

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO CENTRO DE CIÊNCIAS AGRÁRIAS E ENGENHARIAS PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS

RACHEL CLEMENTE CARVALHO

INVENTÁRIO DE UMA FLORESTA DE PRODUÇÃO COM A UTILIZAÇÃO DE IMAGENS MSI/SENTINEL-2 E FOTOGRAMETRIA AÉREA DIGITAL

RACHEL CLEMENTE CARVALHO

INVENTÁRIO DE UMA FLORESTA DE PRODUÇÃO COM A UTILIZAÇÃO DE IMAGENS MSI/SENTINEL-2 E FOTOGRAMETRIA AÉREA DIGITAL

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias e Engenharias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Mestre em Ciências Florestais na Área de Concentração Ciências Florestais.

Orientador: Prof. Dr. Adriano Ribeiro de

Mendonça

Coorientador: Prof. Dr. André Quintão de

Almeida

INVENTÁRIO DE UMA FLORESTA DE PRODUÇÃO COM A UTILIZAÇÃO DE IMAGENS MSI/SENTINEL-2 E FOTOGRAMETRIA AÉREA DIGITAL

Rachel Clemente Carvalho

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias e Engenharias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Mestre em Ciências Florestais na Área de Concentração Ciências Florestais.

Aprovada em 30 de abril de 2021.

Dr. Fábio Guimarães Gonçalves (Examinador externo)
Canopy Remote Sensing Solutions

Prof. Dr. Gilson Fernandes da Silva (Examinadora interno) Universidade Federal do Espírito Santo

Prof. Dr. André Quintão de Almeida (Coorientador)
Universidade Federal de Sergipe

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

adriano Ribeiro de Mandonça

Ficha catalográfica disponibilizada pelo Sistema Integrado de Bibliotecas - SIBI/UFES e elaborada pelo autor

Carvalho, Rachel Clemente, 1994-

C331i Inventário de uma floresta de produção com a utilização de imagens MSI/Sentinel-2 e fotogrametria aérea digital / Rachel Clemente Carvalho. - 2021.

94 f.: il.

Orientador: Adriano Ribeiro de Mendonça. Coorientador: André Quintão de Almeida. Dissertação (Mestrado em Ciências Florestais) -Universidade Federal do Espírito Santo, Centro de Ciências Agrárias e Engenharias.

1. Florestas - manejo. 2. Redes Neurais. 3. Sensoriamento remoto. 4. Fotogrametria aérea. I. Mendonça, Adriano Ribeiro de. II. Almeida, André Quintão de. III. Universidade Federal do Espírito Santo. Centro de Ciências Agrárias e Engenharias. IV. Título.

CDU: 630

AGRADECIMENTOS

A Deus, por me guiar e permitir chegar até aqui.

Aos meus pais, Maria Geralda e João Dehon, minha irmã Laura, por todo amor, confiança e incentivo durante toda a minha vida.

Ao Jeangelis, pelo companheirismo, paciência, apoio emocional e ajuda no desenvolvimento desse trabalho. Essa vitória também é sua.

À Universidade Federal do Espírito Santo e ao Programa de Pós-Graduação em Ciências Florestais pela oportunidade e acolhimento durante esta etapa.

À CAPES pelo auxílio financeiro durante um ano de mestrado.

Ao meu orientador Adriano Ribeiro de Mendonça, pelos conhecimentos transmitidos, incentivo e paciência.

Ao meu coorientador André Quintão de Almeida, por todo incentivo e apoio na realização desta pesquisa, pela amizade e boas risadas.

Ao professor Gilson Fernandes da Silva, pelos ensinamentos, conselhos e incentivo na minha vida acadêmica e profissional.

Ao Fábio Guimarães Gonçalves, pela disponibilidade e importantes sugestões para a melhoria deste trabalho.

À LD Celulose, pela possibilidade de conciliar o mestrado com as minhas atividades profissionais e pela disponibilização dos dados para a realização desta pesquisa. Agradeço em especial ao Anderson Wantroba e aos amigos da equipe de Planejamento Florestal pelo incentivo durante essa trajetória.

À Dayana Seidel, pela ótima convivência e por sempre me ouvir e incentivar a continuar essa caminhada.

Aos amigos do Laboratório de Mensuração e Manejo Florestal, por todas as risadas e companheirismo durante o mestrado.

Às minhas amigas Gardênia, Keila, Susane e Thaís, por estarem comigo em mais essa etapa da minha vida.

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

RESUMO

CARVALHO, Rachel Clemente. Inventário de uma floresta de produção com a utilização de imagens MSI/Sentinel-2 e fotogrametria aérea digital. 2021. Dissertação (Mestrado em Ciências Florestais) — Universidade Federal do Espírito Santo, Jerônimo Monteiro, ES. Orientador: Prof. Dr. Adriano Ribeiro de Mendonça. Coorientador: Prof. Dr. André Quintão de Almeida.

No setor florestal, o conhecimento da produtividade das florestas é obtido por meio de inventários florestais. Entretanto, as técnicas de amostragem tradicionalmente aplicadas nos inventários florestais possuem uma demanda elevada de tempo e alto custo de execução. Diante disso, é necessário avaliar o uso de técnicas alternativas para a obtenção desses dados, como aplicações de sensoriamento remoto. Nesse contexto, o uso sensoriamento remoto permite a aquisição de dados em extensas áreas de forma rápida e com custo reduzido. Este trabalho teve como objetivo principal estimar atributos de interesse florestal de um plantio comercial de eucalipto por imagem orbital (IO) e fotogrametria aérea digital (FAD) e comparar com os resultados obtidos pelo inventário florestal tradicional. Como objetivo secundário, foi realizada uma avaliação dos produtos da FAD a partir de atributos do plantio coletados no campo. Para o inventário a partir das IO, foram selecionadas bandas espectrais de uma imagem do sensor MSI/Sentinel-2 e calculados diversos índices de vegetação. As bandas individuais e os índices de vegetação foram utilizados como variáveis preditoras para a modelagem. Para a obtenção dos dados de FAD, foi realizado um voo com uma aeronave remotamente pilotada (ARP) para a geração de uma nuvem de pontos tridimensionais pelo algoritmo SfM, e também um modelo digital do terreno (MDT) para a sua normalização. A qualidade do MDT da FAD foi avaliada comparando os valores de altura dominante de cada parcela com as métricas representativas da altura máxima da nuvem de pontos normalizada. Foram extraídas métricas tradicionais baseadas na altura para cada parcela, que foram utilizadas como variáveis preditoras. O processo de estimação da área basal (G) e volume (V) foi realizado por regressão linear múltipla (RLM) e por redes neurais artificiais (RNA). Para a modelagem, foram consideradas três fontes de dados, IO, FAD e a combinação de IO e FAD. Em nível de parcela, para estimar a G a partir de dados de IO e da FAD, os menores valores de *RMSE* na validação ocorreram na modelagem por RNA, sendo de 13,22% e 13,36%, respectivamente. Para a combinação de IO e FAD, a RLM apresentou menor *RMSE* na validação (*RMSE* = 12,46%). O mesmo aconteceu para

o *V*, sendo os menores valores de *RMSE* na validação com dados de IO (15,05%) e FAD (16,58%), obtidos na modelagem por RNA, já para a combinação de IO e FAD, o menor *RMSE* foi obtido pela RLM (14,14%). Ao realizar a modelagem para toda a área, foi possível observar que as RNA apresentaram maior capacidade de generalização, com resultados mais próximos dos obtidos no inventário florestal tradicional para todas as fontes de dados. Todas as médias de *G* e *V* ficaram próximas aos valores obtidos no inventário, tendo no máximo 3,2% de diferença em nível de povoamento. Assim como nos resultados em nível de parcela, a combinação de IO e FAD gerou resultados mais acurados em nível de povoamento, com diferença de 0,3% para a *G* e 0,4% para o *V*, em relação ao inventário. Os resultados obtidos neste estudo indicam que dados de IO e FAD podem ser utilizados para o inventário de *G* e *V* em plantios de eucalipto, com resultados compatíveis com os obtidos no inventário florestal tradicional.

Palavras-chave: Inventário florestal; redes neurais artificiais; sensoriamento remoto 3D; Structure from Motion; Floresta 4.0.

ABSTRACT

CARVALHO, Rachel Clemente. Inventory of a production forest using MSI/Sentinel-2 imagery and digital aerial photogrammetry. 2021. Dissertation (Master's degree in Forest Sciences) – Federal University of Espírito Santo, Jerônimo Monteiro, ES. Advisor: Prof. Dr. Adriano Ribeiro de Mendonça. Co-advisors: Prof. Dr. André Quintão de Almeida.

In the forestry sector, knowledge of forest productivity is obtained through forest inventories. However, the sampling techniques traditionally applied to forest inventories have a high demand for time and high cost of execution. Therefore, it is necessary to evaluate the use of alternative techniques to obtain this data, such as remote sensing applications. In this context, the use of remote sensing allows the acquisition of data in large areas quickly and at a reduced cost. This work had as main objective to estimate attributes of forest interest of a commercial planting of eucalyptus by orbital image (IO) and digital aerial photogrammetry (DAP) and to compare with the results obtained by the traditional forest inventory. As a secondary objective, an evaluation of DAP products was carried out based on planting attributes collected in the field. For the inventory based on the IO, spectral bands of an image from the MSI/Sentinel-2 sensor were selected and various vegetation indices were calculated. The individual bands and the vegetation indexes were used as predictive variables for the modeling. To obtain the DAP data, a flight was performed with an unmanned aerial vehicle (UAV) for the generation of a three-dimensional point cloud by the SfM algorithm and also a digital terrain model (DTM) for its normalization. The quality of FAD's DTM was evaluated by comparing the values of dominant height of each plot with the metrics representative of the maximum height of the normalized point cloud. Traditional height-based metrics were extracted for each plot, which were used as predictor variables. Multiple linear regression (MLR) and artificial neural networks (ANN) performed the basal area (G) and volume (V) estimation process. For the modeling, three data sources were considered, IO, DAP and the combination of IO and DAP. At the plot level, to estimate the G from IO and DAP data, the lowest values of RMSE in the validation occurred in the ANN modeling, being 13.22% and 13.36%, respectively. For the combination of IO and DAP, the MLR presented a lower RMSE in the validation (RMSE = 12.46%). The same happened for V, with the lowest values of RMSE in the validation with data from IO (15.05%) and DAP (16.58%), obtained in

ANN modeling, for the combination of IO and DAP, the lower *RMSE* was obtained by MLR (14.14%). When performing the modeling for the entire area, it was possible to observe that the ANN presented greater capacity for generalization, with results closer to those obtained in the traditional forest inventory for all data sources. All the averages of *G* and *V* were close to the values obtained in the inventory, with a maximum of 3.2% difference. As in the plot level results, the combination of IO and DAP generated more accurate results for the whole area, with a difference of 0.3% for *G* and 0.4% for *V*, in relation to the inventory. The results obtained in this study indicate that IO and DAP data can be used for the inventory of *G* and *V* in eucalyptus plantations, with results compatible with those obtained in the traditional forest inventory.

Keywords: Forest inventory; artificial neural networks; 3D remote sensing; Structure from Motion; Forest 4.0.

SUMÁRIO

1. I	NTRODUÇÃO	11
2. (DBJETIVOS	15
2.1.	Objetivo geral	15
2.2.	Objetivos específicos	15
3. F	REVISÃO DE LITERATURA	16
3.1.	Inventário florestal	16
3.2.	Sensoriamento remoto	17
3.2.1	Índices de vegetação	20
3.2.2	Sensoriamento remoto aplicado aos estudos florestais	23
3.2.3	Fotogrametria aérea digital	25
3.2.4	. Aplicações de fotogrametria aérea digital no inventário florestal	30
4. N	METODOLOGIA	33
4.1.	Descrição da área de estudo	33
4.2.	Inventário florestal	34
4.3.	Imagem orbital multiespectral	37
4.4.	Fotogrametria aérea digital	40
4.4.1	Structure from motion (SfM)	40
4.4.2	Elaboração do modelo digital do terreno (MDT)	41
4.4.3	Métricas tradicionais baseadas na altura	43
4.4.4	. Avaliação dos produtos da Fotogrametria Aérea Digital	45
4.5.	Avaliação e redução dos erros de posicionamento	46
4.6.	Modelagem das variáveis biofísicas	48
4.6.1	Regressão linear múltipla	49
4.6.2	. Redes neurais artificiais	51

4.6.3.	Critérios para a avaliação dos métodos de estimação	52
4.6.4.	Espacialização das variáveis biofísicas	52
5. R	RESULTADOS	53
5.1. model	Processamento da nuvem de pontos pelo algoritmo SfM e elaboração lo digital do terreno	
5.2.	Avaliação dos produtos da Fotogrametria Aérea Digital	56
5.3.	Avaliação do erro de posicionamento das parcelas em campo	58
5.4.	Variáveis selecionadas para os modelos de regressão linear múltipla	59
5.5.	Variáveis selecionadas para a modelagem por redes neurais artificiais	60
5.6.	Parametrização das redes neurais artificiais	63
5.7.	Modelagem das variáveis biofísicas	66
5.7.1.	Modelagem da área basal de povoamentos de eucalipto	66
5.7.2.	Modelagem do volume total de povoamentos de eucalipto	69
5.8.	Espacialização das variáveis biofísicas	71
6. D	DISCUSSÃO	74
6.1.	Relações entre as variáveis preditoras selecionadas e as variáveis resposta	74
6.2.	Métodos de estimação de área basal e volume de povoamentos de eucaligados.	oto
6.3.	Fontes de dados para estimar a área basal e volume de povoamentos	de
eucali	pto	76
7. C	ONCLUSÕES	80
REFE	RÊNCIAS	81

1. INTRODUÇÃO

No Brasil, os plantios florestais de crescimento rápido são responsáveis por 90% de toda matéria prima madeireira para fins industriais, destacando-se os plantios dos gêneros *Eucalyptus* e *Pinus*, espécies exóticas de elevada produtividade e com boa adaptação (IBÁ, 2020). O gênero *Eucalyptus* ocupa 7,59 milhões de hectares no Brasil (IBGE, 2020), e é utilizado na produção de madeira para fibras (celulose, chapas e painéis), serraria, produtos sólidos, bem como biomassa para energia (ALZATE, 2004; IBÁ, 2020; VALVERDE, 2008).

Para a gestão eficiente desses plantios, é determinante a quantificação acurada das florestas, sejam elas para intervenções silviculturais ou exploratórias (GOODBODY et al., 2017; TOMPALSKI et al., 2016). Esta quantificação, geralmente, é realizada por meio de inventários florestais tradicionais (IFT), com base em amostragem em campo. Todavia, os IFT são complexos, onerosos e dispendiosos (FAYAD et al., 2016; KERSHAW JR. et al., 2017; SANQUETTA et al., 2014; WEST, 2015; WHITE et al., 2016; ZHAO et al., 2019). Então, além do uso de técnicas tradicionais de inventário, o uso de dados oriundos de sensoriamento remoto tem despertado interesse de pesquisadores em todo o mundo, o que pode diminuir os custos e o tempo de execução dessa atividade (ALMEIDA et al., 2014; BOLTON et al., 2018; CARVALHO, 2013; GONÇALVES et al., 2017; KANGAS et al., 2018; PEARSE et al., 2018; WITTKE et al., 2019).

Uma das fontes de dados de sensoriamento remoto mais utilizada no meio florestal são as imagens orbitais multiespectrais. Esses sensores fornecem informações sobre os alvos de forma bidimensional, que se relacionam diretamente com parâmetros da estrutura horizontal da floresta, como cobertura do dossel, área basal e densidade do povoamento (ALBA et al., 2017; ASTOLA et al., 2019; VAN GUNST et al., 2016; WALLIS et al., 2019). No entanto, uma de suas limitações é a impossibilidade de aquisição de informações diante de fatores adversos como a presença de nuvens. Outra grande limitação observada nos dados orbitais é a saturação da resposta espectral em florestas com alta produtividade, pois a resposta espectral tende a acompanhar o desenvolvimento da vegetação até certo ponto. Porém, quando a floresta já está madura e possui uma alta produção volumétrica, a

resposta espectral tende a estabilizar não representando de forma significativa o incremento volumétrico (FORKUOR et al., 2020; DJOMO; CHIMI, 2017; ZEIDLER et al., 2012).

Outra técnica muito utilizada no setor é o sensoriamento remoto tridimensional. O *Light Detection and Ranging* (LiDAR) é uma dessas técnicas e permite a obtenção de informações com alto grau de detalhamento, pois o feixe de laser emitido atravessa o dossel e atinge o solo, trazendo informações de todo o perfil vertical da floresta (DALLA CORTE, 2020a; GONÇALVES et al., 2017; WU et al., 2019). Diversos estudos vêm sendo realizados visando a aplicação do LiDAR no setor florestal e apresentam resultados de elevada acurácia (DALLA CORTE et al., 2020a; LEITE et al., 2020; SILVA et al., 2020).

Muitos pesquisadores obtiveram êxito ao utilizar LiDAR para estimar atributos da floresta como a altura e o volume de árvores individuais ou de povoamentos (DALLA CORTE et al., 2020b; LEFSKY et al., 2005; NÆSSET; ØKLAND, 2002; RUIZ et al., 2014; SILVA et al., 2016; SUMNALL; HILL; HINSLEY, 2016). A obtenção de variáveis da estrutura e da composição das florestas como índice de área foliar e cobertura florestal, bem como estratificação vertical e classificação de espécies também são realizadas com acurácia a partir de dados LiDAR (CAO et al., 2016; IOKI et al., 2016; LI et al., 2015; LOPATIN et al., 2016; PASCUAL et al., 2016).

Entretanto, uma das limitações do LiDAR é o seu custo operacional elevado, o que pode inviabilizar a sua aplicação, especialmente em povoamentos menores (BELMONTE et al., 2019). Para contornar este problema, uma tecnologia que vem recebendo cada vez mais atenção é a aquisição de dados tridimensionais de sensoriamento remoto por técnicas de fotogrametria aérea digital (FAD) obtida por aeronaves remotamente pilotadas (ARP), que utilizam instrumentos sensores (câmeras fotográficas) com menores custos quando comparados aos sensores LiDAR (GOODBODY et al., 2019; IGLHAUT et al., 2019; MORALES et al., 2018; REMONDINO et al., 2017; WHITE et al., 2013). A FAD utiliza princípios de estereoscopia similar à fotogrametria clássica que, aliados à técnica de processamento computacional *Structure from Motion* (SfM), permitem gerar uma nuvem de pontos tridimensional similar às nuvens de pontos obtidas pelo LiDAR.

Para a extração das métricas da nuvem de pontos, tanto do LiDAR quanto da FAD, é necessário realizar a normalização da nuvem de pontos. Esse processo

transforma os valores originais de altitude da nuvem de pontos em valores de altura, pela diferença entre a altitude dos pontos da nuvem e do modelo digital do terreno (MDT). A principal diferença entre a nuvem de pontos do LiDAR e da FAD é que a primeira possui informações desde o solo até o topo das árvores. Assim, o LiDAR permite a geração do MDT em qualquer tipo de floresta. Por outro lado, como a nuvem de pontos da FAD é obtida por câmeras fotográficas, suas informações se limitam ao topo das copas das árvores, principalmente em áreas de vegetação densa, já que o tipo de radiação eletromagnética captada não penetra o dossel da floresta (GOODBODY et al., 2019; WHITE et al., 2016).

Normalmente os estudos com FAD utilizam outras fontes de MDT, como o próprio LiDAR, que muitas vezes não são facilmente adquiridos. Embora essa possa ser uma limitação de sua aplicação, é possível obter um bom desempenho da FAD para geração de MDT em florestas abertas e terrenos não declivosos. Utilizando FAD obtida por uma ARP, Almeida et al. (2020) conseguiram estimar com relativa precisão os valores de altitude do terreno e os valores da altura dominante de árvores de um fragmento florestal secundário de Mata Atlântica no estado de Sergipe.

Em florestas mais densas, como plantios de eucalipto, muitas vezes a FAD não consegue captar pontos do solo no interior dos talhões. Entretanto, é possível realizar a modelagem do terreno pela interpolação dos pontos de solo em áreas abertas, como estradas, aceiros e clareiras (ALMEIDA et al., 2020). Entretanto, os MDT gerados a partir da FAD podem superestimar os valores de altitude e, consequentemente, a altura da vegetação é subestimada (DANDOIS et al., 2015; GUERRA-HERNÁNDEZ et al., 2018; SWINFIELD et al. 2019). Nesse sentido, é importante realizar uma análise do MDT para verificar se após a normalização as alturas da nuvem de pontos estão condizentes com as obtidas no IFT.

Assim, as informações obtidas da nuvem de pontos da FAD podem ser usadas para o inventário de parâmetros biofísicos das florestas com baixo custo de aquisição (BARRETT et al., 2016), menor tempo para obtenção dos dados (SALAMÍ et al., 2014; TORRESAN et al., 2017; ZHANG; KOVACS, 2012) e acurácia desejável (ALMEIDA et al., 2020; BOHLIN et al., 2012; GOBAKKEN et al., 2015; PULITI et al., 2017a, PULITI et al., 2017b; RAHLF et al., 2015, RAHLF et al., 2014; WASER et al., 2015).

Dentre as aplicações da FAD na área florestal, estão os mapeamentos e caracterização da tipologia florestal (CUNLIFFE et al., 2016; FU et al., 2021;

FRANKLIN; AHMED, 2017), avaliação de danos causados por incêndios florestais (FERNÁNDEZ-GUISURAGA et al., 2018) e análises de fitossanidade (DASH et al., 2017). Em nível de estrutura da floresta, destaca-se a detecção de árvores individuais e estimativas de altura, diâmetro de copa e volume, tanto para árvore individual como para estimativas por área (DANDOIS; ELLIS, 2013; GIANNETTI et al., 2018; GOODBODY et al., 2017; NAVARRO et al., 2020; PANAGIOTIDIS et al., 2016; ZHANG et al., 2016).

Outro fator a ser considerado, diante das vantagens e limitações das imagens orbitais e da FAD, é a integração dessas duas fontes de dados. Assim, na modelagem seriam consideradas as características fisiológicas das florestas, representadas pela resposta espectral dos povoamentos, e também os atributos da estrutura vertical, obtidos pelas métricas da FAD, o que pode gerar estimativas de maior acurácia.

Diante disso, é evidente que a utilização de dados de sensoriamento remoto permite obter informações mais detalhadas com uma cobertura completa dos plantios e pode reduzir os custos operacionais do inventário florestal, tendo grande potencial para revolucionar a forma como são coletadas informações sobre as florestas.

2. OBJETIVOS

2.1. Objetivo geral

Avaliar o emprego de imagens MSI/Sentinel-2 e fotogrametria aérea digital na estimação de variáveis biofísicas de florestas de *Eucalyptus* spp.

2.2. Objetivos específicos

- Avaliar a qualidade dos produtos da fotogrametria aérea digital obtidos por uma aeronave remotamente pilotada;
- Avaliar o uso de modelos de regressão linear múltipla e redes neurais artificiais para estimar a área basal e o volume de madeira a partir de imagem orbital, fotogrametria aérea digital e a combinação de ambos;
- Comparar os valores de área basal e volume obtidos no inventário florestal tradicional com os estimados pelas diferentes fontes de dados de sensoriamento remoto;
- Selecionar o melhor método de estimação e a melhor fonte de dados para estimar a área basal e o volume para a área de estudo.

3. REVISÃO DE LITERATURA

3.1. Inventário florestal

O inventário florestal é um procedimento que visa a quantificação e qualificação dos estoques florestais, sendo determinante na tomada de decisões a curto, médio e longo prazo (FANKHAUSER et al., 2018; KERSHAW JR. et al., 2017). De acordo com o interesse do manejador e técnicas estatísticas de amostragem, é possível realizar a coleta de dados, que pode ser do tipo censo, na qual são medidos todos os indivíduos e se obtém os parâmetros da população; ou uma amostragem, na qual é medida uma parte representativa da população distribuindo-se parcelas na área, obtendo-se uma estimativa dos parâmetros da população (CAMPOS; LEITE, 2017).

Para aumentar a eficiência e diminuir os esforços de campo e os custos da atividade, a grande maioria dos inventários florestais são realizados por amostragem, de acordo com o objetivo do inventário e a acurácia desejada (GOODBODY et al., 2017; KERSHAW JR. et al., 2017). Na coleta de dados em florestas plantadas, geralmente são mensurados os diâmetros a 1,30 m do solo (*D*) de todas as árvores das parcelas e a altura total de algumas, pois a medição de altura total é um processo dispendioso, que diminui o rendimento das equipes de campo. Para estimar a altura total das demais árvores, é ajustado um modelo hipsométrico, que é a relação entre a altura e o *D*, tendo o *D* como variável preditora (BATISTA et al., 2014).

Para a obtenção do volume individual das árvores geralmente utiliza-se a cubagem rigorosa. Nesse processo, seleciona-se algumas árvores por classe diamétrica, e as mesmas são abatidas e seccionadas em partes menores. Calcula-se o volume de cada parte e, ao final desse processo, o volume total da árvore é obtido a partir do somatório de todas as secções. Para o ajuste volumétrico, são utilizados os dados de *D*, altura total e volume individual provenientes da cubagem rigorosa. De posse do modelo volumétrico, é calculado o volume de todas as árvores da parcela e, posteriormente, extrapola-se o volume para a área total (CAMPOS; LEITE, 2017; KERSHAW JR. et al., 2017; SANQUETTA et al., 2014).

Contudo, mesmo sendo utilizado 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, podendo 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; WHITE et al., 2016).

Diante disso, há uma crescente demanda em melhorar a qualidade e a agilidade na obtenção de informações sobre os povoamentos florestais, e novas técnicas vem sendo integradas ao inventário florestal tradicional (BARROS, 2015). Dentre elas está o sensoriamento remoto passivo por meio de dados multiespectrais (ASTOLA et al., 2019; CHEN et al. 2018; REIS et al., 2018), o escaneamento laser aerotransportado (*Airborne Laser Scanning* – ALS) (DALLA CORTE et al., 2020a; SILVA et al., 2020) e a fotogrametria aérea digital (FAD) (GOODBODY et al., 2019; IGLHAUT et al., 2019; REMONDINO et al., 2017).

3.2. 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 o objetivo de estudar a superfície terrestre com base no registro e na análise das interações entre a radiação eletromagnética (REM) e as substâncias que a compõe (FIGUEIREDO, 2005; NOVO, 2010). O SR permite a aquisição de medidas nas quais o ser humano não é parte essencial do processo de detecção e registro dos dados (FLORENZANO, 2011; MENESES; ALMEIDA, 2012; MORAES, 2002).

De acordo com Novo (2010), para aquisição de informações, o SR pode ser dividido em dois subsistemas, 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 pelas seguintes etapas: pré-processamento (correções radiométricas e

geométricas); processamento de realce (filtros e manipulações de histogramas); fotointerpretação; interpretação automática; e modelagem.

Os sensores convertem a energia proveniente dos objetos em um registro na forma de imagem ou gráfico que permite associar a distribuição da radiância (intensidade), emitância ou retroespalhamento (energia emitida pela superfície de um objeto) com suas propriedades físicas, químicas, biológicas ou geométricas. Ao converter e registrar essa energia, podem ocorrer transformações radiométricas, geométricas e espaciais devido à degradação causada pelo sensor ao sinal de interesse, sendo necessário compreender essas degradações para empregar algoritmos adequados às correções (JENSEN, 2015; NOVO, 2010).

Os sensores remotos podem ser classificados em passivos e ativos, que se diferenciam quanto à sua fonte de REM. Os sensores passivos dependem de fontes externas de REM e detectam a radiação refletida ou emitida por um objeto, como os sistemas imageadores. Já os sensores ativos emitem radiação própria e medem o retorno dessa radiação após ser modificada pelos objetos, como lasers e radares (MORAES, 2002; NOVO, 2010).

Em virtude do desenvolvimento de sensores mais potentes, que proporcionaram ao longo do tempo imagens com resoluções melhores, associadas às técnicas de extração de informações oriundas do processamento de imagens, as ferramentas de SR evoluíram consideravelmente nos últimos anos (RIBEIRO et al., 2019; WAGNER, 2013; WATZLAWICK et al., 2009). Assim, a aplicação do sensoriamento remoto foi ampliada para diversas áreas do conhecimento, como: levantamento de recursos ambientais, geologia, agricultura, estudos urbanos, análise ambiental, entre outros.

De acordo com Meneses e Almeida (2012), toda matéria com temperatura acima de zero absoluto (0°K ou -273°C) emite energia, podendo ser considerada fonte de REM devido às suas oscilações atômicas e moleculares. Há duas teorias que explicam o comportamento da REM: a corpuscular (energia) e a ondulatória (onda). Na teoria corpuscular, a REM transmite energia de um corpo para o outro de forma fixa e discreta, a partir da emissão de um fluxo partículas (fótons) que se movimentam na velocidade da luz.

Na teoria ondulatória, a REM pode ser explicada como uma forma de onda senoidal e harmônica, gerada a partir de perturbações nos campos elétrico e magnético que se propagam repetidamente no vácuo, que é caracterizada por um

 10^8

10⁵ km

10°

10⁴

10 km

104

Rádio

Ondas longas

de Rádio

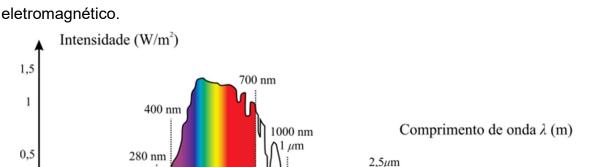
Frequência V (HZ)

comprimento de onda e uma frequência. Partículas carregadas eletricamente geram um campo elétrico em torno de si e, ao se movimentarem, geram um campo magnético.

A onda eletromagnética é o resultado da oscilação dos campos elétrico (E) e magnético (M) segundo um padrão harmônico de ondas e se propaga no vácuo à velocidade da luz (3 x 10⁸ m.s⁻¹). O número de ciclos de onda que passa por um ponto do espaço num determinado intervalo de tempo define a frequência (f) da radiação eletromagnética. O intervalo de tempo relativo à passagem de um ciclo representa o período (T) da onda eletromagnética.

A frequência (f) da onda é diretamente proporcional à velocidade da radiação, que por sua vez é constante para cada meio: quanto maior a velocidade, mais ciclos passariam por um dado ponto num certo intervalo de tempo. Já o período (T) é inversamente proporcional à velocidade de propagação da radiação: quanto maior a velocidade, menor o tempo para a passagem de um ciclo. Uma onda eletromagnética é também caracterizada pelo comprimento de onda (λ), que se relaciona com a frequência (f), o período (T) e a velocidade da onda (c).

As imagens obtidas pelo SR, além da qualidade técnica dos sensores, dependem da intensidade e qualidade irradiante das fontes de REM (MENESES; ALMEIDA, 2012). Os sensores coletam a REM em faixas distintas de comprimentos de onda, conhecidas como bandas espectrais (Figura 1).



1014

4,3 1014

Infravermelho

 10^{-4}

1012

10°2 10°

Microondas

10¹⁰ 10⁸

100μm 1cm 1m

Figura 1 - Comprimentos de onda e frequência nas regiões do espectro eletromagnético

Fonte: Pereira (2019).

10-16

10⁻⁶Å

 10^{24}

Raios

10-10

1Å

Raios X

 10^{18}

Ultra

violeta

1016 7,5 1014

Luz visível

Cada sensor possui uma resolução espectral, que se refere ao número de bandas e faixa de largura de comprimento onda; uma resolução espacial, que indica a mínima área da superfície que é representada, chamada de célula de grade; e uma resolução temporal que se refere ao menor intervalo de tempo que o sensor necessita para capturar repetidamente imagens das mesmas áreas (BETTINGER et al., 2009; CENTENO, 2004).

Ao incidir no topo da atmosfera, parte da REM é refletida ou espalhada pelas partículas presentes na atmosfera e a outra parte atravessa a atmosfera e atinge a superfície. Segundo Cassol (2013), existem três fenômenos físicos básicos resultantes da interação entre a radiação eletromagnética e a superfície vegetal, sendo elas: transmitância (fluxo de radiação transmitido pelo alvo dividido pelo fluxo de REM incidente); reflectância (razão entre o fluxo de radiação refletido pelo alvo dividido pela REM incidente, medida no mesmo instante de tempo); e absortância (razão entre a radiação absorvida pelo alvo e a incidente). Os valores de transmitância, reflectância e absortância variam de 0 a 1 e são adimensionais, de modo que formam um balanço de energia da REM.

3.2.1. Índices de vegetação

Os índices de vegetação são originados de diferentes combinações matemáticas das reflectâncias em diferentes faixas espectrais da REM (LIU, 2006). Para a classificação e monitoramento das florestas com a utilização do sensoriamento remoto, são utilizados índices de vegetação (IV), que permitem o estabelecimento de comparações temporais e espaciais das variações estruturais da vegetação e de alterações das atividades fotossintéticas (LIU, 2006). Os IV se relacionam com as propriedades fisiológicas das folhas e conseguem identificar a vegetação com base no princípio da razão entre bandas, fundamentada nos parâmetros dos aspectos físicos do sensor e no comportamento das reflectâncias espectrais originadas da REM, onde é possível extrair informações dos valores dos pixels da imagem (MENESES; ALMEIDA, 2012). A variação da reflectância da cobertura vegetal em

diferentes bandas de sensores remotos depende, principalmente, da quantidade de folhas e da arquitetura do dossel (d'OLIVEIRA et al., 2007).

A partir da análise dos IV é possível identificar a presença e a ausência de vegetação, avaliar o crescimento das culturas, incidência de fatores como doenças, pragas, incêndios, secas, dentre outros (LIU, 2006). Devido a essa importância, foram desenvolvidos vários IV. O primeiro índice de vegetação desenvolvido foi o índice da razão simples (SR), também conhecido como RATIO (*Ratio Vegetation Index*), utilizado para separar vegetação verde de solo (Equação 1) (JORDAN, 1969).

$$RATIO = \frac{NIR}{R} \tag{1}$$

Em que: NIR = valores de reflectância contidos em bandas do infravermelho próximo; R = valores de reflectância contidos na banda do vermelho.

O NDVI (Normalized Difference Vegetation Index) permite identificar a presença de vegetação verde diferenciá-la do solo exposto, além de caracterizar sua distribuição espacial e suas modificações temporais (ROUSE et al., 1974), sendo o índice mais utilizado em estudos de vegetação. Esse índice se baseia no contraste entre a máxima absorção na região do vermelho devido aos pigmentos da clorofila e à máxima reflexão no infravermelho próximo ocasionada pela estrutura celular das folhas (JENSEN, 2015). O NDVI é obtido de acordo com a Equação 2.

$$NDVI = \frac{NIR - R}{NIR + R} \tag{2}$$

Em que: NIR = banda do infravermelho próximo; R = banda do vermelho.

A partir de então, diversos índices foram desenvolvidos para avaliar outros atributos relacionados à vegetação, dentre eles pode-se citar:

a) SAVI (Soil Adjusted Vegetation Index) (HUETE, 1988) (Equação 3):

$$SAVI = \frac{(NIR - R)}{NIR + R + I}(1 + L) \tag{3}$$

Em que: NIR = banda do infravermelho próximo; R = banda do vermelho; L = fator de correção do solo (usualmente adota-se 0,5).

b) WDVI (Weighted Difference Vegetation Index) (CLEVERS, 1988) (Equação 4):

$$WDVI = NIR - aV \tag{4}$$

Em que: NIR = banda do infravermelho próximo; R = banda do vermelho; a = inclinação da linha de solo.

c) MSAVI (Modified Soil Adjusted Vegetation Index) (QI et al., 1994) (Equação 5):

$$MSAVI = \frac{(NIR - R)(1 + R)}{NIR + R + I}$$
(5)

Em que: NIR = banda do infravermelho próximo; R = banda do vermelho; L = fator de correção do solo (usualmente adota-se 0,5).

d) MSAVI2 (QI et al., 1994) (Equação 6):

$$MSAVI2 = \frac{2NIR + 1 - \sqrt{(2NIR + 1)^2 - 8(NIR - R)}}{2}$$
 (6)

Em que: NIR = banda do infravermelho próximo; R = banda do vermelho; L = fator de correção do solo (usualmente adota-se 0,5).

e) EVI (Enhanced Vegetation Index) (JUSTICE et al.,1998) (Equação 7):

$$EVI = G\frac{(NIR - R)}{(L + NIR + C_1V + C_2A)}$$

$$\tag{7}$$

Em que: NIR = banda do infravermelho próximo; R = banda do vermelho; L = 1 (densidades baixas) fator de correção do solo; C_1V = fator de correção dos efeitos atmosféricos para a banda do vermelho; C_2A = fator de correção para a banda do azul.

f) TVI (Transformed Vegetation Index) (BROGE; LEBLANC, 2000) (Equação 8):

$$TVI = \sqrt{NDVI + 0.5} \tag{8}$$

Em que: NDVI = índice de vegetação da diferença normalizada.

g) GEMI (Global Environment Monitoring Index) (PINTY; VERSTRAETE, 1992) (Equação 9):

$$GEMI = \frac{[2(NIR^2 - R^2) + 1,5NIR + 0,5R]}{NIR + R + 0,5}$$
(9)

Em que: NIR = banda do infravermelho próximo; R = banda do vermelho.

3.2.2. Sensoriamento remoto aplicado aos estudos florestais

No campo das ciências florestais, o sensoriamento remoto contribui na quantificação de recursos e monitoramento das florestas, servindo de base no processo de tomada de decisões (SOUZA et al., 2007). Os avanços tecnológicos em relação às imagens originadas dos sensores remotos em conjunto com o avanço no processamento, permitem a caracterização da estrutura das florestas e a associação entre os dados coletados no local com os dados de reflectância originados das imagens de satélite (WAGNER, 2013; WATZLAWICK et al., 2009).

Os primeiros mapeamentos da cobertura vegetal no Brasil iniciaram na década de 80, mas foi na década de 90 que os estudos passaram a ser mais quantitativos, estabelecendo correlações de parâmetros geofísicos com parâmetros biofísicos (PONZONI; SHIMABUKURO; KUPLICH, 2015). A utilização de técnicas de sensoriamento remoto constitui um método indireto e não destrutivo para estimar parâmetros biofísicos das florestas, demonstrando um grande potencial para monitorar ou detectar mudanças na cobertura florestal sobre grandes áreas geográficas (BOYD; DANSON, 2005; JENSEN, 2015).

De acordo com Boyd e Danson (2005) e Meng et al. (2009), o uso do SR passivo em estudos florestais fornece informações sobre a dinâmica da cobertura florestal; a tipologia florestal e as propriedades biofísicas e bioquímicas da floresta (como índice de área foliar, idade do plantio e área basal), que fornecem informações para o manejo florestal.

Ma et al. (2006) utilizaram dois índices de vegetação (NDVI e SAVI) calculados a partir de dados do sensor TM/Landsat 5 para estimar o índice de sítio em florestas de coníferas do sudoeste da China. Os autores concluíram que os índices de vegetação possuem uma correlação linear com o índice de sítio.

Astola et al. (2019) compararam a performance de dados dos sensores MSI/Sentinel 2 e OLI/Landsat 8 para estimar o volume, diâmetro, altura e a área basal em uma floresta boreal no sul da Finlândia. Os autores concluíram que os dados do sensor MSI/Sentinel 2 apresentaram melhor desempenho para estimar as variáveis de interesse.

Também utilizando dados dos sensores MSI/Sentinel 2 e OLI/Landsat 8, Bar et al. (2020) aplicaram técnicas de inteligência artificial para mapear áreas de incêndios florestais no oeste do Himalaia. Os resultados deste estudo mostraram que a classificação de áreas queimadas a partir de dados do Landsat 8 foi mais acurada, provavelmente em função da melhor resolução radiométrica das bandas. Entretanto, os dados do Sentinel 2 possuem maior potencial para capturar áreas queimadas logo após os incêndios.

Shen et al. (2020) utilizaram dados do sensor Landsat ETM+ para avaliar a dinâmica da biomassa ao longo do tempo em uma floresta urbana localizada em Xangai, de 2005 a 2015. Os autores analisaram 93 parcelas permanentes distribuídas de acordo com classes de idade, *D* e propriedades do solo para verificar a influência dos mesmos e a estimativa da densidade de carbono para estimar a biomassa. Os resultados mostraram que a utilização de dados multiespectrais aliados às variáveis se mostrou satisfatória para mapear os estoques de carbono florestal.

Kowalski et al. (2020) analisaram a fenologia da vegetação em uma floresta na Alemanha utilizando séries temporais combinadas dos sensores MSI/Sentinel-2 e Landsat. Para tanto, os autores utilizaram modelagem por regressão e os índices de vegetação NDVI e EVI. A partir das análises, foi observado que o EVI obteve melhor desempenho, obtendo menor *RMSE* que o NDVI. Foi possível concluir que o uso combinado dos dois sensores foi consistente e viável para analisar o comportamento da vegetação na área de estudo.

Para gerar mapas de biomassa aérea em uma área degradada no estado do Mato Grosso entre os anos de 2000 e 2017, Santos (2018) avaliou a integração entre dados de sensoriamento remoto orbital do sensor Landsat e LiDAR multitemporais. O

autor verificou que essa integração permitiu boas estimativas da biomassa, possibilitando a elaboração de modelos genéricos para aplicação em diferentes datas.

Reis et al. (2018) integraram dados de inventário florestal e sensoriamento remoto com técnicas de *machine learning* para estimar e mapear a área basal e o volume de povoamentos de eucalipto. Os autores utilizaram como variáveis de entrada os índices EVI, GEMI, MSAVI, NDVI e SAVI, obtendo valores de *RMSE* variando de 13,6 a 16,7%.

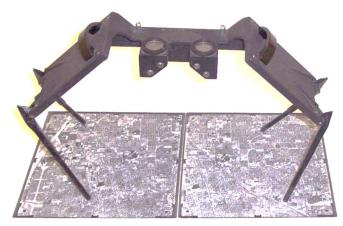
Trabalhando com dados do sensor ETM+/Landsat 7, Santos (2020) avaliou diferentes cenários de redução da intensidade amostral do inventário para modelar o crescimento e a produção de povoamentos de eucalipto. A metodologia proposta pelo autor permitiu uma redução na intensidade amostral do inventário, mantendo valores satisfatórios de acurácia, com diferença de até 3,69% quando comparados com os dados coletados em campo.

3.2.3. Fotogrametria aérea digital

O termo fotogrametria deriva das palavras gregas *photos*, que significa luz, *gramma*, que significa algo desenhado ou escrito e *metron*, que significa medir. Possibilita a obtenção de informações sobre objetos físicos e o meio ambiente por meio de processos de gravação, medição e interpretação de imagens fotográficas e padrões de energia eletromagnética radiante e outras fontes (COELHO; BRITO, 2007).

No início da fotogrametria, as imagens eram obtidas por câmeras a bordo de aeronaves e analisadas analogicamente por meio do estereoscópio (Figura 2). Esse equipamento é composto por dois eixos ópticos posicionados paralelamente sobre um par estereoscópico e simula o que ocorre biologicamente para dar noção de profundidade na visão humana. Cada eixo ótico incide diretamente em um mesmo ponto de cada uma das fotografias. Nesse momento, os nervos óticos conduzem a um só ponto do cérebro as imagens do respectivo ponto e, imediatamente há a sensação de profundidade de imagem, conduzindo uma percepção tridimensional (DURRIEU et al., 2015).

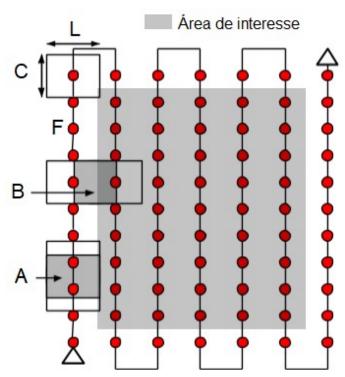
Figura 2 – Estereoscópio sobre par de fotos.



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

A fotogrametria permite 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). A sobreposição dos pares estereoscópicos é calculada em relação à percentagem da dimensão da fotografia, nos sentidos longitudinal e lateral. A sobreposição longitudinal é aquela entre fotos sucessivas na linha de voo que permite a visualização tridimensional e a restituição estereoscópica. Já a sobreposição lateral é realizada entre linhas de voo que funciona como margem de segurança para evitar lacunas entre as linhas de voo (Figura 3) (GRANSHAW, 2016; REDWEIK, 2007).

Figura 3 – Representação de um levantamento fotogramétrico, em que: A é a sobreposição longitudinal; B é a sobreposição lateral; F é o ponto onde se captura a imagem; C é o comprimento da imagem; e L é a largura da imagem.

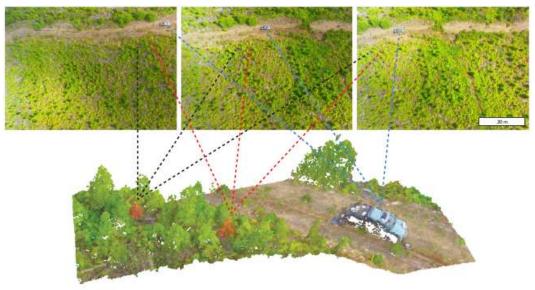


Fonte: PIX4D (2015) adaptado pela autora.

Para efetuar a cobertura completa da área de interesse, deve-se realizar um planejamento adequado de voo assegurando que haja sobreposição suficiente para a modelagem do terreno (GRANSHAW, 2016). É recomendado que haja pelo menos 60% de sobreposição longitudinal e 30% de sobreposição lateral ou entre faixas, para garantir o recobrimento total da área e alcançar a percepção estereoscópica (MIKHAIL et al., 2001; REDWEIK, 2007; WOLF et al., 2014).

Existem algoritmos computacionais capazes de simular essa percepção tridimensional em ambiente virtual por meio de operações matemáticas utilizando a posição e o ângulo de obtenção das imagens (pares estereoscópicos). Esses algoritmos são chamados de *Structure from Motion* (SfM). Nesse processamento são encontrados *pixels* análogos em todas as fotos da área a fim de se produzir uma nuvem tridimensional de pontos (Figura 4). Esse procedimento é denominado *Digital Aerial Photogrammetry*, traduzido como fotogrametria aérea digital (FAD) (GOODBODY et al., 2019).

Figura 4 – Exemplo de visualização simplificada de como as nuvens de pontos da FAD são geradas a partir de pares de imagens estereoscópicas.



Fonte: Goodbody et al. (2019).

O desenvolvimento de técnicas de processamento computacional permitiu a extração de nuvens de pontos das imagens, similares às nuvens de pontos tridimensionais obtidas por procedimentos como o *Light Detection and Ranging* (LiDAR), porém restritas à superfície da copa das árvores, principalmente em áreas de vegetação densa, já que o tipo de radiação eletromagnética utilizada não penetra o dossel (DURRIEU et al., 2015; WHITE et al., 2016). Apesar disso, as nuvens de pontos provenientes das imagens podem ser utilizadas para geração de modelo digital de superfície (MDS), que pode ser normalizado em um modelo de altura do dossel (MAD), desde que haja um modelo digital do terreno (MDT) de outra fonte disponível, e com este MAD é possível detecção de árvores e estimativas de alturas, similar ao LiDAR (WHITE et al., 2016). Caso não haja outra fonte do MDT, é possível realizar a classificação dos pontos referentes ao solo na nuvem de pontos obtida por fotogrametria aérea digital e posteriormente realizar a interpolação desses pontos, gerando assim um MDT.

A exatidão da obtenção de alturas por fotogrametria depende de vários fatores, relacionados à qualidade das imagens e aspectos da área e elementos alvo (geometria da copa, topografia, exatidão do MDT, entre outros), porém em geral se observa subestimativa dos valores de alturas devido à suavização do topo das árvores

(DURRIEU et al., 2015). Da mesma forma, a detecção das árvores é limitada por alguns fatores, entre eles a presença de árvores suprimidas, que não podem ser detectadas porque não são visíveis na superfície (DURRIEU et al., 2015; WHITE et al., 2016).

Além dos elementos vinculados ao planejamento de voo, é importante realizar o planejamento dos pontos de controle, que apesar de serem opcionais no processamento, são importantes quando há necessidade de realizar o georreferenciamento do local (NEX; REMONDINO, 2014). Quanto maior o número de pontos de controle, maior a acurácia, sendo recomendado, no mínimo, três pontos de controle bem distribuídos sobre a área, variando conforme a área, formato, espécie, exatidão necessária, além de equipamentos e equipe disponíveis (BREDE et al., 2017; LINDER, 2016; WOLF et al., 2014).

O desenvolvimento de aeronaves remotamente pilotadas (ARP) permitiu a flexibilização na aquisição de imagens para o processamento fotogramétrico (REMONDINO, 2014). Diversos estudos mostram as vantagens de se utilizar ARP para a obtenção de informações, podendo citar engenharia civil, geologia, arqueologia, agricultura e manejo florestal (JAYATHUNGA et al., 2018; SHAHBAZI et al., 2014; REDWEIK, 2007; SALAMÍ et al., 2014; WATTS et al., 2012; WHITEHEAD; HUGENHOLTZ, 2014).

As ARP permitem a obtenção de dados de SR com várias vantagens comparadas às plataformas tradicionais, como satélites e aeronaves tripuladas. Essas vantagens se referem ao baixo custo em relação à tecnologias similares em termos de resolução e dados obtidos (PÁDUA et al., 2017; WHITEHEAD; HUGENHOLTZ, 2014), a capacidade de uso desses veículos aéreos com diversos sensores de acordo com a aplicação (PÁDUA et al., 2017; TANG; SHAO, 2015) e a flexibilidade na escolha de data de aquisição, devido à simplificada operação desses veículos aéreos (WHITEHEAD; HUGENHOLTZ, 2014).

Para levantamentos fotogramétricos, é importante destacar que as ARP são muito sensíveis às variações de posição e altitude (ângulos) devido à ação do vento (ZHANG et al., 2011), causando deslocamentos da posição do veículo aéreo e, consequentemente, variações na sobreposição das imagens. Devido a esse fator, recomendam-se valores de sobreposição superiores aos utilizados na fotogrametria com aeronaves tripuladas, porém dependendo da aplicação e características da área

(NEX; REMONDINO, 2014; TORRES-SÁNCHEZ et al., 2018). Na área florestal é comum se utilizar sobreposições acima de 80% (DANDOIS et al., 2015).

As ARP foram propostas como uma ferramenta inovadora e acessível para apoiar a aquisição de dados tridimensionais de detecção remota para inventários florestais (LISEIN et al., 2013; PULITI et al., 2015) e para levantamentos florestais em larga escala em que a coleta extensiva de dados de campo pode ser dispendiosa e em locais inacessíveis, sendo recomendável o uso de dados remotos para complementar a amostragem de campo (PULITI et al., 2017a). Com a maior disponibilidade de dados ARP, há uma maior acurácia das estimativas das variáveis mensuradas e produção de mapas em larga escala.

3.2.4. Aplicações de fotogrametria aérea digital no inventário florestal

Devido às suas características vantajosas aliadas às técnicas de processamento, seu uso no setor florestal tem se tornado cada vez mais frequente (TANG; SHAO, 2015; TORRESAN et al., 2017). Dentre suas possíveis aplicações, pode-se citar: mapeamentos e caracterização da tipologia florestal (CUNLIFFE et al., 2016; FRANKLIN; AHMED, 2017), análises de fitossanidade (DASH et al., 2017; NÄSI et al., 2018) e monitoramento de incêndios florestais (FERNÁNDEZ-GUISURAGA et al., 2018). Em nível da estrutura da floresta, destaca-se a detecção de árvores individuais e estimativas de altura, diâmetro de copa, volume, tanto para árvore individual como para estimativas por parcela (ALMEIDA, 2020; DANDOIS; ELLIS, 2013; GIANNETTI et al., 2018; GOODBODY et al., 2017; PANAGIOTIDIS et al., 2016; ZHANG et al., 2016).

Gülci et al. (2017) avaliaram diferentes parâmetros do planejamento de voo e processos fotogramétricos em uma floresta na Turquia. A partir desse estudo, os autores constataram que imagens sobrepostas de alta resolução podem fornecer dados significativos para a avaliação de plantios florestais, estradas e áreas com potencial para biomassa na área de estudo. Esses resultados podem ser usados para gerar modelagem 3D da estrutura da floresta e delinear parâmetros individuais da árvore. O levantamento fotogramétrico se mostrou uma ferramenta altamente eficaz,

possibilitando mapeamentos de baixo custo para áreas florestais médias e grandes, além de permitir a análise das métricas da floresta.

Em uma floresta mista de coníferas localizada no Japão, Jayathunga et al. (2018) avaliaram o uso de dados de fotogrametria e LiDAR para estimar o volume comercial e o estoque de carbono. A diferença encontrada entre as métricas obtidas pela FAD e pelo LiDAR foi de 0,76% para volume e de 0,81% para biomassa, tal erro pode estar atribuído à capacidade limitada de imagens de FAD penetrarem na camada do dossel.

Para estimar a *G* e o *V*, dentre outras variáveis, Wittke et al. (2019) utilizaram LiDAR, fotogrametria a partir de dados orbitais do WorldView-2, dados de radar do TerraSAR-X-stereo e dados multitemporais do Sentinel-2. Os resultados obtidos pelos dados do Sentinel-2 apresentaram valores de *RMSE* maiores que os obtidos por LiDAR e fotogrametria, com aproximadamente 5 e 10 pontos percentuais a mais para estimar a *G* e o *V*, respectivamente. Os dados de radar apresentaram o pior desempenho quando comparados com os demais. Além disso, os autores concluíram que o uso de séries temporais do Sentinel-2 não apresentou melhor performance quando comparado com o uso de imagem obtida em apenas uma data.

Para modelar variáveis biofísicas em uma floresta boreal na Noruega, Puliti et al. (2015) utilizaram nuvem de pontos da FAD normalizada por MDT proveniente do LiDAR e a resposta espectral nas bandas do vermelho, verde e infravermelho próximo. Os autores concluíram que a inclusão de variáveis espectrais não gerou ganhos significativos na modelagem, embora o período do ano de aquisição das imagens e condições climáticas, como a presença de neve, podem ter influenciado na resposta espectral.

Iqbal et al. (2018) compararam a modelagem de área basal, altura, volume e número de árvores por hectare a partir de dados LiDAR e FAD com câmeras de formato pequeno (21 *megapixels*) e médio (60,5 *megapixels*). Em nível de parcela, a diferença máxima entre os valores de *RMSE* foi de 2,46 e 2,53% para *G* e *V*, respectivamente, sendo os menores erros obtidos pelo LiDAR. Já em nível de talhão, essa diferença foi de 0,99% para *G* e 2,02% para *V*, sendo que para a *G* a FAD com câmera de formato médio apresentou melhor resultado. Os autores concluíram que a fotogrametria por ambos os tipos de câmera utilizados gerou resultados com acurácia similar à obtida pelo LiDAR.

Também comparando dados de LiDAR e FAD em uma floresta plantada no leste da China, Cao et al. (2019) constataram que as maiores similaridades entre as métricas obtidas por ambas as fontes de dados ocorreram em florestas mais altas e com menor densidade de fustes. Além disso, a maior diferença dos valores de RMSE foi encontrada para a modelagem do V e a menor para a G (4,2 e 0,86 pontos percentuais, respectivamente).

4. METODOLOGIA

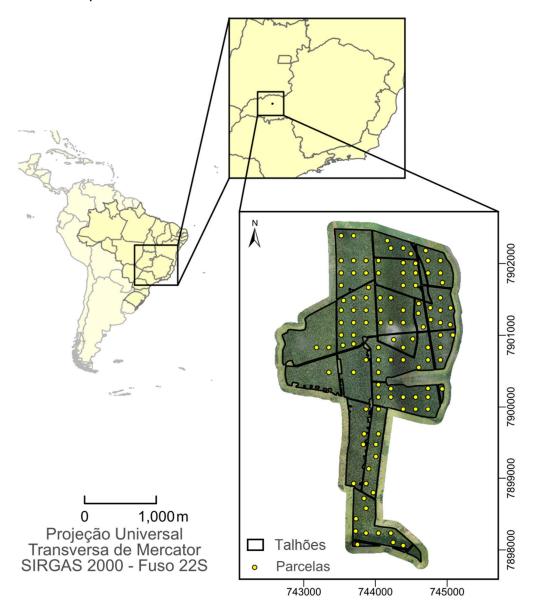
Para a elaboração deste estudo foram utilizados dados de inventário florestal tradicional obtidos em campo, métricas derivadas de uma imagem orbital (IO) do sensor MSI/Sentinel-2 e métricas extraídas de uma nuvem de pontos tridimensionais derivada por fotogrametria aérea digital (FAD) por aeronave remotamente pilotada (ARP). Além disso, foram utilizados e comparados dois métodos de modelagem: regressão linear múltipla e redes neurais artificiais. Nas modelagens foram consideradas três diferentes fontes de dados, a IO, a nuvem de pontos da FAD e uma combinação de ambas (IO e FAD), sendo as variáveis estimadas a área basal e o volume. Todo o processo de obtenção, processamento e análise dos dados é descrito nas seções a seguir.

4.1. Descrição da área de estudo

Este estudo foi realizado em uma floresta de produção com área de 496 ha, localizada no município de Monte Alegre de Minas, na região do Triângulo Mineiro, no estado de Minas Gerais, Brasil (Figura 5). Essa floresta é composta por quatro materiais genéticos do híbrido *Eucalyptus grandis* (W. Hill *ex* Maiden) x *Eucalyptus urophylla* (S. T. Blake), em primeira e segunda rotação, com espaçamentos de 3,0 x 1,5 m e 3,0 x 2,0 m, e idades variando de 3,83 a 4,57 anos.

Segundo a classificação de Köppen, o clima da região é caracterizado como Aw, tropical com inverno seco e verão quente (KÖPPEN, 1926). A temperatura média anual é de 23,4°C e precipitação média anual é de 1377 mm. O relevo da região é considerado plano a suave ondulado, com altitude superior a 732 metros acima do nível do mar (CLIMATE-DATA.ORG, 2021).

Figura 5 – Localização da área de estudo, com destaque para os talhões e parcelas de inventário de campo.



4.2. Inventário florestal

Foi realizado um inventário florestal tradicional em março de 2020 com a alocação de 111 parcelas georreferenciadas por GNSS de navegação (erro aproximado de \pm 3 m), com formato circular e área de 400 m² (0,04 ha). O

delineamento amostral utilizado foi amostragem sistemática com estratificação por rotação.

Nas parcelas do inventário foram coletadas as seguintes informações: diâmetro à 1,30 m do solo (*D*) de todas as árvores, utilizando uma suta; altura total (*H*) das 10 primeiras árvores da parcela e altura dominante (*HD*) considerando a média das alturas das quatro árvores com maior diâmetro em cada parcela, utilizando o hipsômetro eletrônico Haglöf II. Posteriormente, a altura das demais árvores foi estimada por relação hipsométrica com o modelo de Campos (1984) ajustado para cada rotação (Tabela 1).

Tabela 1 – Equações ajustadas e estatísticas de desempenho do modelo hipsométrico de Campos (1984) ajustado por rotação.

Rotação	Equação ajustada	R ²	Syx (%)
1 ^a	$\widehat{LnH} = 0,7962 - 6,1783D^{-1} + 0,8679LnHD$	0,87	4,46
2ª	$\widehat{LnH} = 0.8819 - 5.7677D^{-1} + 0.8288LnHD$	0,88	5,40

Em que: H= altura total (m); D= diâmetro a 1,30 m do solo (cm); HD= altura dominante média da parcela (m).

Para o cálculo do volume das árvores, foi considerado o volume do fuste até 4 cm de diâmetro (volume comercial). Para tanto, foi realizada a cubagem rigorosa de 60 e 70 árvores-amostra, pelo método de Smalian (KERSHAW JR et al., 2017), para as áreas de primeira e segunda rotação, respectivamente. Posteriormente, foi ajustado o modelo de Schumacher e Hall (1933), para cada rotação, para estimar o volume das demais árvores (Tabela 2).

Tabela 2 – Equações ajustadas e estatísticas de desempenho do modelo volumétrico de Schumacher e Hall (1933) ajustado por rotação.

Rotação	Equação ajustada	R^2	Syx (%)
1 ^a	$\hat{V} = -9,2873D^{1,9197}H^{0,7491}$	0,98	8,96
2 ^a	$\hat{V} = -9,6110D^{2,0145}H^{0,7619}$	0,99	10,34

Em que: $V = \text{volume comercial individual (m}^3)$; D = diâmetro a 1,30 m do solo (cm) e H = altura total (m).

As estatísticas descritivas das variáveis coletadas no inventário florestal podem ser encontradas na Tabela 3.

Tabela 3 – Estatísticas descritivas relacionadas às variáveis do povoamento para cada rotação e número de parcelas mensuradas por rotação e espaçamento.

Variáveis				Rota	ação				Geral			
variaveis	1			2			_ Gerai					
	Méd.	Mín.	Máx.	CV	Méd.	Mín.	Máx.	CV	Méd.	Mín.	Máx.	CV
Idade (anos)	4,5	4,5	4,6	0,9	3,9	3,8	4,1	2,2	4,2	3,8	4,6	7,6
D (cm)	13,7	12,5	15,0	4,4	12,9	10,4	14,4	6,3	13,3	10,4	15,0	6,0
<i>H</i> (m)	22,5	19,7	26,0	6,2	20,2	16,4	23,6	7,3	21,3	16,4	26,0	8,0
HD (m)	24,7	22,1	29,1	6,5	23,1	20,3	26,0	6,0	24,1	20,3	29,1	6,9
G (m²ha-1)	25,6	19,9	31,2	10,5	18,4	15,7	24,0	9,8	22,2	15,7	31,2	19,6
V (m³ha⁻¹)	243,6	182,3	308,0	13,2	165,1	127,7	251,5	16,2	208,3	127,7	308,0	23,4
Fustes (N)	1.678	1.275	2.000	8,1	1.363	1.000	2.200	16,0	1.561	1.000	2.200	15,0
Espaçamento	3 >	< 2	3 x	1,5	3 >	(2	3 x	1,5	3 >	κ2	3 x	1,5
Parcelas	5	7	ç)	3	0	1:	5	8	7	24	4

Em que: Méd., Mín. e Máx. = valor médio, mínimo e máximo da variável; CV = coeficiente de variação (%); D = diâmetro a 1,30 m do solo (cm); H = altura média (m); N = número de árvores por hectare; HD = altura dominante (m); G = área basal (m^2ha^{-1}) e V = volume comercial com casca (m^3ha^{-1}).

Para as variáveis G e V, foram calculadas as estatísticas média estratificada (Equação 10), erro padrão da média estratificada (Equação 11), os erros absoluto (Equação 12) e relativo de amostragem (Equação 13) (KERSHAW JR. et al., 2017). As estimativas dessas estatísticas são apresentadas na Tabela 4.

$$\overline{X}_{st} = \sum_{h=1}^{L} W_h \overline{X}_h \tag{10}$$

$$s_{\bar{x}st} = \sqrt{\sum_{h=1}^{L} W_h^2 \frac{s_h^2}{n_h}}$$
 (11)

$$E_a = \pm t \mathbf{s}_{\bar{\mathbf{x}}st} \tag{12}$$

$$E_r = \pm \frac{t s_{\overline{x}st}}{\overline{x}_{st}} 100 \tag{13}$$

Em que: \overline{X}_{st} = média estratificada da variável de interesse; L = número de estratos; W_h = proporção da área do estrato h em relação à população; \overline{X}_h = média da variável de interesse no estrato h; $S_{\overline{x}st}$ = erro padrão da média estratificada; S_h^2 = variância do estrato h; n_h = número de parcelas no estrato h; E_a = erro absoluto de amostragem; t = valor da estatística t-Student; e; E_r = erro relativo de amostragem.

Tabela 4 – Estatísticas estimadas do inventário tradicional estratificado por rotação.

Variáveis	\overline{X}_{st}	S _{Xst}	Ea	Er
G	22,19	0,23	0,45	2,02
V	208,30	2,97	5,89	2,83

Em que: \overline{X}_{st} = média estratificada (m²ha-¹ para G e m³ha-¹ para V); S_{st} = erro padrão da média estratificada (m²ha-¹ para G e m³ha-¹ para V); E_a = erro absoluto de amostragem a 95% de probabilidade (m²ha-¹ para G e m³ha-¹ para V) e E_r = erro relativo de amostragem (%).

4.3. Imagem orbital multiespectral

Foi utilizada uma imagem do sensor MSI/Sentinel-2 obtida junto a Agência Espacial Europeia (European Space Agency - ESA) por meio do Copernicus Open Access Hub. Foram utilizados os valores de reflectância de superfície das bandas espectrais 2 (azul – 0,49 μm), 3 (verde – 0,56 μm), 4 (vermelho – 0,66 μm), 5 (borda do vermelho 1 – 0,70 μm), 6 (borda do vermelho 2 – 0,74 μm), 7 (borda do vermelho 3 – 0,78 μm), 8 (infravermelho próximo – 0,83 μm) e 8A (borda do vermelho 4 – 0,86 μm). As bandas 2, 3, 4 e 8 foram reamostradas para a resolução espacial de 20 metros, resolução original das bandas 5, 6, 7 e 8A. Essa reamostragem dos pixels para 20 metros foi feita para que a área do pixel coincidisse com a área das parcelas mensuradas no IFT. Os valores de reflectância de superfície foram estimados a partir de correção atmosférica realizada pelo algoritmo sen2cor (MAIN-KNORN et al., 2017). Foi selecionada uma imagem sem nuvens do dia 13 de março de 2020, no mesmo mês do inventário em campo.

A partir dessas informações foram calculados os índices de vegetação (IV) apresentados na Tabela 5. Esses índices são utilizados para identificar a vegetação e

separar do solo exposto (RATIO e MSR), expressar o vigor vegetativo (NDVI, RDVI e DVI), estimar a atividade fotossintética (GNDVI), reduzir a interferência do brilho do solo (SAVI, OSAVI e MSAVI2), minimizar a saturação e efeitos de perturbações atmosféricas (TVI e GEMI).

Os valores das bandas individuais e os índices de vegetação foram utilizados como variáveis preditoras para estimar a área basal e o volume dos povoamentos. Para cada parcela de inventário foi extraída a resposta espectral média dos pixels, ponderada pela área de intersecção com a parcela. Todo o procedimento descrito acima foi realizado no software R (R CORE TEAM, 2019).

Tabela 5 – Índices de vegetação utilizados na modelagem das variáveis biofísicas a partir dos dados do Sentinel-2.

Fórmula	Autor
$RATIO = \frac{NIR}{R}$	Jordan (1969)
$NDVI = \frac{NIR - R}{NIR + R}$	Rouse et al. (1974)
$GNDVI = \frac{NIR - G}{NIR + G}$	Gitelson et al. (1996)
DVI = NIR - R	Tucker (1979)
$RDVI = \frac{NIR - R}{\sqrt{NIR + R}}$	Roujean; Breon (1995)
$SAVI = \frac{(NIR - R)}{NIR + R + L}(1 + L)$	Huete (1988)
$OSAVI = \frac{(NIR - R)}{(NIR + R + 0.16)}$	Rondeaux et al. (1996)
$MSAVI2 = \frac{2NIR + 1 - \sqrt{(2NIR + 1)^2 - 8(NIR - R)}}{2}$	Qi et al. (1994)
$TVI = \sqrt{NDVI + 0.5}$	Broge; Leblanc (2000)
$MSR = \frac{\left(\frac{NIR}{R} - 1\right)}{\left(\sqrt{\frac{NIR}{R}} + 1\right)}$	Chen (1996)
$GEMI = \frac{[2(NIR^2 - R^2) + 1,5NIR + 0,5R]}{NIR + R + 0,5}$	Pinty; Verstraete (1992)

Em que: *RATIO* = índice da razão simples; *NIR* = banda do infravermelho próximo; *R* = banda do vermelho; *NDVI* = índice de vegetação da diferença normalizada; *GNDVI* = índice de vegetação da diferença normalizada do verde; *G* = banda do verde; *DVI* = índice de vegetação por diferença; *RDVI* = índice de vegetação por diferença renormalizada; *SAVI* = índice de vegetação ajustado ao solo; *L* = fator de correção do solo (usualmente adota-se 0,5); *OSAVI* = índice de vegetação ajustado ao solo otimizado; *MSAVI2* = índice de vegetação ajustada ao solo modificado; *TVI* = índice de vegetação transformado; *MSR* = índice de razão simples modificado; *GEMI* = índice global de monitoramento ambiental.

4.4. Fotogrametria aérea digital

Para o levantamento aerofotogramétrico para toda a área do plantio, foi utilizado um hexacóptero modelo X800 GEO equipado com câmera RGB de 24,1 *megapixels*. A altitude de voo foi de 120 metros, de acordo com a ICA100-40 (DECEA, 2015), e as imagens foram obtidas com sobreposição longitudinal de 92% e lateral de 85%, assim como sugerido por Dandois et al. (2015). Os voos foram realizados em março de 2020, data próxima ao inventário florestal, evitando assim as incertezas provocadas pela não concordância temporal entre os dados de campo e remotos (GONÇALVES et al., 2017).

No momento da obtenção das fotos, as mesmas foram georreferenciadas com o GNSS de navegação da própria aeronave, com precisão horizontal de 2 m e vertical de 9 m. Não foram coletados pontos de controle do terreno (PCT) com GNSS apropriado (precisão centimétrica) no momento do levantamento aerofotogramétrico. Também não foi possível determinar PCT precisos a partir de outras fontes de dados da mesma área de estudo, como informações obtidas por LiDAR ou fotografias aéreas de datas posteriores ao levantamento. Para avaliar o impacto da ausência dos PCT na modelagem, foram feitas análises descritas na seção 4.5.

4.4.1. Structure from motion (SfM)

Os pares de imagens foram interpretados pelo algoritmo SfM, extraindo assim as informações tridimensionais do terreno e sua superfície no formato de nuvem de pontos (x, y e z), utilizando o software Agisoft Photoscan (AGISOFT, 2018). Os parâmetros utilizados para o alinhamento das fotos foram *accuracy medium*, *pair selection generic* com *key point limit* igual a 40.000 e *tie point limit* igual a 4.000. Para o processamento da nuvem densa de pontos, os parâmetros definidos foram *quality medium* e *filtering mode mild*. No final do processo, a nuvem de pontos 3D resultante teve um erro de localização 2,5 metros na horizontal e 9,38 metros na vertical. A nuvem de pontos gerada foi exportada no formato de arquivo binário ".LAS". Um

ortomosaico com resolução espacial de 1 metro também foi criado e exportado para o formato ".TIF".

O sistema de referência utilizado para todos os produtos gerados do levantamento fotogramétrico foi o SIRGAS 2000 com projeção UTM, zona 22S.

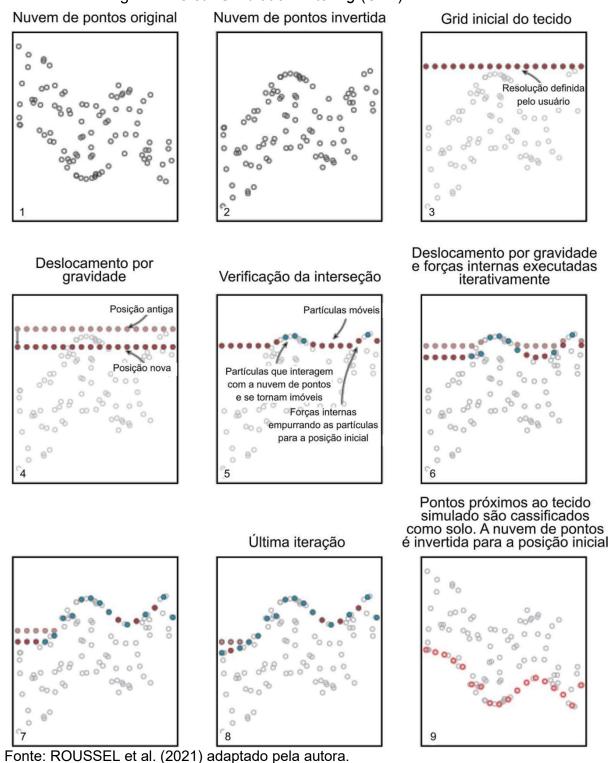
4.4.2. Elaboração do modelo digital do terreno (MDT)

O MDT foi criado a partir da nuvem de pontos 3D da FAD. A classificação dos pontos do solo foi realizada com a função *Cloth Simulation Filtering* (ZHANG et al., 2016), presente no pacote lidR (ROUSSEL et al., 2021) do software R (R CORE TEAM, 2019). Nessa função, a nuvem de pontos é invertida e, em seguida, é feita uma simulação de um tecido sobre esses pontos (Figura 6). Esse tecido é representado por um *grid* cujos pontos são interconectados e juntos determinam a posição tridimensional e a forma do tecido. Os pontos classificados como solo são determinados por uma interação entre esses pontos e a superfície da nuvem de pontos invertida.

Os parâmetros a serem definidos foram o limiar de classificação (class_threshold) que representa a distância mínima entre o tecido simulado e determinado ponto da nuvem para que seja classificado como solo; a resolução do tecido (cloth_resolution) que determina a distância entre os pontos que formam o grid do tecido; e a rigidez do tecido (rigidness) que varia de 1 a 3, sendo 1 utilizado para terrenos fortemente ondulados e 3 para terrenos mais planos.

A classificação foi realizada em duas etapas. Na primeira os parâmetros definidos foram *class_threshold* = 7, *cloth_resolution* = 10 e rigidness = 3. Já na segunda etapa, os parâmetros foram *class_threshold* = 1,5, *cloth_resolution*= 0,75 e rigidness = 2.

Figura 6 – Representação do processo de classificação de pontos representativos do terreno com o algoritmo *Cloth Simulation Filtering* (CSF).



Após essa classificação, foram filtrados os pontos referentes ao solo e gerado o MDT com a função *Triangular Irregular Network* (TIN), também presente no pacote lidR. Esse algoritmo foi usado para estimar pontos do solo em locais não amostrados (entre pontos de solo conhecidos). Nesse processo, foi realizada uma triangulação a partir de cada ponto classificado como solo, com coordenadas x, y e z. Assim, os pontos classificados como solo foram os vértices dos triângulos e as arestas foram geradas a partir pela conexão desses pontos.

Para analisar o MDT gerado pela nuvem de pontos da FAD foram comparadas as suas classes de altitude com as obtidas a partir de dados do *Shuttle Radar Topography Mission* (SRTM).

4.4.3. Métricas tradicionais baseadas na altura

A nuvem de pontos 3D foi normalizada a partir do MDT da FAD e foi realizada a extração de métricas tradicionais baseadas na altura no software FUSION/LDV 3.8 (McGAUGHEY, 2018). A abordagem utilizada foi baseada em área e as métricas utilizadas como variáveis preditoras para a modelagem (Quadro 1) foram calculadas por meio da função *GridMetrics*. Todas as métricas descritas no Quadro 1 foram estimadas para as 111 parcelas de IFT e, posteriormente, para toda a área de estudo para a elaboração dos mapas com a espacialização das variáveis estimadas.

Quadro 1 – Métricas tradicionais extraídas da nuvem de pontos.

Variável	Descrição
Hmin	Altura mínima
Hmax	Altura máxima
Hmean	Altura média
Hmode	Moda da altura
H.MADmed	Média dos desvios absolutos da média
H.MADmode	Média dos desvios absolutos da moda
Hsd	Desvio padrão da altura
Hvar	Variância da altura
Hcv	Coeficiente de variação da altura
Hskew	Assimetria dos valores de altura
Hkurt	Curtose dos valores de altura
H.IQ	Percentil 75 menos o percentil 25 da altura
H.AAD	Desvio médio absoluto da altura
HL1, HL2, HL3, HL4	Momentos (L) da altura
HLcv	Coeficiente de variação do momento da altura
HLskew	Assimetria do momento da altura
HLkurt	Curtose do momento da altura
HSQRTmean	Média quadrática da elevação
HCURTcube	Média cúbica da elevação
PFAmean	Percentual dos primeiros retornos acima da média
PFAmode	Percentual dos primeiros retornos acima da moda
FAmean	Primeiros retornos acima da média
FAmode	Primeiros retornos acima da moda
H.P01 até H.P99	Altura do 1º até o 99º percentil
CRR	Relação de suavização do dossel
FRA12	Primeiros retornos acima de 12 metros

Em que: $CRR = \frac{(Hmean - Hmin)}{(Hmax - Hmin)}$.

4.4.4. Avaliação dos produtos da Fotogrametria Aérea Digital

Para avaliar a qualidade da normalização da nuvem de pontos pelo MDT da FAD, inicialmente foi realizada uma comparação visual entre os valores de altura média obtidas nas parcelas de inventário florestal e a altura do povoamento no modelo de altura do dossel (MAD) gerado a partir da nuvem de pontos da FAD normalizada.

Adicionalmente, foram comparados os valores de altura dominante (*HD*) das parcelas de campo em função das métricas de altura obtidas da nuvem da FAD, a altura máxima (*Hmax*) e os valores correspondentes ao 99º percentil da altura (*H.P99*). Essas métricas foram escolhidas pois representam os maiores valores de altura da nuvem de pontos normalizada e espera-se que tenham forte correlação com a *HD* das parcelas.

Em seguida, foi elaborado um gráfico da dispersão dos valores de *Hmax* e *H.P99* em função da *HD* observada e foram calculados o coeficiente de correlação (*r* – Equação 14), a raiz quadrada do erro quadrático médio (*RMSE* – Equação 15) e o *viés* (Equação 16). A qualidade da classificação da nuvem de pontos e a representatividade do MDT para a área de estudo foi avaliada pela análise desses resultados. Assim, caso os valores de *Hmax* e *H.P99* tenham correlação com os valores de HD das parcelas e o *RMSE* e *viés* sejam baixos, pode-se deduzir que o MDT permitiu uma normalização satisfatória da nuvem de pontos.

$$r = \frac{\sum_{i=1}^{n} (y_i - \overline{y})(\hat{y}_i - \hat{y}_m)}{\sqrt{\left[\sum_{i=1}^{n} (y_i - \overline{y})^2\right] \left[\sum_{i=1}^{n} (\hat{y}_i - \hat{y}_m)^2\right]}}$$
(14)

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

$$RMSE(\%) = \frac{RMSE}{\overline{y}} 100$$
(15)

$$Vi\acute{e}s = \frac{\sum_{i=1}^{n} y_i - \sum_{i=1}^{n} \hat{y}_i}{n}$$

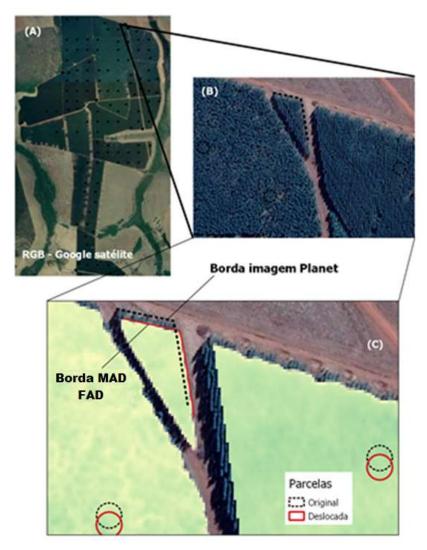
$$Vi\acute{e}s\left(\%\right) = \frac{Vi\acute{e}s}{\overline{y}} 100$$
(16)

Em que: y_i = variável dependente observada, \hat{y}_i = variável dependente estimada, y = média da variável dependente observada, \hat{y}_m = média da variável dependente estimada e número de observações.

4.5. Avaliação e redução dos erros de posicionamento

Com o intuito de corrigir o deslocamento horizontal dos produtos da FAD (erro de localização de 2,5 metros na horizontal — seção 4.4.1), as parcelas de inventário de campo foram deslocadas (Figura 7). Este deslocamento foi realizado tendo como referência uma imagem Planet (PLANET LABS INC, 2018) com resolução espacial de 3 metros da mesma época do voo da ARP (março de 2020). Considerando o deslocamento observado entre o MAD obtido por FAD (Figura 7C, linha tracejada na cor preta e contínua na cor vermelha) e a imagem Planet, todas as parcelas de campo foram deslocadas na mesma proporção, de forma a compensar o erro horizontal observado. O erro vertical observado do processamento das fotos (9,38 metros) foi desconsiderado, uma vez que, o erro que ocorre na parte superior do plantio (topo do dossel) será o mesmo que ocorre na parte inferior (solo). Sendo assim, o erro vertical do processo de alinhamento das fotos é compensado no momento da normalização da nuvem de pontos FAD.

Figura 7 – Representação do deslocamento das parcelas de inventário de campo, considerando o erro posicional (X e Y) dos produtos da FAD.

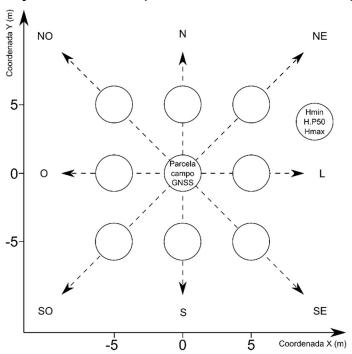


Como descrito na seção 4.2, a localização do centro das parcelas em campo foi realizada com GNSS de navegação e este equipamento possui um erro de posicionamento horizontal (X e Y) de aproximadamente três metros. Na tentativa de avaliar o efeito deste deslocamento no ajuste dos modelos de estimação, foi realizada uma simulação de deslocamento (X e Y) das parcelas e avaliado seu efeito na estimativa de algumas métricas da FAD. Para isso, foi simulado um deslocamento de 5 metros em oito direções (pontos cardeais e colaterais), conforme a Figura 8, e extraídas as métricas baseadas na altura da nuvem de pontos da FAD, *Hmin*, *H.P50* e *Hmax* (Quadro 1). Essas três métricas foram escolhidas pois permitem observar o

comportamento da nuvem de pontos em relação seu deslocamento em termos de valores mínimos, medianos e máximos.

Posteriormente, foi realizado um teste *t-Student*, a 5% de significância, para dados pareados entre as métricas extraídas em cada uma dessas posições para verificar se havia diferença significativa entre elas e as métricas obtidas na posição central (original). Um resultado não significativo indica que o erro de localização das parcelas do inventário não influenciou negativamente na obtenção das métricas da nuvem de pontos. A normalidade dos dados foi confirmada pelo teste de Shapiro-Wilk a 5% de significância.

Figura 8 – Representação gráfica da simulação do deslocamento das parcelas de inventário para avaliar o efeito do deslocamento do erro posicional do GNSS no momento da localização do centro da parcela de inventário no campo.



4.6. Modelagem das variáveis biofísicas

As variáveis de interesse modeladas neste trabalho foram a área basal e o volume de madeira de povoamentos de eucalipto. Para isso, foram consideradas três

abordagens diferentes: a modelagem com variáveis obtidas (i) apenas pela imagem orbital (IO); (ii) apenas por métricas derivadas da nuvem de pontos FAD; e (iii) pela combinação de métricas de ambas as tecnologias (IO e FAD).

A modelagem foi realizada por dois métodos de estimação: regressão linear múltipla (RLM) e redes neurais artificiais (RNA). Os dados das parcelas foram divididos de forma aleatória em dois conjuntos: 70% para ajuste dos modelos de regressão e treinamento das redes neurais artificiais e 30% para validação dos métodos de estimação. Os mesmos conjuntos de treino e validação foram utilizados para os dois métodos de estimação utilizados. Na Tabela 6 encontram-se as estatísticas descritivas para os dois conjuntos de dados.

Tabela 6 – Estatísticas descritivas para o conjunto de ajuste/treino e validação por variável resposta.

Conjunto	Média	Mínimo	Máximo	CV(%)
Conjunto		(G	
Ajuste/Treino	22,79	14,83	30,57	18,64
Validação	22,90	15,68	31,23	20,27
		1	V	
Ajuste/Treino	214,44	128,46	308,01	22,23
Validação	215,98	138,06	307,61	23,91

Em que: CV = coeficiente de variação (%); G = área basal (m^2ha^{-1}) e V = volume total com casca (m^3ha^{-1}).

4.6.1. Regressão linear múltipla

Antes de realizar análises de regressão linear múltipla, um fator importante a ser analisado é a correlação entre as variáveis preditoras nos modelos. Neste estudo foi aplicado o método de seleção de variáveis por busca exaustiva presente no pacote *Leaps* (LUMLEY, 2017) do *software* R versão 3.5.2. (R CORE TEAM, 2019). Este algoritmo testa e compara todas as variáveis independentes (*X*), buscando encontrar o melhor subconjunto de variáveis em *X* para estimar a variável dependente (*Y*) na regressão linear, utilizando o algoritmo *branch-and-bound* (MILLER, 2002). Neste

método, a seleção dos melhores modelos é feita por um *ranking* baseado nas seguintes estatísticas: R^2 ajustado (KVÅLSETH, 1985) (Equação 17), critério de informação Bayesiano (BIC) (SCHWARZ, 1978) (Equação 18), estatística Cp de Mallows (MALLOWS, 2000) e soma de quadrados dos resíduos da regressão.

$$R_{ajus}^{2} = 1 - \left(\frac{n-1}{n-p}\right) - \left[1 - \left(1 - \frac{\sum_{i=1}^{n} (y_{i} - \hat{y}_{i})^{2}}{\sum_{i=1}^{n} (y_{i} - \overline{y}_{i})^{2}}\right)\right]$$
(17)

Em que: y_i = variável dependente observada; \hat{y}_i = variável dependente estimada; \overline{y}_i = média da variável dependente observada; n = número de observações; p = número de parâmetros do modelo.

$$BIC = -2LnL + (p+1)Ln n$$
(18)

Em que: L = máxima verossimilhança do modelo; p = número de variáveis explicativas consideradas no modelo; n = número de observações; Ln = logaritmo neperiano.

Assim, foram ajustadas quatro equações, com número de variáveis preditoras variando de dois a cinco, para estimar a área basal e o volume de madeira de povoamentos de eucalipto, totalizando oito equações para cada fonte de dados (IO, FAD e combinação de IO e FAD).

Uma vez elaborado o *ranking* com os melhores modelos, foi avaliado o grau de multicolinearidade entre as variáveis preditoras pelo fator de inflação de variância (FIV) (Equação 19). Seguindo as recomendações de Montgomery (2021), os modelos com FIV médio acima de 10 foram descartados, pois apresentavam multicolinearidade acima do limite aceitável.

$$FIV_j = \frac{1}{1 - R_j^2} \tag{19}$$

Em que: FIV_j = mede o quanto a variância do coeficiente $\hat{\beta}_j$ é inflacionada por sua colinearidade; R_j^2 = coeficiente de determinação da regressão de X_j sobre as outras variáveis explicativas.

Dessa forma, foram selecionadas como variáveis preditoras aquelas presentes nos modelos que apresentaram melhor colocação no *ranking* das estatísticas e valores de FIV menor do que 10.

Após a seleção do melhor conjunto de variáveis explicativas, realizou-se o ajuste do modelo linear múltiplo (Equação 20).

$$Y_{i} = \beta_{0} + \beta_{1} X_{i1} + \beta_{2} X_{i2} + \dots + \beta_{p} X_{ip} + \varepsilon_{i}$$
(20)

Em que: Y_i = valor da variável dependente na i-ésima observação, correspondendo a área basal ou volume de madeira; β_p = coeficientes do modelo; X_{i1} , X_{i2} , ..., X_{ip} são os p-valores das p-ésima variável explicativa na i-ésima observação; ε_i = erro aleatório.

4.6.2. Redes neurais artificiais

Devido ao elevado número de métricas extraídas, foi realizada uma seleção visando diminuir a dimensionalidade do conjunto de variáveis preditoras. Para tanto, foram removidas as variáveis altamente correlacionadas, cujos coeficientes de correlação foram iguais ou superiores a 0,90 (LEITE et al., 2020; SILVA et al., 2017).

Após a seleção das variáveis preditoras, foi utilizado o *toolbox Neural Network* do *software* Matlab R2016a (MATHWORKS, 2016) para o treinamento de RNA *multilayer perceptron* do tipo *feedforward* com algoritmo Levenberg-Marquardt. A parada antecipada (*early stopping*) e o número de épocas igual a 1.000 foram adotados como critérios de parada no treinamento das RNA.

Para cada variável dependente, foram testadas diferentes combinações de número de neurônios na camada oculta e funções de ativação. O número de neurônios variou de 3 a 20 e as funções de ativação avaliadas foram a tangente hiperbólica e a logística.

Para a parametrização das RNA foram treinadas 50 redes com cada uma das configurações. A melhor estrutura de rede foi aquela que apresentou menor média do erro quadrático médio (*RMSE* – Equação 11) na validação.

Uma vez obtida a melhor configuração das redes (número de neurônios e função de ativação) para estimar *G* e *V* para as três fontes de dados, foram treinadas 100 RNA para cada uma dessas abordagens. Para calcular as estimativas de *G* e *V*

em nível de parcela e para toda a área, foi selecionada a RNA que apresentou maior acurácia na validação.

4.6.3. Critérios para a avaliação dos métodos de estimação

A avaliação das estimativas geradas pelos modelos de regressão e RNA, para ajuste e validação, foi feita com as estatísticas: coeficiente de correlação (*r*) (Equação 14), erro quadrático médio (*RMSE*) (Equação 15) e *viés* (Equação 16). Também foi realizada uma análise gráfica dos valores observados em relação aos estimados e do histograma dos erros percentuais (Equação 21).

$$E = \frac{\left(\hat{y}_i - y_i\right)}{y_i} \ 100 \tag{21}$$

Em que: E = erro em porcentagem entre a variável dependente observada e estimada; \hat{y}_i = variável dependente estimada; y_i = variável dependente observada.

4.6.4. Espacialização das variáveis biofísicas

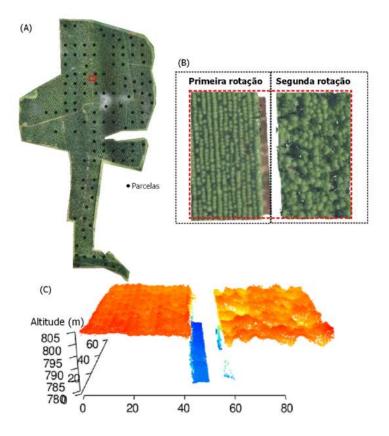
Após a seleção dos melhores modelos, foram elaborados mapas com a espacialização da área basal e do volume de madeira de povoamentos de eucalipto. De forma complementar, foram utilizados os dados de toda a área de estudo obtidos nos mapas para comparar a diferença percentual entre as médias estimadas a partir das diferentes fontes de dados (IO, FAD e a combinação IO e FAD) com as obtidas no inventário florestal tradicional.

5. RESULTADOS

5.1. Processamento da nuvem de pontos pelo algoritmo SfM e elaboração do modelo digital do terreno

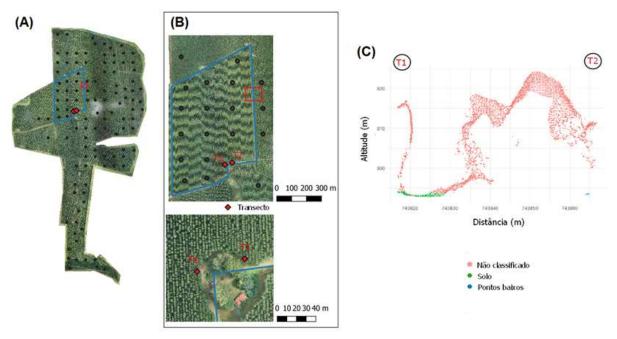
Na Figura 9 está representado um recorte da nuvem de pontos da FAD entre dois talhões em primeira e segunda rotação. Analisando a nuvem de pontos, é possível verificar que a reconstrução tridimensional pelo processo de fotogrametria foi capaz de representar a diferença na estrutura do dossel nos talhões nas diferentes rotações. Isso pode ser observado pela uniformidade do dossel no talhão de primeira rotação e irregularidade no de segunda.

Figura 9 – Representação da nuvem de pontos em talhões de primeira e segunda rotação. (A) Ortomosaico com composição cromática RGB da área de estudo. (B) Vista superior da nuvem de pontos RGB com destaque nos talhões em primeira e segunda rotação. (C) Vista frontal da nuvem de pontos.



Uma amostra do resultado da classificação da nuvem de pontos encontra-se na Figura 10. Ao observar o transecto entre os pontos T1 e T2 (Figura 10C), é possível notar que o algoritmo de classificação conseguiu representar satisfatoriamente o relevo da área de estudo, pois os pontos mais baixos da nuvem foram classificados como solo (pontos na cor verde da Figura 10C). Apesar da modelagem do terreno ser uma das principais limitações da FAD em estudo em áreas com florestas (ALMEIDA et al., 2020), as configurações de voo, as características do plantio e do relevo da área, além do algoritmo de classificação utilizado, possibilitaram uma classificação adequada.

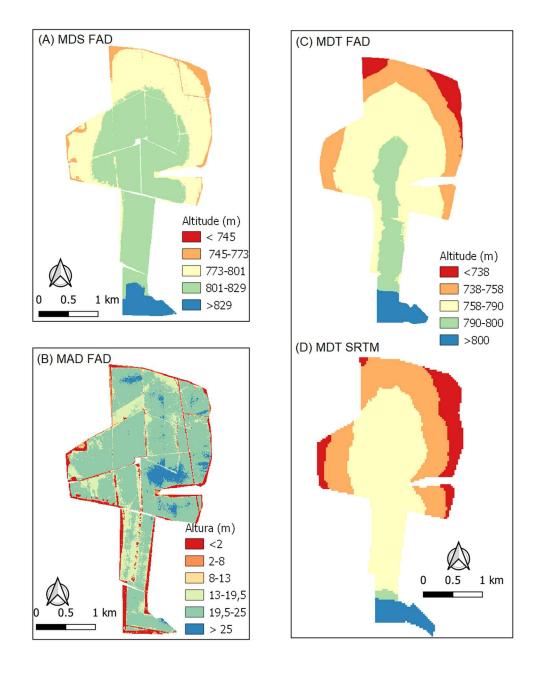
Figura 10 – Representação da classificação da nuvem de pontos da Fotogrametria Aérea Digital. (A) Ortomosaico com composição cromática RGB da área de estudo. (B) Vista superior da nuvem da FAD RGB com destaque para o transecto entre os pontos T1 e T2. (C) Classificação dos pontos da nuvem da FAD.



Na Figura 11, pode-se verificar o modelo digital de superfície – MDS (A), o MAD (B) e o MDT (C) para toda a área de estudo, interpolado pelo método TIN a partir dos pontos classificados como solo na nuvem de pontos da FAD. Ao comparar o MDT da FAD (Figura 11C) com o do SRTM (Figura 11D), é possível notar que as classes de

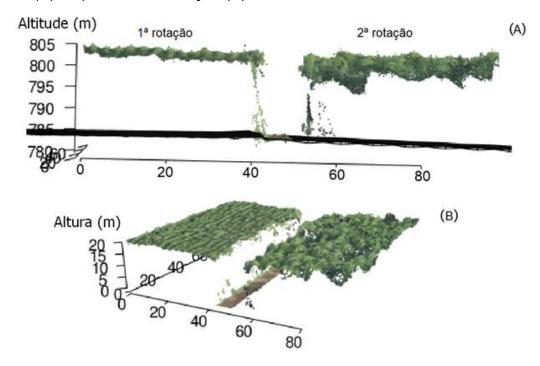
altitude foram próximas, sendo que o da FAD possui um maior grau de detalhamento, com representação da classe de 790 a 800 m na parte central do povoamento.

Figura 11 – Representação do MDS, MAD e MDT gerados pela nuvem de pontos e o MDT do SRTM.



Após a elaboração do MDT, foi realizada a normalização da nuvem de pontos. Na Figura 12A é possível observar um recorte da nuvem de pontos em talhões de primeira e segunda rotação (esquerda e direita, respectivamente) juntamente com o MDT e na Figura 12B, a nuvem de pontos após a normalização.

Figura 12 – Vista frontal da nuvem de pontos em áreas de primeira e segunda rotação com o MDT (A) e após a normalização (B).



5.2. Avaliação dos produtos da Fotogrametria Aérea Digital

Para analisar espacialmente o comportamento do MAD em relação às alturas obtidas nas parcelas do inventário, foi gerado o mapa da Figura 13. É possível verificar que, de modo geral, as alturas medidas no inventário estão condizentes com as classes de altura do MAD.

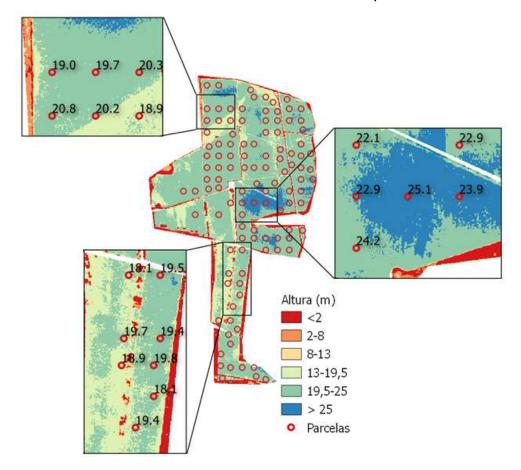


Figura 13 – Classes de altura do MAD e altura média das parcelas de inventário.

Na Figura 14 estão os gráficos de dispersão utilizados para avaliar a classificação da nuvem de pontos e o MDT. É possível observar que, em ambos os casos, a correlação foi moderada entre as variáveis, com baixos valores de *RMSE* e *viés*, sendo que o melhor desempenho foi obtido por *Hmax*. Além disso, a dispersão entre os valores das métricas e a *HD* observada ficou próxima à linha 1:1. A análise dos gráficos e das estatísticas indica que a classificação da nuvem de pontos foi eficiente e que o MDT gerado é representativo da área de estudo.

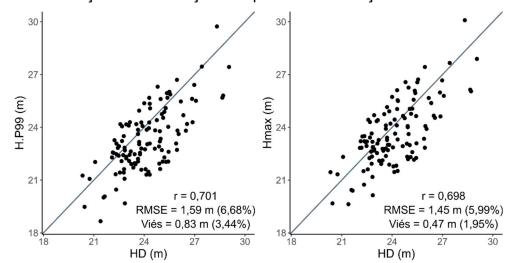


Figura 14 – Validação da localização das parcelas em função da altura dominante.

5.3. Avaliação do erro de posicionamento das parcelas em campo

Os valores de *Hmin*, *H.P50* e *Hmax* obtidos na simulação do deslocamento das parcelas estão apresentados na Figura 15. Em todas as direções de deslocamento os valores das variáveis foram próximos, não havendo diferença significativa (p-valor > 0,05) entre as médias pelo teste *t-Student* para dados pareados. Isso mostra que, mesmo se o GNSS deslocasse o centro da parcela em até 5 metros, a obtenção das métricas da nuvem de pontos não seria afetada negativamente.

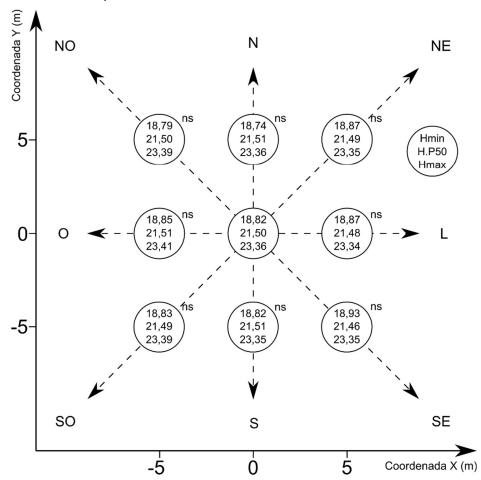


Figura 15 – Influência do deslocamento das parcelas de inventário na obtenção das métricas da nuvem de pontos.

Em que: Hmin = altura mínima da nuvem de pontos da FAD; H.P50 = altura do 50° percentil da nuvem de pontos da FAD; Hmax = altura máxima da nuvem de pontos da FAD; ns = diferença não significativa pelo teste t-Student para dados pareados (p-valor > 0,05).

5.4. Variáveis selecionadas para os modelos de regressão linear múltipla

Os modelos que apresentaram melhor desempenho com valores de FIV menor que 10 e seus respectivos parâmetros estimados estão apresentados na Tabela 7. De modo geral, todos os coeficientes associados a variáveis foram significativos (p-valor < 0,05), indicando que as variáveis preditoras selecionadas possuem relação com a variável resposta.

Tabela 7 – Modelos selecionados para estimar as variáveis biofísicas a partir de diferentes fontes de dados.

IO
$$\widehat{G} = 56,347^* + 1.690,381B3^* - 735,089B5^* - 167,903B6^*$$

$$\widehat{V} = 601,25^* + 23.465,81B3^* - 8.354,79B5^* - 2.437,37B6^*$$
FAD
$$\widehat{G} = 3,678^{ns} - 1,070Hmode^* + 2,126H.P01^*$$

$$\widehat{V} = 60,944^{ns} + 14,946H.P01^* - 2,766PFAmean^*$$
IO e FAD
$$\widehat{G} = 37,96^* + 0,9335H.P20^* - 0,00498FAmean^* + 1.008B3^* - 499,4B5^* - 121,2B6^*$$

$$\widehat{V} = 22,259^{ns} + 13,796H.P01^* + 10.463,035B4^* - 5.050,465B5^*$$

Em que: \hat{G} = área basal estimada (m²ha⁻¹); \hat{V} = volume estimado por hectare (m³ha⁻¹); B3 = verde, B5 = borda do vermelho 1 e B6 = borda do vermelho 2; Hmode = moda da altura; H.P01 = altura do 1º percentil; H.P20 = altura do 20º percentil; PFAmean = percentual dos primeiros retornos acima da média; FAmean = primeiros retornos acima da média; * = significativo (p-valor < 0,05); ns = não significativo (p-valor>0,05).

Para a modelagem de *G* e *V* a partir da IO, foram selecionadas as mesmas variáveis preditoras: *B3* (verde), *B5* (borda do vermelho 1) e *B6* (borda do vermelho 2). Essas mesmas variáveis foram selecionadas para a estimação da *G* pela combinação de dados de IO e FAD.

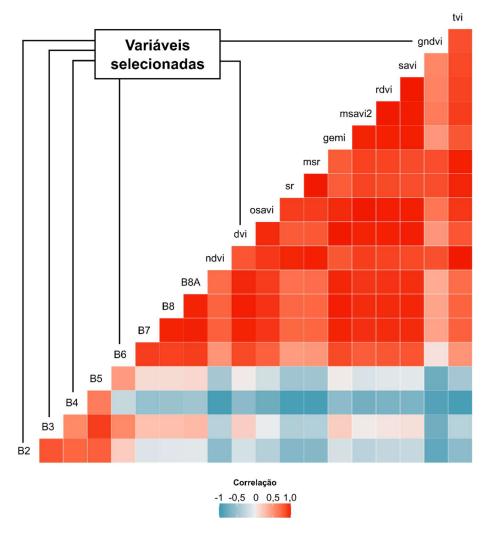
Em relação às variáveis selecionadas da FAD, nota-se que a *H.P01* esteve presente nos modelos de RLM para a estimação da *G* e do *V*, e também para a estimação do *V* para a combinação de IO e FAD. De acordo com Leite et al. (2020), os percentis de altura normalmente aparecem em estudos sobre a modelagem de *V*, sendo pelo menos um percentil de altura selecionado.

5.5. Variáveis selecionadas para a modelagem por redes neurais artificiais

As correlações entre as variáveis obtidas a partir das IO e FAD podem ser observadas nas Figuras 16 e 17, respectivamente. Dentre as variáveis extraídas da IO, as que foram selecionadas para a modelagem da área basal e volume foram *B2*,

B3, B4, B6, DVI e GNDVI. Para a FAD, as variáveis preditoras selecionadas foram Hmin, Hmax, Hsd, Hskew, Hkurt, CRR e FRA12. Para a combinação de IO e FAD, foram utilizadas todas as variáveis selecionadas anteriormente.

Figura 16 – Coeficientes de correlação entre as variáveis obtidas a partir da imagem orbital.

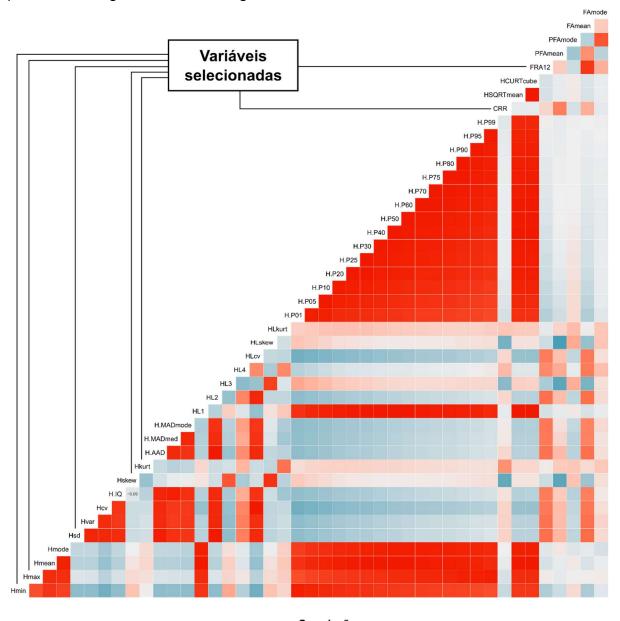


Diferentemente da modelagem por RLM, para a IO a *B5* não foi selecionada pela sua forte correlação com a *B3* (Figura 16). Além disso, muitos índices de vegetação foram excluídos, uma vez que são calculados a partir das mesmas bandas, sendo altamente correlacionados.

O grande número de variáveis da FAD excluídas provavelmente ocorreu devido a nuvem de pontos representar apenas o topo do dossel da floresta, causando forte correlação entre as variáveis. Ao contrário do constatado por Leite et al. (2020),

nenhum outro percentil de altura foi selecionado, pois são fortemente correlacionados com *Hmin* ou *Hmax* (Figura 17).

Figura 17 – Coeficientes de correlação entre as variáveis obtidas a partir da nuvem de pontos da fotogrametria aérea digital e variáveis selecionadas.





5.6. Parametrização das redes neurais artificiais

Nas Figuras 18 e 19 é possível visualizar a relação entre os valores de *RMSE*, do conjunto de treino e de validação, em função do número de neurônios da camada oculta, para a estimação da área basal e volume, respectivamente. É possível observar que, à medida que o número de neurônios aumenta, o *RMSE* do treino tende a diminuir e o da validação aumentar. Isso indica que em redes mais complexas (maior número de neurônios) ocorre o *overfitting*, fazendo com que a RNA perca a sua capacidade de generalização.

Figura 18 – Seleção da função de ativação e número de neurônios da RNA para a estimação da área basal de povoamentos de eucalipto. Treino = - - -; validação = —; e ponto em que ocorre o menor *RMSE* na validação = |.

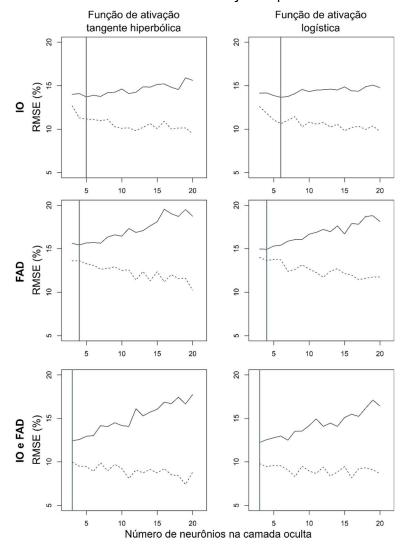
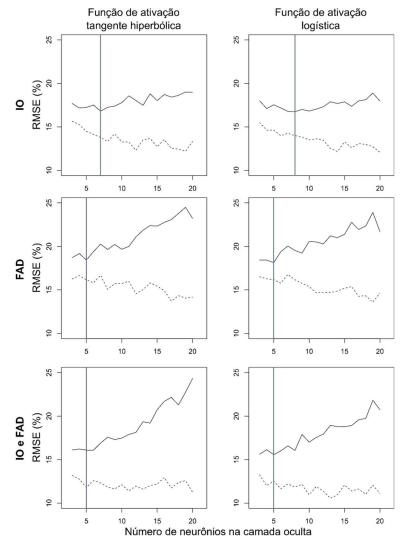


Figura 19 – Seleção da função de ativação e número de neurônios da *RNA* para a estimação do volume de povoamentos de eucalipto. Treino = - - -; validação = -; e ponto em que ocorre o menor *RMSE* na validação = |.



A configuração selecionada para cada variável resposta, de acordo com a fonte de dados, está apresentada na Tabela 8. Em geral, foram necessários no máximo oito neurônios para estimar as variáveis de interesse. Isso indica que, mesmo com poucos neurônios, as RNA possuem a capacidade de reconhecer os padrões e as relações entre as variáveis preditoras e as respostas.

Tabela 8 – Configurações selecionadas das RNA para a estimação das variáveis biofísicas.

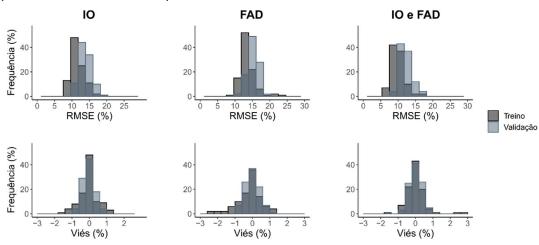
Fonte de dados _	(3	V		
i onte de dados _	F.A.	N.N.	F.A.	N.N.	
Ю	Log.	6	Log.	8	
FAD	Log.	4	Log.	5	
IO e FAD	Log.	3	Log.	5	

Em que: F.A. = função de ativação da camada oculta; N.N. = número de neurônios; Log. = função de ativação logística; Tan. = função de ativação tangente hiperbólica; IO = imagem orbital; FAD = fotogrametria aérea digital; G = área basal (m^2 ha⁻¹); V = volume (m^3 ha⁻¹).

Nas Figuras 20 e 21 é possível observar a distribuição dos valores de *RMSE* e *viés* por meio de histogramas. De modo geral, os valores de *RMSE* e *viés* encontrados tiveram distribuição aproximadamente normal.

Em relação aos histogramas do *RMSE* (Figuras 20 e 21), é possível notar que os valores da validação tiveram médias superiores às do treino, sendo a diferença entre essas médias iguais a 4,30, 2,34 e 3,69 pontos percentuais para IO, FAD e a combinação IO e FAD, respectivamente. A variável que apresentou maior diferença entre *RMSE* do treino e validação foi o volume estimado por IO e por FAD. Quando se avalia o *viés*, é possível observar que, para as variáveis área basal e volume, as distribuições tiveram uma tendência leptocúrtica.

Figura 20 – Histogramas com valores de *RMSE* e *viés* para e estimação da área basal dos povoamentos de eucalipto, considerando as 100 redes neurais treinadas.



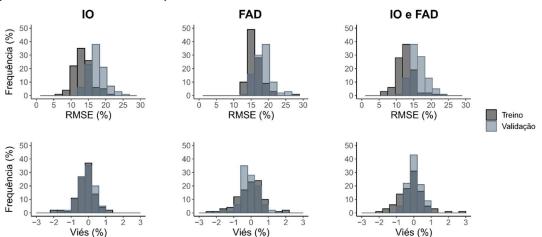


Figura 21 – Histogramas com valores de *RMSE* e *viés* para e estimação do volume dos povoamentos de eucalipto, considerando as 100 redes neurais treinadas.

5.7. Modelagem das variáveis biofísicas

5.7.1. Modelagem da área basal de povoamentos de eucalipto

As estatísticas para avaliar o desempenho das alternativas de estimação de área basal encontram-se na Tabela 9. Ao observar as estatísticas calculadas para a RLM, nota-se que os valores de *r*, *RMSE* e *viés* calculados com os dados de IO e FAD isoladamente foram muito próximos tanto no treino quanto na validação. O melhor desempenho foi obtido pela combinação dos dados de IO e FAD, com uma diferença de *RMSE* da validação de, aproximadamente, 31,6% e 16,6% em relação ao uso de dados de IO e FAD, respectivamente.

A modelagem por RNA resultou em uma melhoria nos valores de *r* do IO e da FAD. Em relação ao *RMSE*, houve uma redução de 19,4% da validação da IO em relação ao RLM. O mesmo aconteceu com a FAD, porém em menor magnitude (8,1%). Já para a combinação de IO e FAD não houve ganho nas três estatísticas analisadas, sendo as estimativas da RLM mais acuradas. As estimativas de *G* pelos métodos de estimação não foram viesadas (*viés* < 1%). Embora as estatísticas da RLM tenham sido mais estáveis entre os conjuntos de ajuste e validação, as RNA se

mostraram superiores para estimar a área basal a partir dos dados de IO e da FAD, sendo a RLM melhor para os dados de IO e FAD combinados.

Tabela 9 – Resultado das estatísticas para avaliar a acurácia da estimação da área basal pelas diferentes fontes de dados.

		Ю	F	AD	IO e FAD			
Estatísticas	Regressão Linear Múltipla							
-	Ajuste	Validação	Ajuste	Validação	Ajuste	Validação		
r	0,6544	0,6373	0,6836	0,6886	0,8661	0,8112		
RMSE (%)	13,43	16,40	13,52	14,53	8,88	12,46		
Viés (%)	0,00	-0,95	0,00	-0,75	0,00	-0,08		
	Redes neurais artificiais							
-	Treino	Validação	Treino	Validação	Treino	Validação		
r	0,8404	0,6994	0,8420	0,7418	0,8903	0,7733		
RMSE (%)	10,47	13,22	10,02	13,36	8,48	12,81		
Viés (%)	0,16	0,14	0,05	0,10	0,14	-0,11		

Em que: *r* = coeficiente de correlação entre valores observados e estimados; e *RMSE* = erro quadrático médio.

Nas Figuras 22 e 23, estão apresentados os gráficos dos valores observados e estimados e os histogramas dos erros percentuais da área basal por RLM e RNA, respectivamente, para as diferentes fontes de dados analisadas. É possível observar no gráfico da dispersão entre valores observados e estimados da RLM, que as estimativas feitas na validação pela IO e pela FAD tiveram uma tendência de subestimação em valores de *G* acima de 25 m²ha-1, indicando um problema de saturação. Para a combinação de dados de IO e FAD, houve uma boa distribuição dos valores em torno da linha 1:1, sem efeito evidente de saturação. Em geral, houve uma melhor dispersão dos valores estimados pelas RNA, sem efeito claro de saturação observado, independentemente da fonte de dados. Quanto aos histogramas, observa-se que em todos os casos a média foi próxima de zero, com aproximadamente 60% dos valores de erro entre ± 15%.

Figura 22 – Relação entre valores observados e estimados de área basal por RLM e histograma dos erros percentuais.

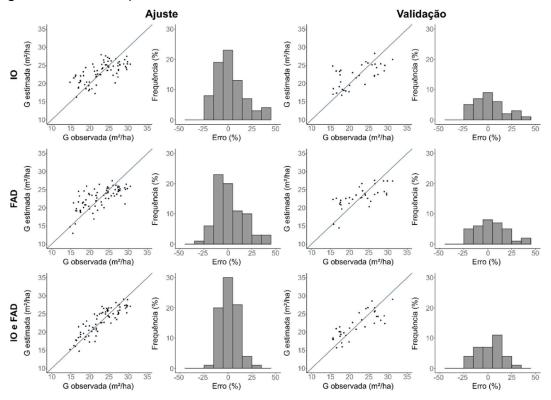
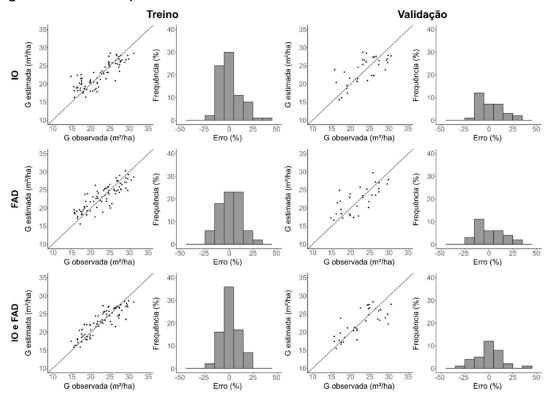


Figura 23 - Relação entre valores observados e estimados de área basal por RNA e histograma dos erros percentuais.



5.7.2. Modelagem do volume total de povoamentos de eucalipto

Analisando as estatísticas de acurácia para a estimação do volume (Tabela 10), verifica-se que a aplicação das RNA apresentou melhores resultados para os dados de IO quando comparado com os obtidos pela RLM. Também houve uma melhoria nas estatísticas de validação da FAD com o uso de RNA, passando a correlação de moderada a forte e reduzindo o *RMSE* em aproximadamente 8,9%.

Assim como na área basal, os valores estimados pela combinação IO e FAD foram próximos, tanto para RLM quanto para RNA. Embora o *RMSE* da validação da combinação IO e FAD por RNA tenha ficado, aproximadamente, 5,7% maior que o da RLM, o *r* e o *viés* foram melhores para a RNA. Para todas as fontes de dados para a estimação do volume, as RNA apresentaram melhores resultados. Dentre as fontes de dados, os melhores resultados foram obtidos pela combinação IO e FAD, seguido pela FAD e IO, assim como na modelagem de *G*.

Tabela 10 – Resultado das estatísticas para avaliar a acurácia da estimação do volume pelas diferentes fontes de dados.

		Ю	F	AD	IO e FAD		
Estatísticas	Regressão Linear Múltipla						
-	Ajuste	Validação	Ajuste	Validação	Ajuste	Validação	
r	0,6866	0,5256	0,6935	0,5363	0,8222	0,7197	
RMSE (%)	16,91	18,94	16,76	18,17	13,24	14,14	
Viés (%)	0,00	-2,71	0,00	0,32	0,00	-1,45	
	Redes neurais artificiais						

	Treino	Validação	Treino	Validação	Treino	Validação		
r	0,8247	0,7578	0,7545	0,7022	0,8511	0,7325		
RMSE (%)	12,80	15,05	14,63	16,68	12,25	14,99		
Viés (%)	0,31	-0,29	-0,10	-0,07	0,57	0,29		

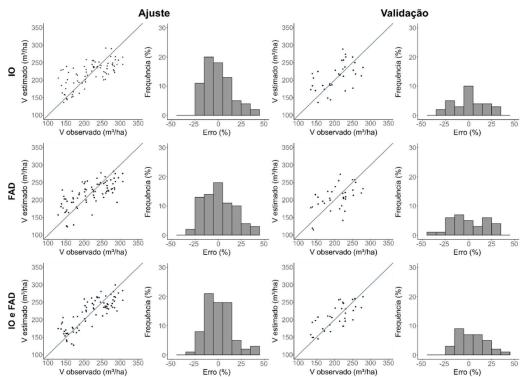
Em que: r = coeficiente de correlação entre valores observados e estimados; e RMSE = erro quadrático médio.

As estatísticas da Tabela 10 corroboram com os gráficos dos valores observados e estimados presentes nas Figuras 24 e 25, nos quais é possível observar

que houve uma melhor distribuição dos valores para a RNA, que ficaram próximas à linha 1:1 nas três fontes de dados. Além disso, é possível observar uma tendência de superestimação no ajuste por RLM a partir de dados das IO na faixa de 150 a 200 m³ha⁻¹. Além disso, nos gráficos de ajuste da RLM nota-se uma possível saturação com os dados de IO e FAD isoladamente, o que não ocorre ao utilizar a combinação destes dados.

Nos histogramas, os erros percentuais da validação ficaram mais bem distribuídos nas estimativas feitas pelas RNA, com distribuição normal. Nota-se que em todos os casos a média foi próxima de zero, não havendo tendência de sub ou superestimação.

Figura 24 – Relação entre valores observados e estimados de volume por RLM e histograma dos erros percentuais.



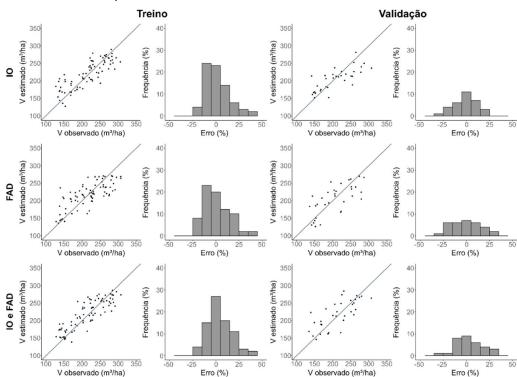


Figura 25 – Relação entre valores observados e estimados de volume por RNA e histograma dos erros percentuais.

5.8. Espacialização das variáveis biofísicas

Na Tabela 11 encontra-se uma comparação entre os valores médios de área basal e volume obtidos no inventário florestal tradicional e pela espacialização dessas variáveis para os dois métodos de estimação e para as três fontes de dados.

Dentre os resultados obtidos pela modelagem por RLM, a menor diferença com o inventário florestal ocorreu ao utilizar dados da IO, tanto para *G* quanto para *V*. Já para os resultados obtidos por RNA para *G* e *V*, o mais próximo do inventário foi pela combinação de IO e FAD, seguido pela FAD e IO, respectivamente, seguindo a tendência dos resultados em nível de parcela.

Em relação aos métodos de estimação, é possível observar que as RNA apresentaram maior capacidade de generalização, com resultados mais acurados e próximos do inventário florestal tradicional para as três fontes de dados. De modo

geral, os melhores resultados foram obtidos pela modelagem por RNA utilizando a combinação dos dados de IO e FAD.

Tabela 11 – Comparação entre os resultados do inventário e os estimados para toda a área pelas diferentes fontes de dados.

Variável	Média do	Ю		FAD		IO e FAD	
estimada	inventário	RLM					
G (m ² ha ⁻¹)	22,19	22,96	(3,5%)	20,31	(-8,5%)	18,84	(-15,1%)
V (m³ha-¹)	208,30	219,87	(5,6%)	189,68	(-8,9%)	191,51	(-8,1%)
		RNA					
G (m ² ha ⁻¹)	22,19	22,90	(3,2%)	22,59	(1,8%)	22,12	(-0,3%)
V (m³ha-1)	208,30	212,95	(2,2%)	203,51	(-2,3%)	209,18	(0,4%)

Em que: IO = imagem orbital; FAD = fotogrametria aérea digital; G = área basal (m²ha⁻¹); V = volume (m³ha⁻¹).

A espacialização das variáveis biofísicas estimadas por RNA para as três fontes de dados está representada na Figura 26. É possível observar que, mesmo que os mapas gerados pelas diferentes fontes de dados tenham ficado diferentes, houve concordância na localização das regiões mais e menos produtivas para as duas variáveis estimadas.

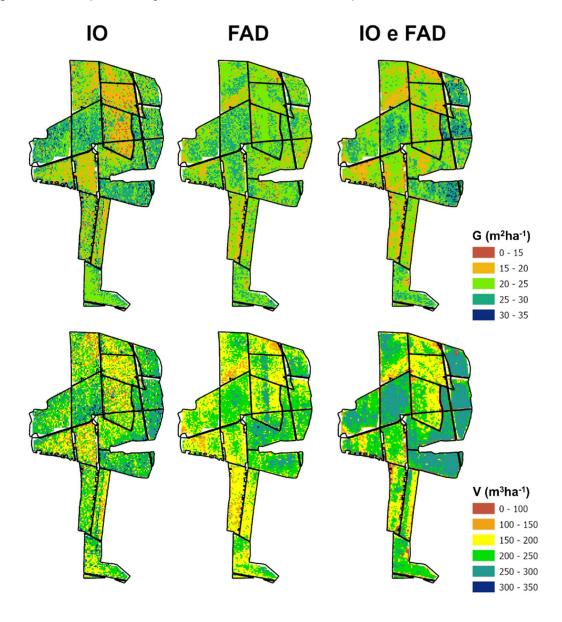


Figura 26 – Espacialização das variáveis biofísicas pelas diferentes fontes de dados.

6. DISCUSSÃO

6.1. Relações entre as variáveis preditoras selecionadas e as variáveis resposta

As variáveis selecionadas para a modelagem a partir da IO por RLM e RNA foram as bandas do visível (*B2*, *B3* e *B4*), a borda do vermelho 1 e 2 (*B5* e *B6*, respectivamente) e os índices de vegetação *DVI* e *GNDVI*. As bandas da região visível do espectro eletromagnético geralmente apresentam baixos valores de reflectância, pois as plantas verdes, como o eucalipto, evoluíram de modo que seus pigmentos absorvessem maiores taxas dessa REM (PONZONI; SHIMABUKURO; KUPLICH, 2015).

Há uma maior absorção da REM referente às bandas do azul e vermelho pela clorofila quando comparado com a banda verde, dando a coloração verde à vegetação. À medida que a vegetação amadurece, seu dossel absorve maior quantidade de energia eletromagnética na banda do vermelho para processos fotossintéticos (JENSEN, 2015). Assim, a reflectância na banda do vermelho pode estar relacionada à produtividade da floresta.

As bandas da borda do vermelho são importantes para análises da vegetação, pois a sua reflectância é sensível às alterações nos conteúdos de água e clorofila das células vegetais, estresses causados por salinidade do solo e incidência de pragas ou doenças (SHIMADA et al., 2014; SOUZA et al., 2009).

Os índices de vegetação selecionados (*DVI* e *GNDVI*) expressam o vigor vegetativo das plantas por meio de uma relação entre a banda do infravermelho próximo e as bandas do visível vermelho e verde, respectivamente. A região do infravermelho próximo é altamente refletida pelas plantas, havendo uma relação direta com a biomassa, ou seja, à medida que a floresta se desenvolve há um aumento na reflectância dessa banda (JENSEN, 2015).

As variáveis selecionadas da FAD foram *Hmin*, *Hmax*, *Hmode*, *Hsd*, *Hshew*, *Hkurt*, *H.P01*, *H.P20*, *CRR*, *FRA12*, *PFAmean e FAmean*. Diferentemente das variáveis oriundas das IO, algumas das métricas extraídas da nuvem de pontos da FAD possuem uma relação mais direta com a *G* e o *V* dos povoamentos, uma vez que

são baseadas na altura do dossel. Por exemplo, as métricas de altura relativa do 99º percentil (*H.P99*) e altura máxima da nuvem de pontos da FAD (*Hmax*), possuem uma relação linear com a altura dominante (Figura 14) e esta está diretamente ligada a capacidade produtiva do local (BATISTA et al., 2014; KERSHAW JR. et al., 2017).

Diante do exposto, fica evidente que o conhecimento da relação teórica entre as variáveis preditoras e resposta é fundamental em estudos sobre a modelagem de variáveis biofísicas. Entretanto, em alguns casos, não há uma relação direta ou não se conhece a relação entre essas variáveis. De acordo com Fernandes (2017), quando essa relação é desconhecida, se torna mais complexo o processo de estimação, o que evidencia a necessidade de mais estudos teóricos com essa abordagem.

6.2. Métodos de estimação de área basal e volume de povoamentos de eucalipto

Uma das principais vantagens ao realizar inventário florestal com dados de sensoriamento remoto é o recobrimento total da área e a possibilidade da espacialização das variáveis de interesse. Assim, mesmo que em alguns casos a RLM tenha apresentado resultados mais acurados em nível de parcela, o mais importante a se considerar é a capacidade de generalização do método de estimação e os resultados obtidos para toda a área. Nesse caso, a RLM não conseguiu gerar estimativas acuradas para toda a área de estudo (Tabela 11), isso pode ter acontecido pois ao extrapolar os resultados, foram geradas estimativas a partir de dados fora do intervalo dos dados utilizados no processo de ajuste dos modelos.

De acordo com Bussab e Morettin (2017), essa é uma das limitações da regressão linear, pois a relação entre as variáveis preditoras e resposta não pode ser estendida para fora dos limites dos dados observados sem que haja informações que validem essa aplicação. Desta forma, mesmo que o conjunto de dados tenha sido dividido em ajuste e validação, como a amostragem do inventário cobriu apenas uma pequena fração dos talhões (menos que 1% da área), é esperado que algumas regiões possuam uma relação entre variáveis preditoras e resposta diferente da

observada no conjunto de ajuste dos modelos e, com isso, a RLM não consiga gerar estimativas acuradas para esses locais.

Nesse sentido, as RNA se mostraram mais aptas para realizar a espacialização das variáveis *G* e *V* para a área de estudo, com resultados mais próximos aos obtidos pelo inventário florestal tradicional (Tabela 11). Os melhores resultados obtidos pelas RNA podem ser explicados por uma série de características desse método de estimação que, segundo Haykin (2001), são o caráter não linear, a capacidade de incorporar redundâncias e reconhecer padrões, e a flexibilidade no atendimento a critérios de generalização. Essas características permitem reconhecer os padrões entre as variáveis e extrapolar para novos dados o conhecimento adquirido na fase de treinamento (BRAGA et al., 2012; HAYKIN, 2001).

Outros autores também obtiveram resultados acurados ao utilizar RNA para estimar variáveis biofísicas em função de variáveis medidas no inventário florestal tradicional (BINOTI et al., 2015; VIEIRA et al., 2018) e dados de sensoriamento remoto (GONÇALVES, 2018; FERNANDES, 2017; SANTOS, 2020). Entretanto, é importante a avaliação de outros métodos não paramétricos de estimação, como a Random Forest (RF) e Support Vector Machine (SVM) que podem gerar resultados satisfatórios (DALLA CORTE et al., 2020a; GARCÍA-GUTIÉRREZ et al., LEITE et al., 2020; REIS et al., 2018).

6.3. Fontes de dados para estimar a área basal e volume de povoamentos de eucalipto

Considerando os resultados obtidos para toda a área de estudo por RNA, que foi o melhor método de estimação, a combinação de dados de IO e FAD gerou resultados mais próximos do inventário florestal tradicional, seguido pela modelagem por dados da FAD e da IO. Esses resultados estão de acordo com outros trabalhos encontrados na literatura, que também obtiveram resultados mais acurados na modelagem a partir de dados da FAD que os obtidos por IO (PULITI et al., 2017a; SHEN et al., 2019; WITTKE et al., 2019).

Os resultados da modelagem com as métricas da FAD neste estudo estão compatíveis com os trabalhos encontrados na literatura em termos de acurácia (CAO et al., 2019; IQBAL et al., 2018; JAYATHUNGA et al., 2018; PULITI et al., 2015; WITTKE et al., 2019). Entretanto, é importante ressaltar que na maioria desses trabalhos, a normalização da nuvem de pontos da FAD foi realizada com o MDT proveniente do LiDAR. Isso mostra que a elaboração do MDT a partir da nuvem de pontos da FAD no presente estudo foi satisfatória, assim como encontrado por Almeida et al. (2020).

Apesar de apresentar um desempenho inferior aos obtidos por dados tridimensionais com o uso de RNA, o resultado da modelagem apenas por dados de IO foi muito próximo dos obtidos pelo inventário florestal tradicional (Tabela 11). Assim, quando os custos forem um fator limitante, podem ser utilizadas apenas as variáveis obtidas das IO para a modelagem. Além disso, uma vantagem destacada por Wittke et al. (2019), é que os dados multiespectrais de satélites possuem cobertura global e uma frequência regular de revisita. No caso do sensor MSI/Sentinel-2 utilizado neste estudo, o tempo de revisita é de 5 dias. Portanto, a modelagem a partir de IO também pode ser recomendada quando se deseja realizar o monitoramento periódico de grandes áreas florestais. Entretanto, o uso apenas de dados de IO pode apresentar algumas limitações decorrentes variação sazonal da resposta espectral dos povoamentos e saturação em plantios com alto volume.

Outros instrumentos sensores orbitais multiespectrais também têm seus dados disponibilizados gratuitamente e podem ser utilizados como fontes de dados para a modelagem de variáveis biofísicas, como aqueles a bordo dos satélites da série Landsat. A principal diferença entre o sensor OLI/Landsat 8 e o utilizado neste estudo é que o primeiro possui uma menor resolução espacial (30 metros). Por outro lado, sua resolução radiométrica é superior, com 16 bits de resolução contra 12 bits do sensor MSI/Sentinel-2. Essa diferença pode influenciar na acurácia das estimativas. Entretanto, a modelagem a partir de dados do sensor MSI/Sentinel-2 tende a apresentar resultados mais acurados (ASTOLA et al., 2019; BAR et al., 2020; KORHONEN et al., 2017).

A utilização apenas de dados da FAD para a modelagem de G e V não se mostrou uma alternativa interessante. Mesmo que os resultados obtidos por essa fonte de dados tenham sido próximos aos obtidos no inventário florestal tradicional, a

inclusão de métricas da IO pode gerar um ganho de acurácia nas estimativas sem um aumento dos custos de aquisição dos dados, uma vez que as IO são disponibilizadas gratuitamente. Quando o objetivo do inventário for obter a maior acurácia na estimação de *G* e *V*, é necessária a realização de um levantamento aerofotogramétrico e a obtenção de IO, uma vez que essa combinação tende a apresentar melhores resultados.

Nos levantamentos aerofotogramétricos, uma série de parâmetros devem ser analisados para a obtenção de bons resultados no processamento das nuvens de pontos, como a altura e velocidade de voo, ângulo de inclinação da câmera e a taxa de sobreposição longitudinal e lateral dos pares estereoscópicos. Analisando a taxa de sobreposição, Domingo et al. (2019) avaliaram o efeito de duas diferentes sobreposições laterais (70 e 80%) e concluíram que, ao manter uma sobreposição longitudinal de 90%, é possível diminuir a sobreposição lateral para 70%, reduzindo assim o tempo de voo, número de imagens obtidas e os custos da atividade. Isso mostra que seria possível reduzir consideravelmente a taxa de sobreposição lateral utilizada no presente estudo, o que iria reduzir os custos do levantamento aerofotogramétrico sem uma perda de acurácia na estimação de *G* e *V*.

Outro fator que influencia na modelagem de variáveis biofísicas de florestas por dados de sensoriamento remoto, bi ou tridimensional, é o tamanho das parcelas medidas em campo. Espera-se que, ao utilizar parcelas maiores, haja uma redução da variância dentro das parcelas, tornando-as mais representativas da área e, consequentemente, haja um ganho de acurácia nos processos de modelagem (KERSHAW JR. et al., 2017). Por outro lado, o aumento da área da parcela resulta em maior tempo de medição e maiores custos.

Considerando essa hipótese, Kachamba et al. (2017) avaliaram a influência de parcelas de 250, 500, 750 e 1000 m² na eficiência da estimação de biomassa em uma floresta tropical seca por FAD. Os resultados obtidos mostraram que os valores de erro diminuem com o aumento do tamanho da parcela, o que já era esperado. Além disso, ao analisar os custos e a eficiência relativa, os autores concluíram que houve uma compensação dos custos de mensuração de parcelas maiores pelo ganho em acurácia. Assim, mesmo que as estimativas do presente estudo tenham apresentado resultados satisfatórios, elas poderiam ser obtidas com maior acurácia caso fossem utilizadas parcelas com áreas maiores.

Ainda em relação aos custos, uma vantagem da realização do inventário florestal por sensoriamento remoto é a possibilidade da redução do número de parcelas mensuradas em campo. Nesse sentido, Santos (2020) simulou diferentes cenários de redução na intensidade amostral do inventário para predição e projeção da produtividade volumétrica de plantios de eucalipto. Os resultados deste estudo permitiram uma redução de até 75% no número de parcelas mensuradas, mantendo as estimativas de volume dentro do intervalo de confiança do inventário florestal. Além da redução de custos, a mensuração de menos parcelas em campo possibilita maior agilidade na obtenção dos resultados.

Outra vantagem do inventário florestal por técnicas de sensoriamento remoto é a obtenção de informações mais detalhadas das florestas quando comparado com o inventário florestal tradicional. A principal diferença é que, no método tradicional, as informações sobre as variáveis de interesse são obtidas pela amostragem de uma pequena fração da população (abaixo de 1%), o que possibilita gerar uma estimativa média por talhão ou por estrato. Esse valor médio permite ter uma ideia geral da produtividade dos talhões, entretanto, não fornece uma visão detalhada das variações de produtividade existentes dentro de cada povoamento, mesmo que as parcelas sejam distribuídas uniformemente em toda a área. Já no inventário por sensoriamento remoto, as informações são coletadas em 100% da área, sendo possível observar as variáveis de interesse de forma espacializada.

Levando em consideração as novas tendências de mercado da indústria 4.0 em que há a necessidade de informações mais assertivas e de forma ágil, a implementação de inventários florestais por sensoriamento remoto vai de encontro com essas necessidades e representa uma mudança de paradigma no setor florestal.

7. CONCLUSÕES

A nuvem de pontos da fotogrametria aérea digital conseguiu representar satisfatoriamente a estrutura do dossel da floresta e o seu modelo digital do terreno permitiu a normalização da nuvem com valores de altura condizentes com o inventário florestal tradicional.

A modelagem por redes neurais artificiais apresentou maior capacidade de generalização para toda a área de estudo que os modelos de regressão linear múltipla, obtendo resultados mais acurados para estimar a área basal e volume total do povoamento de eucalipto.

O uso de dados de imagens orbitais e fotogrametria aérea digital, isoladamente ou em conjunto, gerou estimativas acuradas de área basal e volume total do povoamento de eucalipto, compatíveis com os obtidos com dados de inventário florestal tradicional.

Os resultados com maior acurácia foram obtidos pela combinação de dados das imagens orbitais e fotogrametria aérea digital. Entretanto, a modelagem apenas por imagens orbitais pode ser recomendada quando os custos dos levantamentos fotogramétricos forem um fator limitante.

REFERÊNCIAS

AGISOFT, L. L. C. Agisoft Photoscan User Manual, Professional Edition, version 1.4: **Agisoft** LLC. 2018.

ALBA, E. et al. Spectral characterization of forest plantations with Landsat 8/OLI images for forest planning and management. **Pesquisa Agropecuária Brasileira**, v.52, n.11, p.1072-1079, 2017.

ALMEIDA, A. et al. Estimating structure and biomass of a secondary Atlantic forest in Brazil using fourier transforms of vertical profiles derived from UAV photogrammetry point clouds. **Remote Sensing**, v. 12, n. 21, p. 3560, 2020.

ALMEIDA, A. et al. Relações empíricas entre características dendrométricas da Caatinga brasileira e dados TM Landsat 5. **Pesquisa Agropecuária Brasileira**, v. 49, n. 4, p. 306–315, 2014.

ALZATE, S. B. A. Caracterização da madeira de árvores de clones de *Eucalyptus grandis, E. saligna* e *E. grandis x urophylla*. 2004. 133 p. Tese (Doutorado em Recursos Florestais) – Escola Superior de Agricultura "Luiz de Queiroz", Universidade de São Paulo, Piracicaba, 2004.

ASTOLA, HEIKKI et al. Comparison of Sentinel-2 and Landsat 8 imagery for forest variable prediction in boreal region. **Remote Sensing of Environment**, v. 223, p. 257-273, 2019.

BAR, S. et al. Landsat-8 and Sentinel-2 based Forest fire burn area mapping using machine learning algorithms on GEE cloud platform over Uttarakhand, Western Himalaya. **Remote Sensing Applications: Society and Environment**, v. 18, p. 100324, 2020.

BARRETT, F. et al. A questionnaire-based review of the operational use of remotely sensed data by national forest inventories. **Remote Sensing of Environment**, v. 174, p. 279-289, 2016.

BARROS, B. S. X.; GUERRA, S. P. S.; BARROS, Z. X.; CATITA, C. M. S.; FERNANDES, J. C. C. Uso de imagens de satélite para cálculo de volume em floresta de eucalipto no município de Botucatu/SP. **Energia na Agricultura**, v.30, n.1, p.60-67, 2015.

BATISTA, J. L. F.; COUTO, H. T. Z. do; SILVA FILHO, D. F. da. **Quantificação de recursos florestais:** árvores, arvoredos e florestas. São Paulo: Oficina de Textos, 2014.

BELMONTE, Adam et al. UAV-derived estimates of forest structure to inform ponderosa pine forest restoration. **Remote Sensing in Ecology and Conservation**, v. 6, n. 2, p. 181-197, 2020.

- BETTINGER, P.; BOSTON, K.; SIRY, J. P.; GREBNER, D. L. Forest Management and Planning. 1. ed. Oxford: Academic Press. 2009. 331p.
- BINOTI, M. L. M.; LEITE, H. G.; BINOTI, D. H. B.; GLERIANI, J. M. Prognose em nível de povoamento de clones de eucalipto empregando redes neurais artificiais. **Cerne**, Lavras, v. 21, n. 1, p. 97-105, 2015.
- BOHLIN, J. et al. Forest variable estimation using photogrammetric matching of digital aerial images in combination with a high-resolution DEM. **Scandinavian Journal of Forest Research.**, v. 27, p. 692-699. 2012.
- BOLTON, Douglas K. et al. Updating stand-level forest inventories using airborne laser scanning and Landsat time series data. **International journal of applied earth observation and geoinformation**, v. 66, p. 174-183, 2018.
- 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.
- BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes neurais**: teoria e aplicações. 2. ed. Rio de Janeiro: LTC, 2012. 226p.
- BREDE, B. et al. Comparing RIEGL RICOPTER UAV LiDAR derived canopy height and DBH with terrestrial LiDAR. **Sensors**, v. 17, n. 10, p. 1–16, 2017.
- BROGE, N. H.; LEBLANC, E. Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. **Remote sensing of environment**, v. 76, n. 2, p. 156-172, 2001.
- BUSSAB, W. O.; MORETTIN, P. A. Estatística básica. Saraiva Educação SA, 2017.
- CAMPOS, J. C. C. et al. **Inventário florestal nacional:** reflorestamento: Minas Gerais. Brasília: IBDF, 1984. 126 p.
- CAMPOS, J. C. C; LEITE, H. G. **Mensuração florestal**: perguntas e respostas. 5. ed., Viçosa: UFV, 2017. 636 p.
- CAO, L. et al. Estimation of forest biomass dynamics in subtropical forests using multi-temporal airborne LiDAR data. **Remote Sensing of Environment**, v. 178, p. 158–171, 2016.
- CAO, Z. et al. Effects of broad bandwidth on the remote sensing of inland waters: Implications for high spatial resolution satellite data applications. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 153, p. 110-122, 2019.
- CARVALHO, S. P. C. **Estimativa volumétrica por modelo misto e tecnologia laser aerotransportado em plantios clonais de** *Eucalyptus sp.* 2013. 104 f. Tese (Doutorado em Ciências) Universidade de São Paulo, Piracicaba, 2013.

- CASSOL, H. L. G. Estimativa de biomassa e estoque de carbono em um fragmento de Floresta Ombrófila Mista com uso de dados ópticos de sensores remotos. 2013. 143 f. Dissertação (Mestrado em Sensoriamento Remoto) Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, 2013.
- CENTENO, Jorge A. Silva. Sensoriamento remoto e processamento de imagens digitais. **Curitiba: UFPR**, v. 219, 2003.
- CHEN, G. et al. Stand age estimation of rubber (*Hevea brasiliensis*) plantations using an integrated pixel- and object-based tree growth model and annual Landsat time series. **ISPRS Journal of Photogrammetry and Remote Sensing**. v. 144, p. 94-104, 2018.
- CHEN, J. M. Evaluation of vegetation indices and a modified simple ratio for boreal applications. **Canadian Journal of Remote Sensing**, v. 22, n. 3, p. 229-242, 1996.
- CLEVERS, J. G. P. W. The derivation of a simplified reflectance model for the estimation of leaf area index. **Remote Sensing of Environment**, v.35, n.1, p.53-70, 1988.
- CLIMATE-DATA. ORG. Dados climáticos para cidades mundiais. 2021 Disponível em < https://pt.climate-data.org/search/?q=monte+alegre+de+minas>. Acesso em 23 fev. 2021.
- COELHO FILHO, L.C.T.; BRITO, J.N. **Fotogrametria digital**. Universidade Estadual do Rio de Janeiro, Rio de Janeiro, 2007.
- CUNLIFFE, A. M.; BRAZIER, R. E.; ANDERSON, K. Ultra-fine grain landscape-scale quantification of dryland vegetation structure with drone-acquired structure-frommotion photogrammetry. **Remote Sensing of Environment**, v. 183, p. 129–143, 2016.
- DALLA CORTE, A. P. et al. Forest inventory with high-density UAV-Lidar: Machine learning approaches for predicting individual tree attributes. **Computers and Electronics in Agriculture**, v. 179, p. 105815, 2020b.
- 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.
- 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, p. 259-276, 2013.
- 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.

DASH, J. P. et al. Assessing very high resolution UAV imagery for monitoring forest health during a simulated disease outbreak. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 131, p. 1–14, 2017.

DECEA. n 415/DGCEA, de 9 de novembro de 2015 (APROVAÇÃO). ICA 100-40, que trata dos "Sistemas de Aeronaves Remotamente Pilotadas e o Acesso ao Espaço Aéreo Brasileiro". Publicado no BCA n° 212, de 19 de novembro de 2015. digitais. Curitiba: Curso de Pós-Graduação em Ciências Geodésicas, 2004. 219p.

DJOMO, Adrien N.; CHIMI, Cédric D. Tree allometric equations for estimation of above, below and total biomass in a tropical moist forest: Case study with application to remote sensing. **Forest Ecology and Management**, v. 391, p. 184-193, 2017.

d'OLIVEIRA, L. G. L. et al. Estudo da variabilidade de índices de vegetação através de imagens do ETM+/LANDSAT 7. **Anais..**. do Simpósio Brasileiro de Sensoriamento Remoto, Florianópolis, Brasil. INPE, 2007. p. 5995-6002.

DOMINGO, D. et al. Effects of uav image resolution, camera type, and image overlap on accuracy of biomass predictions in a tropical woodland. **Remote Sensing**, v. 11, n. 8, p. 948, 2019.

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

FANKHAUSER, K. E.; STRIGUL, N. S.; GATZIOLIS, D. Augmentation of traditional forest inventory and airborne laser scanning with unmanned aerial systems and photogrammetry for forest monitoring. **Remote Sensing**, v. 10, n. 10, p. 1562, 2018.

FAYAD, Ibrahim et al. Aboveground biomass mapping in French Guiana by combining remote sensing, forest inventories and environmental data. **International journal of applied earth observation and geoinformation**, v. 52, p. 502-514, 2016.

FERNANDES, M. R. M. Estimação de área basal, volume e biomassa em um fragmento de caatinga hiperxerófila densa no alto sertão sergipano com base em dados MSI/Sentinel-2. Tese (Doutorado em Ciências Florestais). Universidade Federal do Espírito Santo, Jerônimo Monteiro, 2017. 200p.

FERNANDEZ-GUISURAGA, J. M. et al. Using unmanned aerial vehicles in postfire vegetation survey campaigns through large and heterogeneous areas: Opportunities and challenges. **Sensors**, v. 18, n. 2, p. 2–17, 2018.

FIGUEIREDO, D. 2005. **Conceitos básicos de sensoriamento remoto**. Companhia Nacional de Abastecimento - CONAB. Brasília - DF. Disponível em: http://www.clickgeo.com.br/wp-content/uploads/2013/04/conceitos_sm.pdf. Acesso em: set 2019.

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

- FORKUOR, G. et al. Above-ground biomass mapping in West African dryland forest using Sentinel-1 and 2 datasets-A case study. **Remote Sensing of Environment**, v. 236, p. 111496, 2020.
- FRANKLIN, S. E.; AHMED, O. S. Deciduous tree species classification using object based analysis and machine learning with unmanned aerial vehicle multispectral data. **International Journal of Remote Sensing**, UAS Special issue, p. 5236–5245, 2017.
- FU, X. et al. Assessment of approaches for monitoring forest structure dynamics using bi-temporal digital aerial photogrammetry point clouds. **Remote Sensing of Environment**, v. 255, p. 112300, 2021.
- GARCÍA-GUTIÉRREZ, J. et al. A comparison of machine learning regression techniques for LiDAR-derived estimation of forest variables. **Neurocomputing**, v. 167, p. 24–31, 2015.
- 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.
- GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, New York, v. 58, n. 3, p. 289-298, 1996.
- GOBAKKEN, T. et al. Comparing biophysical forest characteristics estimated from photogrammetric matching of aerial images and airborne laser scanning data. **Scand. J. For. Res.**, v. 30, p. 73-86. 2015.
- GONÇALVES, A. F. A. Estimação de características dendrométricas para Floresta Estacional Semidecidual Submontana com o uso de dados OLI e SRTM. Dissertação (Mestrado em Ciências Florestais). Universidade Federal do Espírito Santo, Jerônimo Monteiro, 2018. 98p.
- 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.
- 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.
- GOODBODY, T. R. H. et al. Unmanned aerial systems for precision forest inventory purposes: A review and case study. **The Forestry Chronicle**, v. 93, n. 01, p. 71–81, 2017.
- GRANSHAW, S. I. Photogrammetric terminology: third edition. **Photogrammetric Record**, v. 31, n. 154, p. 210–252, 2016.

- GUERRA-HERNÁNDEZ, J. et al. Comparison of ALS-and UAV (SfM)-derived high-density point clouds for individual tree detection in *Eucalyptus* plantations. **International Journal of Remote Sensing**, v. 39, n. 15-16, p. 5211-5235, 2018.
- GÜLCI, S. et al. Using ready- to-use drone images in forestry activities: case study of Çinarpinar in Kahramanmaras. *In*: 37th International Symposium on Remote Sensing of Environment, 37., 2017, Tshwane. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences.** Hannover: International Society of Photogrammetry and Remote Sensing (ISPRS), 2017. v. 42, p. 51–53.
- HAYKIN, S. **Redes neurais**: princípios e prática. 2. ed. Porto Alegre: Bookman, 2001. 900p.
- HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, New York, v. 25, n. 3, p. 295-309, 1988.
- IBÁ Indústria Brasileira de Árvores. **Relatório IBÁ 2020**. São Paulo: IBÁ, 2020.
- IBGE Instituto Brasileiro de Geografia e Estatística. **Produção da extração vegetal e silvicultura PEVS**. 2019.
- . Acesso em: 15 maio 2021.
- PIX4D. Selecionando o tipo de plano de aquisição de imagens. 2015. Disponível em: https://support.pix4d.com/hc/en-us/articles/202557459. Acesso em: 01 mar. 2021.
- IGLHAUT, J. et al. Structure from motion photogrammetry in forestry: a review. **Remote Sensing**, v. 5, p. 155-168, 2019.
- IOKI, K. et al. Evaluation of the similarity in tree community composition in a tropical rainforest using airborne LiDAR data. **Remote Sensing of Environment**, v. 173, p. 304–313, 2016.
- IQBAL, I. A. et al. Evaluating the robustness of point clouds from small format aerial photography over a *Pinus radiata* plantation. **Australian Forestry**, v. 81, n. 3, p. 162-176, 2018.
- JAYATHUNGA, S.; OWARI, T; TSUYUKI, S. The use offixed—wing UAV photogrammetry with LiDAR DTM to estimate merchantable volume and carbon stock in living biomass over a mixed conifer—broadleaf forest. **International Journal of Applied Earth Observation and Geoinformation**, v. 73, p. 767-777, 2018.
- JENSEN, J.R. **Introductory digital image processing**: a remote sensing perspective. Prentice-Hall Inc., 4 ed, 2015.544p.
- JORDAN, C. F. Derivation of leaf area index from quality of light on the forest floor. **Ecology**, v. 50, n. 4, p. 663-666, 1969.

JUSTICE, C. O. et al. The moderate resolution imaging spectroradiometer (MODIS): land remote sensing for global change research. IEEE Transactions on Geoscience and Remote Sensing, v.36, n.4, p.1228-1249, 1998.

KACHAMBA, D. J. et al. Influence of plot size on efficiency of biomass estimates in inventories of dry tropical forests assisted by photogrammetric data from an unmanned aircraft system. **Remote Sensing**, v. 9, n. 6, p. 610, 2017.

KANGAS, A. et al. Remote sensing and forest inventories in Nordic countries—roadmap for the future. **Scandinavian Journal of Forest Research**, v. 33, n. 4, p. 397-412, 2018.

KERSHAW JR., J. A. et al. **Forest Mensuration**. 5. ed. West Sussex: John Wiley & Sons, Ltd Registered, 2017.

KÖPPEN, W. **Das geographisca System der Klimate**. Gebr, Borntraeger, 1936, p. 1-44

KORHONEN, L. et al. Comparison of Sentinel-2 and Landsat 8 in the estimation of boreal forest canopy cover and leaf area index. **Remote Sensing of Environment**, v. 195, p. 259-274, 2017.

KOWALSKI, K. et al. Characterizing spring phenology of temperate broadleaf forests using Landsat and Sentinel-2 time series. **International Journal of Applied Earth Observation and Geoinformation**, v. 92, p. 102172, 2020.

KVÅLSETH, T. O. Cautionary note about R2. **The American Statistician**, v. 39, n. 4, p. 279-285, 1985.

LEFSKY, M. A. et al. Estimates of forest canopy height and aboveground biomass using ICESat. **Geophysical Research Letters**, v. 32, n. 22, 2005.

LEITE, R. V. et al. Estimating stem volume in eucalyptus plantations using airborne LiDAR: A comparison of area-and individual tree-based approaches. **Remote Sensing**, v. 12, n. 9, p. 1513, 2020.

LI, W. et al. Geostatistical modeling using LiDAR-derived prior knowledge with SPOT-6 data to estimate temperate forest canopy cover and above-ground biomass via stratified random sampling. **International Journal of Applied Earth Observation and Geoinformation**, v. 41, p. 88–98, set. 2015.

LINDER, W. **Digital photogrammetry**: A practical course. 4. ed. Berlin: Springer, 2016.

LISEIN, J.; PIERROT-DESEILLIGNY, M.; BONNET, S.; LEJEUNE, P. A photogrammetric workflow for the creation of a forest canopy height model from small unmanned aerial system imagery. **Forests**, v.4, n.1, p.922-944, 2013.

LIU, W. T. H. **Aplicações de sensoriamento remoto**. 2. ed. Campo Grande: Uniderp. 2006. 908p.

LOPATIN, J. et al. Comparing generalized linear models and random forest to model vascular plant species richness using LiDAR data in a natural forest in central Chile. **Remote Sensing of Environment**, v. 173, p. 200–210, 2016.

LUMLEY, T. **Regression subset selection**, [s.ed.], [s.l.]. Disponível em: https://cran.r-project.org/web/packages/leaps/leaps.pdf>. Acesso em: 02 out. 2019.

MA, M. et al. Estimation of forest-ecosystem site index using remote-sensed data. **Acta Ecologica Sinica**, v. 26, n. 9, p. 2810-2815, 2006.

MAIN-KNORN, M. et al. Sen2Cor for sentinel-2. In: **Image and signal processing for remote sensing XXIII**. International Society for Optics and Photonics, v. p. 1042704. 2017.

MALLOWS, C. L. Some comments on Cp. **Technometrics**, v. 42, n. 1, p. 87-94, 2000.

MATHWORKS, INC. **Neural network toolbox**: User's Guide (R2016a). MathWorks, 2016.

McGAUGHEY, R. J. **FUSION/LDV**: software for LIDAR data analysis and visualization. FUSION Version 3.80 Department of Agriculture Forest Service. Pacific Northwest Research Station, v. 123, 2018.

MENESES, P. R.; ALMEIDA, T. Introdução ao processamento de imagens e sensoriamento remoto. Brasília: UNB, 2012. 266p.

MENG, Q.; CIESZEWSKI, C.; MADDEN, M. Large area forest inventory using Landsat ETM+: a geostatistical approach. **Journal of Photogrammetry and Remote Sensing**, v. 64, p. 27-36, 2009.

MIKHAIL, E. M.; BETHEL, J. S.; MCGLONE, J. C. Introduction to modern photogrammetry. John Wiley & Sons Inc, 2001.

MILLER, A. **Subset selection in regression**. 2 ed. Washington: Chapman & Hall/CRC. 2002. 247p.

MONTGOMERY, D. C.; PECK, E. A.; VINING, G. G. Introduction to linear regression analysis. John Wiley & Sons, 2021.

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.

MORALES, G. et al. Automatic segmentation of *Mauritia flexuosa* in unmanned aerial vehicle (UAV) imagery using deep learning. **Forests**, v. 9, n. 12, p. 736, 2018.

- NÆSSET, E.; ØKLAND, T. Estimating tree height and tree crown properties using airborne scanning laser in a boreal nature reserve. **Remote Sensing of Environment**, v. 79, n. 1, p. 105–115, 2002.
- NÄSI, R. et al. Remote sensing of bark beetle damage in urban forests at individual tree level using a novel hyperspectral camera from UAV and aircraft. **Urban Forestry and Urban Greening**, v. 30, p. 72–83, 2018.
- NAVARRO, J. A. et al. Assessing the transferability of airborne laser scanning and digital aerial photogrammetry derived growing stock volume models. **International Journal of Applied Earth Observation and Geoinformation**, v. 91, p. 102135, 2020.
- NEX, F.; REMONDINO, F. UAV for 3D mapping applications: A review. **Applied geomatics**, v. 6, n. 1, p. 1–15, 2014.
- NOVO, E. M. L. M. **Sensoriamento remoto**: princípios e aplicações. 2. ed. São Paulo: Edgard Blucher, 2010. 388p.
- PÁDUA, L. et al. UAS, sensors, and data processing in agroforestry: a review towards practical applications. **International Journal of Remote Sensing**, v. 38, n. 8–10, p. 2349–2391, 2017.
- PANAGIOTIDIS, D. et al. Determining tree height and crown diameter from highresolution UAV imagery. **International Journal of Remote Sensing**, v. 38, n. 8–10, p. 2392–2410, 2016.
- PASCUAL, A. et al. Using spatial optimization to create dynamic harvest blocks from lidar-based small interpretation units. **Forests**, v. 7, n. 10, p. 220, 2016.
- PEARSE, G. D. et al. Comparison of high-density LiDAR and satellite photogrammetry for forest inventory. **ISPRS journal of photogrammetry and remote sensing**, v. 142, p. 257-267, 2018.
- PEREIRA, V. S. in Auster Tecnologia. 2019. **Entenda o que é sensoriamento remoto.** Disponível em: < https://www.austertecnologia.com/single-post/Sensoriamento-Remoto>. Acesso em: mar. 2021.
- PINTY, B.; VERSTRAETE, M. M. GEMI: a non-linear index to monitor global vegetation from satellites. **Vegetation**, v.1. n.101, p.15-20, 1992.
- PIX4D. Selecionando o tipo de plano de aquisição de imagens. 2015. Disponível em: https://support.pix4d.com/hc/en-us/articles/202557459. Acesso em: 01 mar. 2021.
- PLANET LABS INC. **Planet imagery product specifications**. Planet Labs: San Francisco, CA, USA, p. 91, 2018.
- PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto no estudo da vegetação**. 2. ed. São Paulo: Oficina de textos, 2015. 164 p.

PULITI, S. et al. Assessing 3D point clouds from aerial photographs for species-specific forest inventories. **Scandinavian Journal of Forest Research**, v. 32, 2017b, p. 68-79.

PULITI, S. et al. Use of partial-coverage UAV data in sampling for large scale forest inventories. **Remote Sensing of Environment**, v. 194, 2017a, p. 115-126.

PULITI, S.; ØRKA, H. O.; GOBAKKEN, T.; NÆSSET, E. Inventory of small forest areas using an unmanned aerial system. **Remote Sensing**, v.7, n.1, p.9632-9654, 2015.

QI, J. et al. A modified soil adjusted vegetation index. **Remote sensing of environment**, v. 48, n. 2, p. 119-126, 1994.

R Core Team. R: a language and environment for statistical computing (R version 3.5.2.). Vienna: R Foundation for Statistical Computing, 2019.

RAHLF, J. et al. Comparison of four types of 3D data for timber volume estimation. **Remote Sensing of Environment**, v. 155, 2014, p. 325-333.

RAHLF, J. et al. Forest parameter prediction using an image-based point cloud: a comparison of semi-ITC with ABA. **Forests**, v. 6, 2015, p. 4059-4071.

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

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, 2018.

REMONDINO, F. et al. State of the art in high density image matching. **The photogrammetric record**, v. 29, n. 146, p. 144-166, 2014.

REMONDINO, F. et al. A CRITICAL REVIEW OF AUTOMATED PHOTOGRAMMETRIC PROCESSING OF LARGE DATASETS. International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences, v. 42, 2017.

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.

RONDEAUX, G.; STEVEN, M.; BARET, F. Optimization of soil-adjusted vegetation indices. **Remote Sensing of Environment**, v. 55, n. 2, p. 95–107, 1996.

ROUJEAN, J. L.; BREON, F. M. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. **Remote Sensing of Environment**, v. 51, n. 3, p. 375–384, 1995.

- ROUSE, J. W.; HAAS, R. H.; SCHELL J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. p.309-317. In: **Earth resources technology satellite**. Washington, D.C: Goddart Space Flight Center, 1974.
- ROUSSEL, J. R. et al. The lidR package. 15 jan. 2021. Disponível em: < https://jeanromain.github.io/lidRbook/index.html>. Acesso em: 25 jan. 2021.
- 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.
- SALAMÍ, E.; BARRADO, C.; PASTOR, E. UAV flight experiments applied to the remote sensing of vegetated areas. **Remote Sensing**, v. 6, n. 11, p. 11051–11081, 2014.
- SANQUETTA, C. R. et al. **Inventários florestais**: planejamento e execução. 3. ed. Curitiba: Multi-Graphic Gráfica e editora, 2014.
- SANTOS, E. G dos. **Estimativa de biomassa florestal no estado do Mato Grosso a partir de dados do LiDAR e Landsat**. Dissertação (Mestrado em Sensoriamento Remoto). Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018. 117p.
- SANTOS, J. S. Predição e projeção do crescimento e da produção de plantios de eucalipto por meio de imagens multiespectrais de média resolução espacial. Tese (Doutorado em Ciências Florestais). Universidade Federal do Espírito Santo, Jerônimo Monteiro, 2020. 73p.
- SCHUMACHER, F. X.; HALL, F. S. Logarithmic expression of timber-tree volume. **Journal of Agricultural Research**, v.47, n.9, p.719-734, 1933.
- SCHWARZ, G. Estimating the dimension of a model. **Annals of statistics**, v. 6, n. 2, p. 461-464, 1978.
- SHAHBAZI, M.; THÉAU, J.; MÉNARD, P. Recent applications of unmanned aerial imagery in natural resource management. **GIScience and Remote Sensing**, v. 51, n. 4, p. 339–365, 2014.
- SHEN, G. et al. Mapping aboveground biomass and carbon in Shanghai's urban forest using Landsat ETM+ and inventory data. **Urban Forestry & Urban Greening**, v. 51, p. 126655, 2020.
- SHEN, X. et al. Estimation of forest structural attributes using spectral indices and point clouds from UAS-based multispectral and RGB imageries. **Remote Sensing**, v. 11, n. 7, p. 800, 2019.
- SHIMADA, Masanobu et al. New global forest/non-forest maps from ALOS PALSAR data (2007–2010). **Remote Sensing of environment**, v. 155, p. 13-31, 2014.

- 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**, 2017.
- SILVA, V. S. da et al. Combined impact of sample size and modeling approaches for predicting stem volume in *Eucalyptus* spp. forest plantations using field and LiDAR data. **Remote Sensing**, v. 12, n. 9, p. 1438, 2020.
- SOUZA, A. A. et al. Índices de vegetação derivados do sensor Hyperion/EO-1 para estimativa de parâmetros biofísicos de fitofisionomias de Cerrado. **Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal, Brasil**, p. 25-30, 2009.
- SOUZA, C. C. de; MOREIRA, A. de A.; SCHIMITH, R.S.; BRANDÃO, P.C.; SILVA, E. Técnicas de sensoriamento remoto como subsídios aos estudos de florestas implantadas no Brasil Uma revisão bibliográfica. **Ciência Florestal**, Santa Maria, v. 17, n. 4, p. 409-417, 2007.
- SUMNALL, M. J.; HILL, R. A.; HINSLEY, S. A. Comparison of small-footprint discrete return and full waveform airborne lidar data for estimating multiple forest variables. **Remote Sensing of Environment**, v. 173, p. 214–223, 2016.
- SWINFIELD, Tom et al. Accurate measurement of tropical forest canopy heights and aboveground carbon using structure from motion. **Remote Sensing**, v. 11, n. 8, p. 928, 2019.
- TANG, L.; SHAO, G. Drone remote sensing for forestry research and practices. **Journal of Forestry Research**, v. 26, n. 4, p. 791–797, 2015.
- TOMPALSKI, P. et al. Enhancing forest growth and yield predictions with airborne laser scanning data: increasing spatial detail and optimizing yield curve selection through template matching. **Forests**, v. 7, n. 12, p. 255, 2016.
- TORRESAN, C. et al. Forestry applications of UAVs in Europe: a review. **International Journal of Remote Sensing**, v. 38, n. 8–10, p. 2427–2447, 2017.
- TORRES-SÁNCHEZ, J. et al. Assessing UAV-collected image overlap influence on computation time and digital surface model accuracy in olive orchards. **Precision Agriculture**, v. 19, p. 115–133, 2018.
- TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v.8, n.2, p.127-150, 1979.
- VALVERDE, S. R. Características do mercado da madeira de Reflorestamento no Brasil. 2008. Texto técnico. Centro de Inteligência em Florestas. Disponível em:

- http://www.ciflorestas.com.br/arquivos/doc_caracteristicas_brasil_4558.pdf. Acesso em: 17 jan. 2021.
- VAN GUNST, K. J. et al. Do denser forests have greater risk of tree mortality: a remote sensing analysis of density-dependent forest mortality. **Forest Ecology and Management**, v. 359, p. 19–32, 2016.
- VIEIRA, G. C. et al. Prognoses of diameter and height of trees of *Eucalyptus* using artificial intelligence. **Science of The Total Environment**, v. 619-620, p. 1473-1481, 2018.
- 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. 146 f. Tese (Doutorado em Sensoriamento Remoto) Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, 2013.
- WALLIS, C. I. B. et al. Modeling tropical montane forest biomass, productivity and canopy traits with multispectral remote sensing data. **Remote Sensing of Environment**, v. 225, p. 77-92, 2019.
- WASER, L. T. et al. Wall-to-wall forest mapping based on digital surface models from image-based point clouds and a NFI forest definition. **Forests**, v. 6, p. 4510-4528, 2015.
- WATTS, A. C.; AMBROSIA, V. G.; HINKLEY, E. A. Unmanned aircraft systems in remote sensing and scientific research: classification and considerations of use. **Remote Sensing**, v. 4, n. 6, p. 1671–1692, 2012.
- WATZLAWICK, L. F.; KIRCHNER, F. F.; SANQUETTA, C. R. Estimativa de biomassa e carbono em floresta com araucária utilizando imagens do satélite IKONOS II. **Ciência Florestal**, v.19, n.2, p.169-181, 2009.
- WEST, P. W. Tree and forest measurement. New York: Springer, 2015.
- 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.
- WHITE, J. C. et al. The utility of image-based point clouds for forest inventory: a comparison with airborne laser scanning. **Forests**, v. 4, p. 518-536, 2013.
- WHITEHEAD, K.; HUGENHOLTZ, C. H. Remote sensing of the environment with small unmanned aircraft systems (UASs), part 1: a review of progress and challenges. **Journal of Unmanned Vehicle Systems**, v. 2, n. 3, p. 86–102, 2014.
- WITTKE, S. et al. Comparison of two-dimensional multitemporal Sentinel-2 data with three-dimensional remote sensing data sources for forest inventory parameter estimation over a boreal forest. **International Journal of Applied Earth Observation and Geoinformation**, v. 76, p. 167-178, 2019.

- WOLF, P. R.; DEWITT, B. A.; WILKINSON, B. E. **Elements of photogrammetry with application in GIS**. New York: McGraw-Hill Education, 2014.
- WU, X. et al. Assessment of individual tree detection and canopy cover estimation using unmanned aerial vehicle based light detection and ranging (UAV-LiDAR) data in planted forests. **Remote Sensing**, v. 11, n. 8, p. 908, 2019.
- ZEIDLER, J. et al. Spatio-temporal robustness of fractional cover upscaling: a case study in semi-arid Savannah's of Namibia and western Zambia. In: **Earth Resources and Environmental Remote Sensing/GIS Applications III**. International Society for Optics and Photonics, p. 85380S. 2012.
- ZHANG, C.; KOVACS, J. M. The application of small unmanned aerial systems for precision agriculture: a review. **Precision Agric**, v. 13, p. 693 712, 2012.
- ZHANG, J. et al. Seeing the forest from drones: testing the potential of lightweight drones as a tool for long-term forest monitoring. **Biological Conservation**, v. 198, p. 60–69, 2016.
- ZHANG, Y.; XIONG, J.; HAO, L. Photogrammetric processing of low-altitude images acquired by unpiloted aerial vehicles. **Photogrammetric Record**, v. 26, n. 134, p. 190–211, 2011.
- ZHAO, Min et al. Applications of satellite remote sensing of nighttime light observations: Advances, challenges, and perspectives. **Remote Sensing**, v. 11, n. 17, p. 1971, 2019.