultados da FAD

3.4.1 MDT

A fim de avaliar a qualidade do MDT gerado a partir da nuvem de pontos, foram utilizadas as medições de elevação obtidas em campo pelo sistema RTK. Assim, os valores observados (RTK) e os estimados (FAD) puderam ser validados por meio das estatísticas de desempenho: o coeficiente de correlação de Person (r) (1), a raiz do quadrado médio do erro (RMSE) (2) e (3) e viés (V) (4) e (5). Além disso, foram obtidas as estatísticas descritivas: média, mínimo, máximo e desvio padrão das diferenças.

$$r = \frac{\Sigma(X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\Sigma(x_i - \bar{x})^2(\Sigma(Y_i - \bar{Y})^2)}} \quad (1)$$

$$RMSE = \sqrt{\frac{\Sigma_i^n(Y_i - \hat{Y}_i)^2}{n}} \quad (2)$$

$$RMSE(\%) = \left(\frac{RMSE}{\bar{Y}}\right) * 100 \quad (3)$$

$$V = \frac{\Sigma_i^n(Y_i - \hat{Y}_i)}{n} \quad (4)$$

$$V(\%) = \left(\frac{V}{\bar{Y}}\right) * 100 \quad (5)$$

Em que: X_i = valor observado da variável independente; \bar{X} = média dos valores observados da variável independente; Y_i = valor observado da variável dependente; \hat{Y}_i = valor estimado da variável dependente; \bar{Y} = média dos valores observados da variável dependente.

3.4.2 Detecção do topo da copa das árvores

A precisão da detecção do topo da copa das árvores foi avaliada calculando-se a porcentagem das árvores detectadas corretamente (D_c) e os erros de omissão relativa (E_o) e comissão (E_c) conforme Almeida *et al.* (2021):

$$D_c = \frac{N_d}{N_o} \quad (6)$$

$$E_o = \frac{N_{nd}}{N_o} \quad (7)$$

$$E_c = \frac{N_{id}}{N_o} \quad (8)$$

Em que: N_d é o número de árvores detectadas corretamente, N_{nd} é o número de árvores não detectadas, N_{id} é o número de árvores detectadas onde não havia árvores no campo (detectadas incorretamente) e N_o é o número de árvores observadas no campo.

Por meio da ferramenta de geoprocessamento do software de código aberto Qgis denominada “buffer”, que considerou a camada com as coordenadas posicionais (X , Y_{RTK}), foi gerado um polígono circular de $1,5 \text{ m}^2$, que delimitou a área da copa das árvores. Dessa maneira, uma copa foi considerada corretamente detectada quando o algoritmo LMF a colocou dentro do polígono que representa a árvore em questão. Contudo, se mais de uma árvore foi colocada dentro do polígono de copa, o ponto mais próximo da localização no campo foi considerado para o cálculo de D_c .

3.4.3 Altura das árvores

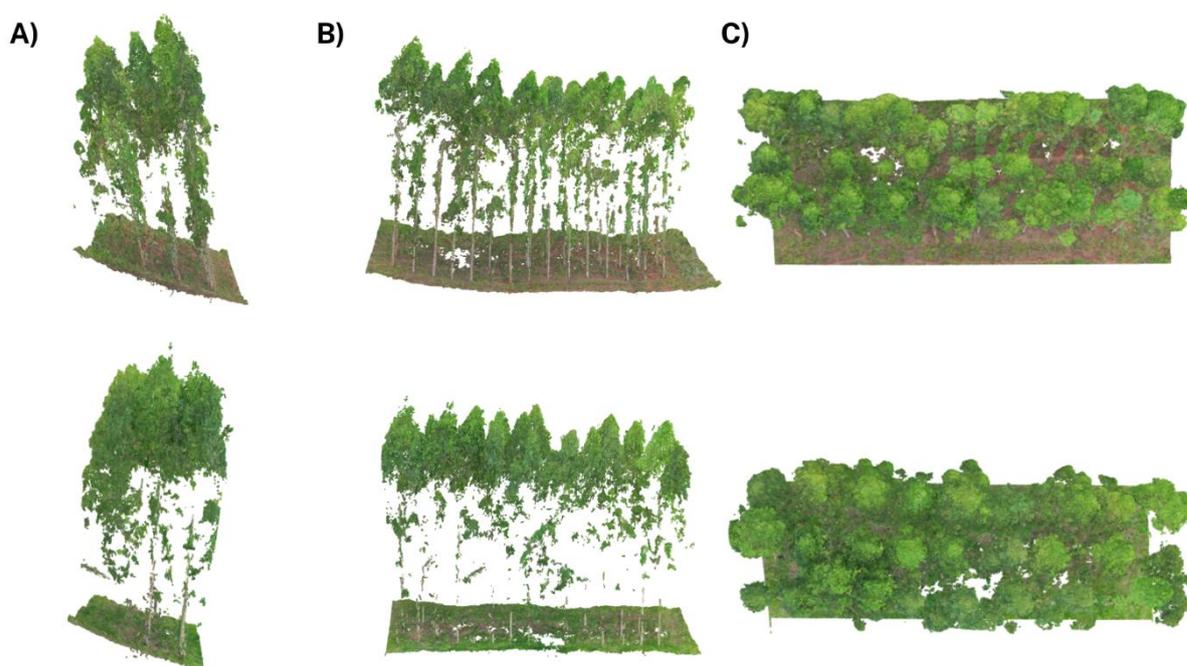
Por meio da ferramenta de processamento do software de código aberto Qgis denominada “interseção”, foi possível criar uma nova camada apenas com as árvores em comum obtidas na FAD e medidas em campo, de modo que a árvore 1 da FAD fosse a mesma árvore 1 medida em campo. As alturas foram identificadas automaticamente em cada NPC (H_{FAD}) e comparadas com as respectivas alturas medidas em campo (H_{campo}). A acurácia das estimativas das alturas por meio da FAD foi avaliada utilizando as estatísticas de desempenho: raiz do quadrado médio das diferenças (RQMD) e viés. Além disso, um gráfico de dispersão foi utilizado para avaliar as alturas totais obtidas, a fim de mostrar a relação de H_{FAD} e H_{campo} .

4. RESULTADOS E DISCUSSÃO

4.1 Processamento da nuvem de pontos pelo algoritmo SfM e avaliação do MDT

Após o processamento das imagens aéreas, foi possível obter uma nuvem de pontos 3D referente ao tratamento quatro, do bloco II (Figura 4).

Figura 4 - Representação do talhão gerada por nuvem de pontos: vista lateral (A), frontal (B) e superior (C).

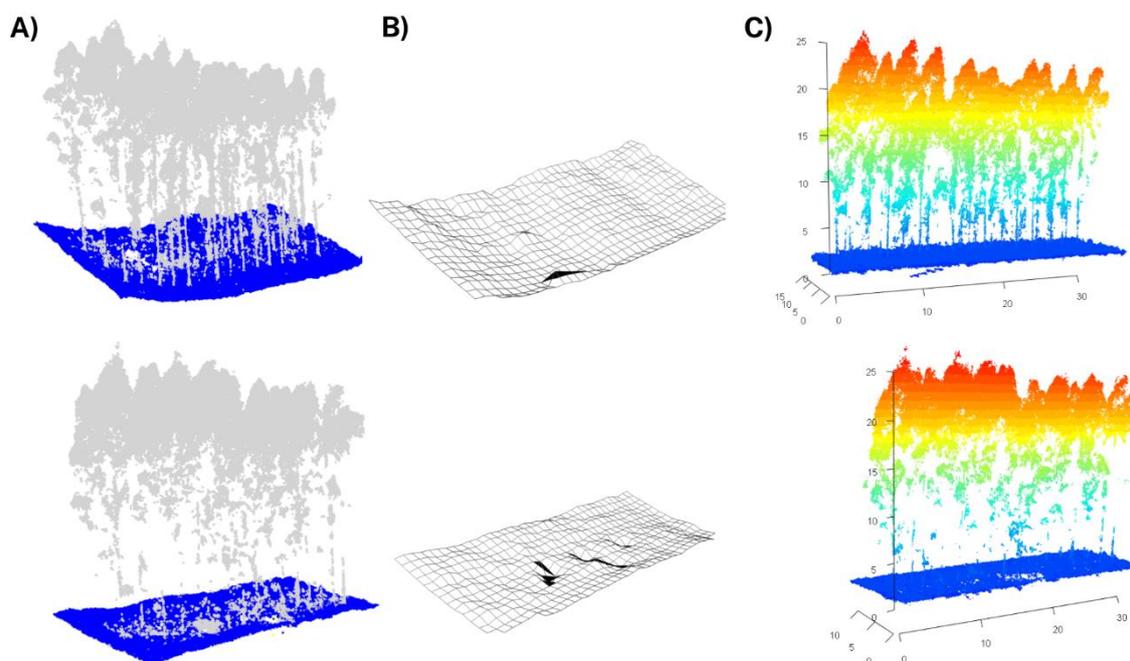


Alguns pontos não foram reconstruídos, deixando falhas no local, isso pode ocorrer pois a fotogrametria, comumente, apresenta limitações para modelar o terreno sob a vegetação (ALMEIDA *et al.* 2021), sobretudo em condições de vegetação densa. A SfM utilizada na fotogrametria, apresenta baixa penetrabilidade no nível do solo, uma vez que as aberturas do dossel são muito pequenas: a) para permitir uma iluminação equivalente do solo e do dossel, resultando em uma subexposição das imagens; b) para ser visto a partir dos ângulos oblíquos necessários para a triangulação posicional (DANDOIS *et al.*, 2017; SWINFIELD *et al.*, 2019). Segundo Swinfield *et al.* (2019), apesar da escassez de pontos no solo obtidos com a fotogrametria, pode ser possível

corrigir as estimativas de posição do solo por meio de modelos que usam as propriedades do MDS para prever uma subestimação do MDT e, também, uma subestimação da altura das árvores. Contudo, isso só é possível se os vieses forem consistentes e previsíveis.

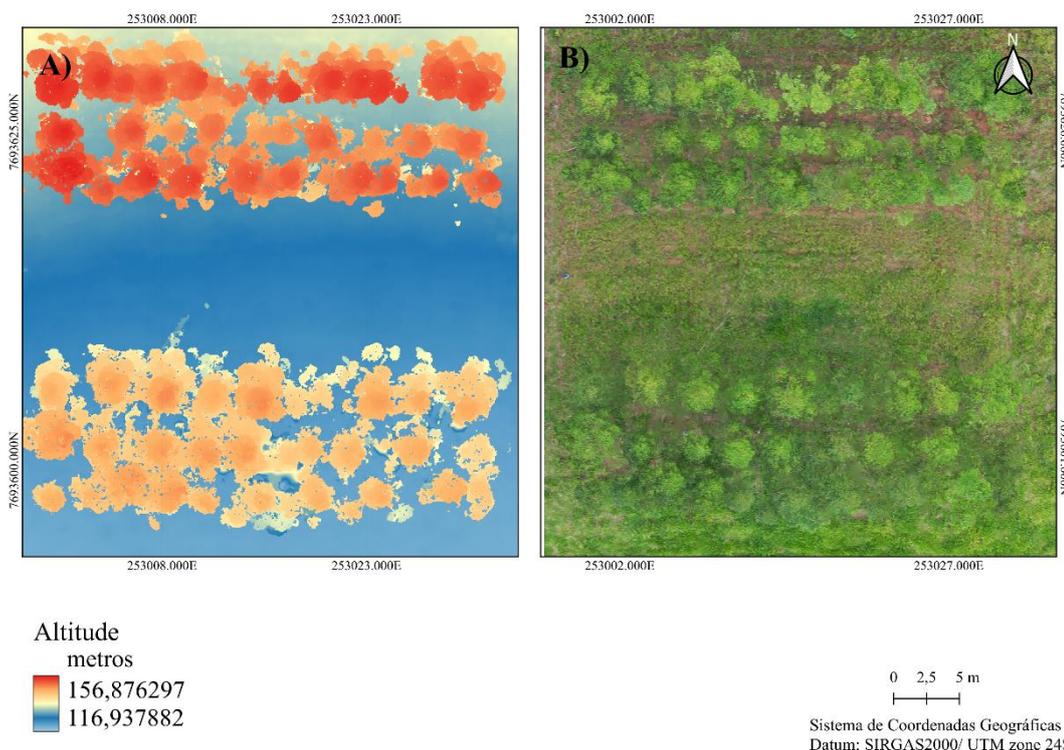
Entretanto, apesar das falhas na nuvem de pontos e da limitação da FAD em modelar o terreno em áreas com florestas, as configurações de voo, as características do plantio e do relevo da área, assim como o algoritmo de classificação utilizado, possibilitaram a construção do MDT de forma adequada. A Figura 5B mostra que o algoritmo de classificação conseguiu representar de forma satisfatória o relevo da área de estudo. No trabalho de Carvalho (2021), também foi possível observar resultados satisfatórios na modelagem do terreno utilizando o mesmo algoritmo de classificação, mostrando ainda, que o MDT gerado pela FAD apresentou maior detalhamento quando comparado com o MDT gerado por dados do *Shuttle Radar Topography Mission* (SRTM).

Figura 5 - Classificação dos pontos do terreno (A); Modelo digital do terreno (B) e Nuvem de pontos normalizada (C).



A partir da nuvem de pontos 3D, além do MDT, foi possível gerar o MDS e o ortomosaico da área de estudo (Figura 6A e 6B, respectivamente), que foram exportados em formato .tif, com resolução espacial de 0,029 m.

Figura 6 - Modelo digital de superfície (A) e Ortomoisaco (B).



As altitudes obtidas via FAD (Z_{FAD}) foram comparadas com as altitudes obtidas em campo pelo sistema RTK (Z_{RTK} , $n = 74$), a fim de validar o MDT gerado.

Tabela 2 - Estatísticas descritivas e de desempenho para altitudes coletadas em campo (Z_{RTK} , $n = 74$) e as estimadas (Z_{FAD}).

Estatística	Borda	Interior	Geral
Diferença mínima (m)	-0,19	-0,08	-0,19
Diferença máxima (m)	0,79	1,22	1,22
Diferença média (m)	0,31	0,86	0,82
Desvio padrão (m)	0,38	0,30	0,34
r	1,00	0,99	0,99
RMSE (m)	0,22 (0,17%)	0,82 (0,64%)	0,78 (0,61%)
Viés (m)	0,31 (0,24%)	0,86 (0,67%)	0,82 (0,64%)

Observa-se que MDT_{RTK} e o MDT_{FAD} obtiveram desempenho semelhante, apresentando valores de altitude próximos. Os valores da borda do plantio foram os pontos de controle coletados (PC) e, quando as altitudes Z_{RTK} e Z_{FAD} foram comparadas,

observou-se que a diferença média foi de apenas 31 cm. Enquanto isso, os valores do interior do plantio foram as posições de cada árvore do tratamento, apresentando diferença média de 85,7 cm. As variáveis Z_{RTK} e Z_{FAD} possuem uma forte correlação linear, como mostra o coeficiente de correlação de Person (r). Esses valores são considerados baixos quando comparados a outros métodos de obtenção de coordenadas posicionais, como o *Global Positioning System* – GPS, confirmando a precisão do sistema RTK em localizar as árvores e os PC, e posteriormente validando o MDT com diferenças de altitude menores que um metro.

Algoritmos de classificação do solo que seguem um processo de divisão de nuvens de pontos em células de grade, como a que foi utilizada neste estudo, identificando os pontos mais baixos do terreno e adicionando pontos adjacentes sempre irão apresentar um viés positivo em relação a sua estimativa da posição do solo (MENG *et al.*, 2010; SWINFIELD *et al.*, 2019). Contudo, observa-se que, apesar do viés positivo apresentado nos três casos (borda, interior e geral – Tabela 1), os valores encontrados ($V < 1\%$) mostram que as estimativas do MDT se mostraram não viesadas.

Cunliffe, Brazier & Anderson (2016), relatam que a distância máxima e o ângulo máximo utilizados nos parâmetros do algoritmo dependem do grau de variação topográfica dentro de cada célula; sendo que a distância máxima representa a variação máxima permitida em Z dentro de qualquer célula, portanto, depende da topografia e do tamanho da célula. Dessa forma, recomenda-se que diferentes ângulos e distâncias sejam testados, a fim de melhorar a qualidade da Identificação de árvore individual (ITD) e do MDT gerado, visto que diferentes ângulos de visão podem aumentar a possibilidade de penetrar nos dosséis e ver o solo, facilitando a identificação dos pontos-chave e dos pontos homólogos no alinhamento das imagens.

4.2 Avaliação da detecção do topo das árvores

Por meio da nuvem de pontos normalizada foram detectados os topos das árvores e suas respectivas alturas (Figura 7). A Figura 8 exibe o ortomosaico do povoamento, indicando a localização das bases das árvores (X , Y_{RTK}) obtidas em campo e seus topos detectados automaticamente utilizando a NPC.

Figura 7 - Topos das árvores detectados: Vista frontal (A) e vista superior (B).

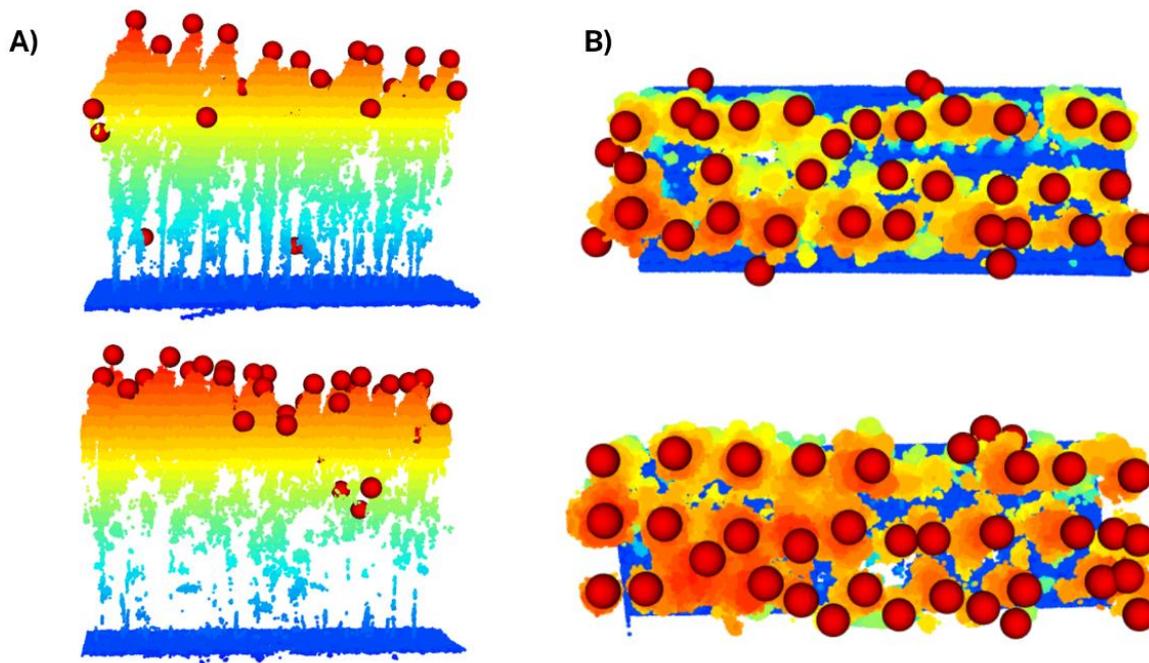


Figura 8 - Ortomosaico RGB do tratamento analisado indicando as copas das árvores (polígonos contornados em preto), bases das árvores obtidas em campo com RTK (pontos em preto) e topos das árvores detectados na nuvem de pontos normalizada (NPC) (pontos em vermelho).



Os algoritmos empregados neste estudo foram capazes de identificar a copa das árvores (X , Y_{FAD}) na parcela estudada com 68,8% de precisão (Tabela 3). Almeida *et al.* (2021) encontraram valores de 97,6% de precisão em um plantio de eucalipto jovem, com 1,5 anos, e mesmo espaçamento (3 m x 2 m). Yu *et al.* (2011) encontraram um valor médio de 69% de árvores detectadas automaticamente utilizando laser, em 69 parcelas de uma floresta boreal manejada, no sul da Finlândia, e mostrou que a precisão na detecção diminuiu à medida em que a densidade de fustes aumentou. Portanto, o

resultado encontrado é coerente com a idade do povoamento analisado, visto que as copas das árvores já se encontram mais adensadas do que as do trabalho de Almeida *et al.* (2021), dificultando a detecção devido a sobreposição de copa.

Tabela 3 - Métricas de detecção de copa das árvores.

Métricas	Valor
D _c (%)	68,8
E _o (%)	31,1
E _c (%)	8,8
Duplicadas (Qtd)	1

Em que: D_c = árvores detectadas corretamente; E_o = erro de omissão; E_c = erro de comissão.

Além disso, a etapa de detecção também foi avaliada estatisticamente por meio dos valores das coordenadas posicionais (X, Y_{RTK}) de cada árvore e as coordenadas estimadas de suas copas (X, Y_{FAD}) para o tratamento analisado. Pode-se observar que o erro foi menor que um metro, ao comparar as coordenadas posicionais e as estimadas pelas copas das árvores, sendo considerado baixo (Tabela 4). Os valores de V% encontrados mostram que as estimativas das coordenadas não se mostraram viesadas. A qualidade do processo de identificação de copa das árvores foi sustentada pelo baixo valor de RMSE encontrado (< 0,001%) observado entre coordenadas de posição estimadas e medidas (Tabela 4). No trabalho de Yu *et al.* (2011), os autores mostraram que a taxa de detecção para as árvores maiores foi significativamente melhor do que para as árvores menores. Foram encontrados os valores de 0,03 m para X e 0,05 m Y para diferenças médias na localização das árvores utilizando o laser.

Tabela 4 - Estatísticas para as diferenças entre as coordenadas posicionais (X, Y_{RTK}) e coordenadas estimadas (X, Y_{FAD}).

Estatística	X, Y
Diferença mínima (m)	-2,09
Diferença máxima (m)	1,59
Diferença média (m)	0,06
Desvio padrão (m)	0,72

r	0,99
RMSE (m)	0,12 (0.000024%)
Viés (m)	0,06 (-0.0000065%)

4.3 Avaliação das alturas das árvores

Os produtos obtidos pela FAD possibilitaram estimar as alturas das árvores de forma esperada. De acordo com Swinfield *et al.* (2019), o viés positivo para o MDT sempre irá resultar em um viés negativo para as alturas. O viés encontrado nesse estudo mostra que houve uma tendência a superestimação nas alturas das árvores, mesmo com um baixo valor de viés para as altitudes e com a nuvem de pontos normalizada.

Tabela 5 - Estatísticas de desempenho para as estimativas de altura total pela FAD.

Estatística	Valor
RQMD	0,76 (3,87%)
Viés	-3,97 (-20,24%)

Apesar do resultado desse estudo ter mostrado uma tendência a superestimação da altura total das árvores, resultados de subestimação das alturas foram encontrados em alguns trabalhos, como o de Swinfield *et al.* (2019), que apresentou um viés negativo de -4,66 m e RMSE de 5,08 m ou 39%, utilizando a SfM para estimar a altura do dossel e a densidade de carbono acima do solo, em uma floresta tropical da Indonésia. Esses mesmos autores mostram que apesar da dificuldade da SfM na detecção pontos de solo em florestas densas, o algoritmo é eficaz em reconstruir superfícies 3D e, juntamente com a previsibilidade na subestimação da altura do dossel, é possível corrigir esse viés. Almeida *et al.* encontrou uma tendência para subestimação das alturas das árvores ($V < 0,3$ e $RMSE < 0,43$ ou 13%). Guerra-Hernández *et al.* também observou uma subestimação dos valores de altura das árvores ($V = 2,67$ m e $RMSE = 2,84$ m).

Não há evidências de que o MDT gerado seja responsável pela superestimativa das alturas totais das árvores (H_{FAD}), pois a estimação deste não foi encontrado evidência de estimativas viesadas do terreno. Incertezas relacionadas a H_{campo} , como falta de

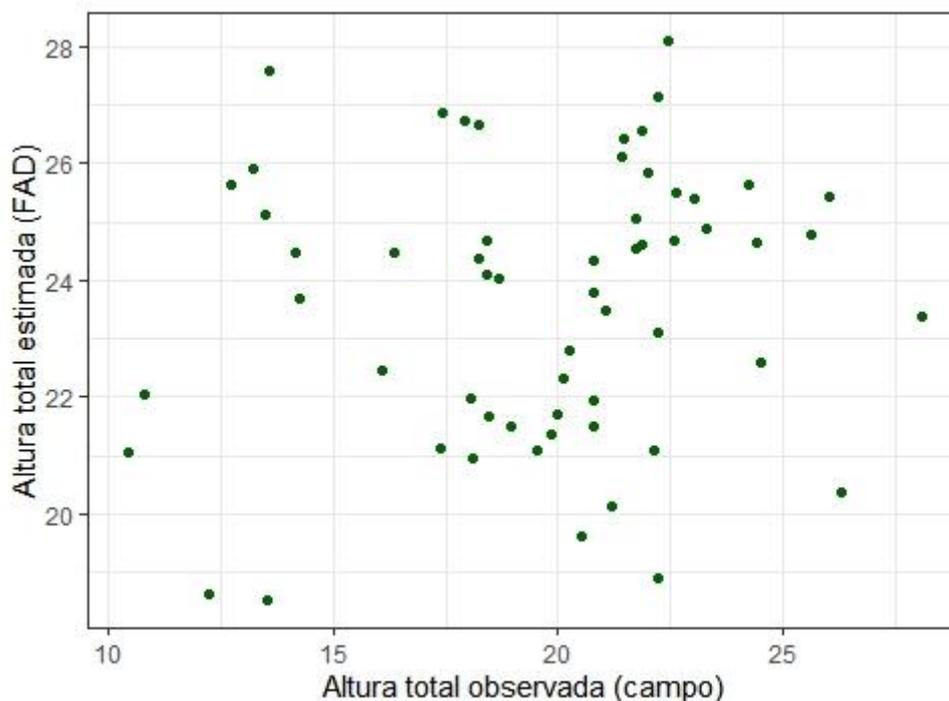
acurácia dos equipamentos utilizados, incertezas na medição das árvores por parte do observador, influências físicas ou topográficas do terreno e outras, podem ser descartadas como fonte de erro.

A superestimação de H_{FAD} provavelmente está relacionada às dificuldades em reconstruir a parte superior das copas das árvores utilizando a FAD. Apesar dos atributos de cor natural das nuvens de pontos derivadas da SfM facilitarem a interpretação visual, essa é uma tecnologia passiva de SR que possui uma penetração muito limitada através dos dosséis da vegetação, restringindo o número de pontos no solo sob dosséis da vegetação (DANDOIS & ELLIS, 2010; LISEIN *et al.*, 2013; DANDOIS *et al.*, 2015).

Além disso, a qualidade dos produtos pode ter sido influenciada pelas condições climáticas no dia do voo, principalmente pelo vento, que pode acarretar falhas na identificação dos pontos-chave e pontos homólogos na etapa de alinhamento das imagens. Dandois *et al.* (2015), sugere que os levantamentos aéreos sejam realizados quando a velocidade do vento for inferior a 8 m/s. Entretanto, as condições meteorológicas não eram adequadas para o voo (nublado com cobertura de nuvens 100%, vento de 12 km/h e 2% de probabilidade de precipitação).

A distribuição dos valores observados em campo *versus* valores da FAD (Figura 9) não apresentou uma dispersão satisfatória das alturas totais obtidas. Para que um gráfico de dispersão seja satisfatório, é preciso que a população amostrada tenha uma maior variação de altura, dessa forma, todas as classes serão representadas adequadamente.

Figura 9 - Gráfico de dispersão das alturas totais observadas (campo) versus estimadas (FAD).



Além disso, Swinfield *et al.* (2019), afirma que, ao desenvolver modelos que utilizam as propriedades do MDS para prever uma superestimação do MDT e uma subestimação da altura do dossel, é possível aplicar uma correção para que o viés seja removido. Dessa forma, os modelos utilizados pelos autores para ajustar a relação entre as alturas medidas pela SfM e também pelo LiDAR, explicou uma grande proporção da variação ($R^2_{\text{modelo1}} = 79\%$ e $R^2_{\text{modelo2}} = 82\%$) e o resultado apresentou um RMSE substancialmente mais baixo em relação as medidas SfM não corrigidas. Zahawi *et al.* avaliaram a correspondência das medições de altura do dossel (SfM e LiDAR), utilizando apenas RMSE. Contudo, os autores mostram que se a SfM subestima consistentemente as alturas do dossel, essas medições irão conter erros sistemáticos e aleatórios, que devem ser contabilizados de forma separada.

5. CONCLUSÃO

O MDT_{RTK} e o MDT_{FAD} obtiveram desempenhos semelhantes, mostrando valores de altitude próximos quando comparados. Além disso, os algoritmos utilizados no estudo foram capazes de detectar a copa das árvores com 68,7% de precisão e de estimar a altura total das árvores. Contudo, os produtos obtidos pela FAD mostraram uma tendência a superestimação da altura total das árvores. Além disso, o gráfico de dispersão de H_{FAD} versus H_{campo} , não apresentou uma dispersão satisfatória.

A qualidade dos produtos FAD pode ter sido influenciada pelas condições climáticas no dia do voo, dessa forma, recomenda-se que sejam testados outros voos para verificar essa influência do clima. Recomenda-se também que, a fim de corrigir o viés, sejam realizados outros estudos, desenvolvendo modelos que utilizem as propriedades do MDS para prever uma superestimação do MDT e uma subestimação da altura do dossel.

6. REFERÊNCIAS BIBLIOGRÁFICAS

AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL - ANAC. **Gov.br**. Disponível em: <https://www.gov.br/anac/pt-br>. Acesso em: 15 abr. 2023.

AGISOFT METASHAPE. **Agisoft**. Disponível em: <https://www.agisoft.com/>. Acesso em: 07 mar. 2023.

ALENCASTRO, Y. O. *et al.* Ferramentas de digitalização 3D faça-você-mesmo na preservação do patrimônio cultural. **Revista Interações**, v. 20, n. 2, p. 435-448, 2019. Disponível em: <https://doi.org/10.20435/inter.v0i0.1744>. Acesso em: 05 jun. 2023.

ALMEIDA *et al.* Individual tree detection and qualitative inventory of a *Eucalyptus* sp. stand using UAV photogrammetry data. **Remote Sensing**, v. 13, n. 18, p. 3655. 2021. Disponível em: <https://doi.org/10.3390/rs13183655>. Acesso em: 05 jun. 2023.

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. Disponível em: <https://doi.org/10.1890/120150>. Acesso em: 21 jul. 2023.

AXELSSON, P. Processing of laser scanner data: algorithms and applications. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, n. 2-3, p. 138-147, 1999. Disponível em: <https://doi.org/10.1016/S0924-2716%2899%2900008-8>. Acesso em: 03 jul. 2023.

BOYD, D.; DANSON, F. Satellite remote sensing of forest resources: three decades of research development. **Progress in Physical Geography**, v. 29, n. 1, p. 1-26, 2005. Disponível em: <https://doi.org/10.1191/0309133305pp432ra>. Acesso em: 03 jul. 2023.

BORTOLOTT, Z.; WYNNE, R. H. Estimating forest biomass using small footprint LiDAR data: an individual tree-based approach that incorporates training data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 59, n. 7, p. 342-360, 2005. Disponível em: <http://dx.doi.org/10.1016/j.isprsjprs.2005.07.001>. Acesso em: 18 jul. 2023.

BRANDTBERG, T. Classify individual tree species under leaf-off and leaf-on conditions using airborne LiDAR. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 61, n. 5, p. 325-340, 2007. Disponível em: <http://dx.doi.org/10.1016/j.isprsjprs.2006.10.006>. Acesso em: 18 jul. 2023.

BURKHART, H. E.; TOMÉ, M. **Modeling Forest trees and stands**. Springer Science & Business Media. 2012. Disponível em: <https://doi.org/10.1007/978-90-481-3170-9>. Acesso em: 03 jul. 2023.

CAIADO, L. H. L.; SILVA, G. S; GUIMARÃES, M. A P. **PROATER - Programa de assistência técnica e extensão rural de Jerônimo Monteiro - ES (2020-2023)**.

INCAPER, 2011. Disponível em:

https://incaper.es.gov.br/media/incaper/proater/municipios/Jeronimo_Monteiro.pdf.

Acesso em: 05 jul. 2023.

CAMPOS, J. C. C; LEITE, H. G. **Mensuração florestal: perguntas e respostas**. 5. ed., Viçosa: UFV, 2017. p. 636.

CUNHA, U. S. **Dendrometria e inventário florestal**. Série técnica (Curso técnico de manejo florestal) – Escola Agrotécnica Federal de Manaus, Manaus, 2004.

CUNLIFFE, A. M.; BRAZIER, R. E.; ANDERSON, K. Ultra-fine grain landscape-scale quantification of dryland vegetation structure with drone-acquired structure-from-motion photogrammetry. **Remote Sensing and Environment**, v. 183, p. 129-143, 2016.

DALLA CORTE, A. P. *et al.* Measuring individual tree diameter and height using GatorEye High-Density UAV-Lidar in an integrated crop-livestock-forest system.

Remote Sensing, v. 12, n. 5, p. 863, 2020a. Disponível em:

<https://doi.org/10.3390/rs12050863>. Acesso em: 03 jul. 2023.

DANDOIS, J. P.; OLANO, M.; ELLIS, E. C. Optimal altitude, overlap, and weather conditions for computer vision UAV estimates of forest structure. **Remote Sensing**. v. 7, n. 10, p. 13895–13920, 2015. Disponível em: <http://dx.doi.org/10.3390/rs71013895>. Acesso em: 05 jul. 2023.

DANDOIS, J. P., & Ellis, E. C. Remote sensing of vegetation structure using computer vision. **Remote Sensing**, v. 2, n. 4, p. 1157–1176, 2010. Disponível em: <http://dx.doi.org/10.3390/rs2041157>. Acesso em: 03 jul. 2023.

DUBAYAH, R. O.; DRAKE, J. B. LiDAR remote sensing for forestry. **Journal of Forestry**, v. 98, n. 06, p. 44-46, 2000. ISSN 0022-1201.

DURRIEU, S. *et al.* Optical remote sensing of tree and stand heights. *In*: THENKABAIL, P. S., **Remote sensing handbook: Land resources monitoring, modeling, and mapping**, v. 3. p. 449-485, 2015.

FIGUEIREDO, D. **Conceitos básicos de sensoriamento remoto**. Companhia Nacional de Abastecimento - CONAB. Brasília – DF, 2005. Disponível em:

http://www.clickgeo.com.br/wp-content/uploads/2013/04/conceitos_sm.pdf. Acesso em: 21 jul. 2023.

FORMAGGIO, A. R.; SANCHES, I. D. A. **Sensoriamento Remoto em agricultura**. São Paulo: Oficina dos textos, 2017. ISBN 978-85-7975-277-3.

FLORENZANO, T. G. **Imagens de satélite para estudos ambientais**. São Paulo: Oficina dos textos, 2002.

FLORENZANO, T. G. **Iniciação em sensoriamento remoto**. 3. ed. São Paulo: Oficina de textos, 2011.

GIANNETTI, F. *et al.* A new set of DTM-independent metrics for forest growing stock prediction using UAV photogrammetric data. **Remote Sensing of Environment**, v. 213, p. 195–205, 2018. Disponível em: <http://dx.doi.org/10.1016/j.rse.2018.05.016>. Acesso em: 03 jul. 2023.

GOODBODY T. R. H.; COOPS N. C.; WHITE J. C. Digital aerial photogrammetry for updating area-based forest inventories: a review of opportunities, challenges, and future directions. **Remote Sensing**, v. 5, n. 2, p. 55-75, 2019. Disponível em: <https://link.springer.com/article/10.1007/s40725-019-00087-2>. Acesso em: 03 jul. 2023.

GONÇALVES, F. *et al.* Estimating aboveground biomass in tropical forests: field methods and error analysis for the calibration of remote sensing observations. **Remote Sensing**, v. 9, n. 47, p.1-23, 2017. Disponível em: <https://doi.org/10.3390/rs12091498>. Acesso em: 03 jul. 2023.

GRANSHAW, S. I. Photogrammetric terminology: third edition. **Photogrammetric Record**, v. 31, n. 154, p. 210–252, 2016. Disponível em: <https://doi.org/10.1111/phor.12146>. Acesso em: 03 jul. 2023.

GUERRA-HERNÁNDEZ, J. *et al.* Predicting growing stock volume of *Eucalyptus* plantations using 3-D point clouds derived from UAV imagery and ALS data. **Remote Sensing**, v. 10, n. 10, p. 905, 2019. Disponível em: <https://doi.org/10.3390/f10100905>. Acesso em: 05 jul. 2023.

HEIPKE, C. State-of-the-art of digital photogrammetric workstations for topographic. **Photogrammetric Engineering & Remote Sensing**, v. 61, n. 01, p. 49-56, 1995.

IBÁ – Indústria Brasileira de Árvores. **Relatório anual 2022**. Disponível em: <https://iba.org/datafiles/publicacoes/relatorios/relatorio-anual-iba2022-compactado.pdf>. Acesso em: 09 abr. 2023.

KERSHAW, J. A. *et al.* **Forest mensuration**. 5. ed. John Wiley & Sons, Ltd, 2017. p. 630.

LECHNER, A. M.; FOODY, G. M.; BOYD, D. S. Applications in remote sensing to forest ecology and management. **One earth** 2. p. 405, 2020. Disponível em: <https://doi.org/10.1016/j.oneear.2020.05.001>. Acesso em: 03 jul. 2023.

LISEIN, J. *et al.* A photogrammetric workflow for the creation of a forest canopy height model from small unmanned aerial system imagery. **Forest**, v. 4, n. 4, p. 922–944. Disponível em: <https://doi.org/10.3390/f4040922>. Acesso em: 03 jul. 2023.

MCGLONE, J. C. *et al.* Manual of photogrammetry. **American society for photogrammetry and remote sensing**. ed. 5, p. 1220, 1966. Disponível em: <https://www.gbv.de/dms/ilmenau/toc/390307416.PDF>. Acesso em: 05 jun. 2023.

MENG, X; CURRIT, N.; ZHAO, K. Ground filtering algorithms for Airbone LiDAR Data: a review of critical issues. **Remote Sensing**. v. 3 n. 2, p. 833-860, 2010. Disponível em: <https://doi.org/10.3390/rs2030833>. Acesso em: 03 jul. 2023.

MORGENROTH. J.; GOMEZ, C. Assessment of tree structure using a 3D image analysis technique – A proof of concept. **Urban Forestry & Urban Greening**, v 13, n. 1, p. 198-203, 2014. Disponível em: <https://doi.org/10.1016/j.ufug.2013.10.005>. Acesso em: 21 jul. 2023.

MOHD JAAFAR, W. W. S. *et al.* Improving Individual Tree Crown Delineation and Attributes Estimation of Tropical Forests Using Airborne LiDAR Data. **Forests**, 2018, v. 9, n. 12, p. 759. Disponível em <https://doi.org/10.3390/f9120759>. Acesso em: 20 jul. 2023.

MORAES, E. C. Fundamentos do sensoriamento remoto. *In*: RUDORFF, B. F. T. *et al.* **Curso de uso de sensoriamento remoto no estudo do meio ambiente**. São José dos Campos: INPE, 2002. Cap 1, p. 1-22.

NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações**. 2. ed. São Paulo: Edgard Blucher, 2010. p. 388.

PELLICO NETTO, P.; BRENA, D. A. **Inventário Florestal**. Curitiba: Editorado pelos autores, 1997. 2. Ed. v. 1, p. 316. 1997.

REIS, A. A. *et al.* Spatial prediction of basal area and volume in Eucalyptus stands using Landsat TM data: an assessment of prediction methods. **New Zealand Journal of Forestry Science**. v. 48, n. 1, p. 2-17, 2018. Disponível em: <https://nzjforestryscience.springeropen.com/articles/10.1186/s40490-017-0108-0>. Acesso em: 03 jul. 2023.

R CORE TEAM. **R: The R project for statistical computing**. 2019. Disponível em: <https://www.r-project.org/>. Acesso em: 21 jul. 2023.

REDWEIK, P.M. **Fotogrametria aérea**. Departamento de Engenharia Geográfica, Geofísica e Energia: Faculdade de Ciências da Universidade de Lisboa. 2007.

RIBEIRO, H. J., *et al.* Sensoriamento remoto em ecologia da paisagem: estado da arte. **Geociências** (São Paulo), v. 38, n. 1, p. 257-267, 2019.

ROUSSEL, J. R.; GOODBODY, T. R. H.; TOMPALSKI, P. **The lidR package**. 2022. Disponível em: <https://r-lidar.github.io/lidRbook/index.html>. Acesso em: 21 jul. 2023.

SANQUETTA, C. R. *et al.* **Inventários florestais: planejamento e execução**. 3. ed. Curitiba: Multi-Graphic Gráfica e editora, 2014.

SILVA, G. F. *et al.* Avaliação econômica de diferentes modelos de sistemas silvipastoris. In: SILVA, G. F. *et al.* **Sistemas integrados de produção: pesquisa e desenvolvimento de tecnologias**. 1. Ed. Guarujá, São Paulo: Científica digital, 2021, p. 216-252. Disponível em: <https://www.editoracientifica.com.br/livros/livro-sistemas-integrados-de-producao-pesquisa-e-desenvolvimento-de-tecnologias>. Acesso em: 09 mar. 2023.

SOARES, C. P. B. *et al.* **Dendrometria e inventário florestal**. Viçosa: Editora UFV, 2012. 2 ed. p. 129, 2011.

SOUZA, C. C. *et al.* Técnicas de sensoriamento remoto como subsídios aos estudos de florestas implantadas no Brasil – Uma revisão bibliográfica. **Ciência Florestal**, v. 17, n. 4, p. 409-417, 2007. Disponível em: <https://doi.org/10.5902/198050981972>. Acesso em: 03 jul. 2023.

SWINFIELD, T. *et al.* Accurate measurement of tropical forest canopy heights and aboveground carbon using structure from motion. **Remote sensing**, v. 8, n. 11, p. 928, 2019. Disponível em: <https://doi.org/10.3390/rs11080928>. Acesso em: 03 jul. 2023.

TEMBA, P. **Fundamentos da fotogrametria**. Departamento de Cartografia, UFMG. 2000. Disponível em: http://www.faed.udesc.br/arquivos/id_submenu/815/fotogrametria_material_01.pdf . Acesso em: 13 dez. 2022.

TOMMASELLI, A. M. G. **Fotogrametria Básica – Introdução**. 2009. Disponível em: http://www.faed.udesc.br/arquivos/id_submenu/891/introducao_a_fotogrametria.pdf. Acesso em: 18 jul. 2023.

TOMMASELLI, A. M. G *et al.* **Fotogrametria: Aplicações a curta distância**. In: MENEGUETE Jr, M., ALVES, N. FCT 40 anos, Perfil Científico – Educacional, Presidente Prudente, p. 147-159, 1999. Disponível em: https://www.researchgate.net/profile/Mauricio-Galo-2/publication/267035028_FOTOGAMETRIA_aplicacoes_a_curta_distancia/links/544282270cf2a76a3ccb00e7/FOTOGAMETRIA-aplicacoes-a-curta-distancia.pdf. Acesso em: 09 abr. 2023.

WAGNER, A. P. L. **Dinâmica temporal de índices de vegetação no Pampa do Rio Grande do Sul e Uruguai e suas relações com os elementos meteorológicos regionais**. 2013. Tese (Doutorado em Sensoriamento Remoto) - Universidade Federal do Rio Grande do Sul, 2013.

WHITE, J. C. *et al.* Remote sensing technologies for enhancing forest inventories: a review. **Canadian Journal of Remote Sensing**, v. 42, n. 5, p. 619–641, 2016.

WOLF, P. R.; DEWITT, B. A.; WILKINSON, B. E. **Elements of photogrammetry with application in GIS**. New York: McGraw-Hill Education, 2014. ISBN: 9780071761123.

YU, X. *et al.* Predicting individual trees attributes from Airbone laser point clouds based on the randon forests technique. **Photogrammetry and Remote Sensing**, v. 66, n. 1, p. 28-37, 2011. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2010.08.003>. Acesso em: 20 jul. 2023.

ZHAO, M. *et al.* Applications of satellite remote sensing of nighttime light observations: Advances, challenges, and perspectives. **Remote Sensing**, v. 17, n. 11, p. 1971, 2019. Disponível em: <https://doi.org/10.3390/rs11171971>. Acesso em: 23 jul. 2023.

ZAHAWI, R. A. *et al.* Using lightweight unmanned aerial vehicles to monitor tropical forest recovery. **Biological conservation**, Saint Louis, MO, n. 186, p. 287-295, 2015. Disponível em: <http://dx.doi.org/10.1016/j.biocon.2015.03.031>. Acesso em: 3 jul. 2023.