



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

RICARDO PINHEIRO CABRAL

**CLASSIFICAÇÃO DO ESTÁGIO SUCESSIONAL DA VEGETAÇÃO EM
ÁREAS DA MATA ATLÂNTICA COM A UTILIZAÇÃO DE NUVEM DE PONTOS 3D
AÉREA E TERRESTRE**

JERÔNIMO MONTEIRO – ES

2022

RICARDO PINHEIRO CABRAL

**CLASSIFICAÇÃO DO ESTÁGIO SUCESSIONAL DA VEGETAÇÃO EM
ÁREAS DA MATA ATLÂNTICA COM A UTILIZAÇÃO DE NUVEM DE PONTOS 3D
AÉREA E TERRESTRE**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias 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: Dr. Gilson Fernandes da Silva

JERÔNIMO MONTEIRO – ES

2022

**CLASSIFICAÇÃO DO ESTÁGIO SUCESSIONAL DA VEGETAÇÃO EM ÁREAS DE
MATA ATLÂNTICA COM A UTILIZAÇÃO DE NUVEM DE PONTOS 3D AÉREA E
TERRESTRE**

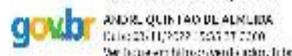
Ricardo Pinheiro Cabral

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 22 de agosto de 2022.



Prof. Dr. Santiago Bonilla Bedoya (Examinador externo)
Universidad Tecnológica Indoamérica, Quito, Ecuador



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

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

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

C117c Cabral, Ricardo Pinheiro, 1994-
Classificação do estágio sucessiona! da vegetação em áreas
da mata atlântica com a utilização de nuvem de pontos 3D aérea e
terrestre / Ricardo Pinheiro Cabral. - 2022.
81 f. : il.

Orientador: Gilson Fernandes da Silva.
Dissertação (Mestrado em Ciências Florestais) -
Universidade Federal do Espírito Santo, Centro de Ciências
Agrárias e Engenharias.

1. Florestas - Manejo. 2. Fotogrametria aérea. 3.
Sensoriamento remoto. 4. Drone. I. Silva, Gilson Fernandes da.
II. Universidade Federal do Espírito Santo. Centro de Ciências
Agrárias e Engenharias. III. Título.

CDU: 630

A Deus.
À minha família

Dedico

AGRADECIMENTOS

A Deus pela vida e por iluminar meu caminho e coração, dando-me saúde e discernimento para chegar até aqui.

Aos meus pais Celso Fernando Baptista Cabral e Carmen Pinheiro Cabral e ao meu irmão Fernando Pinheiro Cabral por todo amor, carinho e suporte em todas as etapas de minha vida.

À minha companheira Stéphanie Ferrari por estar ao meu lado em todos os momentos me incentivando e me mantendo forte nos dias difíceis. Agradeço também à sua família: Silvani, Jeferson e Leonardo por todo suporte.

Ao meu orientador Prof. Dr. Gilson Fernandes da Silva pelos ensinamentos e orientações e por confiar a mim a responsabilidade por este trabalho. Agradeço também ao Prof. Dr. Adriano Ribeiro de Mendonça pelos ensinamentos e pela disponibilidade em ajudar sempre que precisei.

Aos amigos Prof. Dr. André Quintão de Almeida, a doutoranda Nivea Maria Mafra Rodrigues e a mestranda Carem Cristina Araújo Valente, por toda ajuda, convivência e principalmente parceria. Não tenho dúvidas que sem a presença de vocês nada teria dado certo. Serei eternamente grato por ter conhecido vocês e por tudo que fizeram por mim.

Aos membros da banca, Prof. Gilson Fernandes, Prof. André Quintão e Prof. Dr. Santiago Bonilla Bedoya pela disponibilidade e contribuições.

A toda equipe que contribuiu com as coletas de dados em campo; agradeço a Carem, Nivea, Lucas Caldas, Klisman, Stefany, Vinicius, Prof. Gilson, Prof. André, Prof. Henrique, Fabio, Jeangelis e Leon.

Aos amigos Alison Moreira e Prof. Dr. Nilton Fiedler por incentivarem minha inscrição no processo seletivo do Mestrado.

Aos amigos Alexa Melo e Klisman Oliveira pelo companheirismo durante o cumprimento das disciplinas. Só nós sabemos as dificuldades que enfrentamos para transpor esta etapa.

Aos amigos do IDAF, Tobias e Emanuel, que contribuíram fortemente com o desenvolvimento desta pesquisa.

A toda equipe do LamFlor: Jeferson, Nivea, Carem, Klisman, Quinny, Lucas Lobato, Milena, Laís, Lucas Caldas, Stefany, Eduarda, Wander, Igor, Leon, Valéria, Gabriel, Tobias e Larissa.

A toda equipe da MVGI pela amizade e sensibilidade de me ajudarem a passar por esse período de grandes desafios; agradeço a Jamile, Dayane, Marcelo, Vinícius, Guilherme, Willian, Igor, Thales, Letícia, Thais, Lunalda, Djalma, Ana Elise, Pedro, Clarisse e Thayna.

Ao Programa de pós-graduação em Ciências Florestais, pelo comprometimento e acolhimento.

À empresa Suzano Papel e Celulose, por disponibilizar as áreas para coletas e viabilizar a execução da pesquisa. Agradeço de modo especial a Tathiane Sarcinelli, pelo suporte ao longo de todo o processo.

Aos amigos João Vitor e Rafael, da empresa Equilíbrio, pelo suporte durante as coletas de dados na região norte do estado.

A todos os professores que já passaram por minha vida, representados pela professora Geisa Nara e pelo professor Wanderson da Silva Santos. Vocês foram essenciais para o início dessa jornada até aqui.

Agradeço a todos que, direta ou indiretamente fizeram parte dessa conquista.

*“Crux sacra sit mihi lux,
Non Draco Sit Mihi Dux,
Vade retro, Satana!
Nunquam Suade Mihi Vana,
Sunt Mala Quae Libas,
Ipse Venena Bibas”*

Sancti Patris Benedicti

RESUMO

CABRAL, Ricardo Pinheiro. **CLASSIFICAÇÃO DO ESTÁGIO SUCESSIONAL DA VEGETAÇÃO EM ÁREAS DA MATA ATLÂNTICA COM A UTILIZAÇÃO DE NUVEM DE PONTOS 3D AÉREA E TERRESTRE**. 2022. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal do Espírito Santo, Jerônimo Monteiro, ES. Orientador: Dr. Gilson Fernandes da Silva.

A definição de estratégias de condução, recuperação e restauração de áreas desmatadas e ou degradadas está em função do estágio de sucessão ecológica que ela se encontra. Normalmente, a classificação do estágio sucessional é realizada em campo, a partir de campanhas de inventário florestal. Entretanto, estas campanhas são consideravelmente onerosas e demandam elevado tempo de execução, e, ainda assim, apresentam cobertura espacial limitada. Atualmente, os inventários florestais estão sendo aprimorados a partir da utilização de dados tridimensionais obtidos por sensoriamento remoto, com destaque para as métricas derivadas de *Light Detection And Ranging* (LiDAR) e de Fotogrametria Aérea Digital (FAD). Portanto, o objetivo principal deste trabalho foi estimar alguns parâmetros de interesse da floresta e classificar o estágio de sucessão ecológica de áreas com vegetação degradada do Bioma Mata Atlântica com a utilização de dados 3D de FAD obtida por Aeronave Remotamente Pilotada (ARP). Uma análise dos custos do inventário tradicional e aprimorado também foi realizada. Inicialmente, foi feita a estimativa em campo dos valores de altura total (h), diâmetro a 1,30 m do solo (dap) e a área basal (ab) dos indivíduos de 40 parcelas de inventário (de 30 x 30 m cada). Nas mesmas parcelas, nuvens de pontos 3D foram geradas por FAD-RPA e LiDAR portátil (PLS). Em seguida, foram ajustados e validados modelos de regressão para estimativa dos valores de h e dap médio e ab a partir das métricas tradicionais baseadas nas alturas da nuvem de pontos da FAD e LiDAR. Por fim, mapas do estágio sucessional da vegetação foram gerados com resolução espacial de 30 m. Os mapas foram criados com base em intervalos pré-estabelecidos de h e dap médio e ab , conforme resolução CONAMA 29/94. Foram considerados na análise de custos os gastos com a aquisição de equipamentos, coleta, processamento e análise de dados. Por fim, os custos dos inventários foram comparados. Os modelos de estimativa baseados na FAD apresentaram desempenho semelhante aos modelos ajustados com LiDAR, com valores de R^2 variando entre 88,3% e 94% e RMSE(%) entre 11,11 e 28,46 para FAD e R^2 entre 83,6% e 96,4% e RMSE(%) entre 8,58 e 33,63 para o LiDAR. Os mapas dos estágios sucessionais estimados por FAD foram compatíveis com as classes de sucessão estimadas nas 40 parcelas de campo. O custo de aquisição dos equipamentos utilizados na FAD foi duas vezes maior do que o método tradicional e dez vezes menor do que o inventário aprimorado realizado com LiDAR. Analisando os custos de aquisição e processamento de dados por hectare, a FAD apresentou um custo de apenas R\$83,40, contra R\$16449,16 e R\$26268,33 para o LiDAR e o método tradicional, respectivamente. As métricas da FAD podem ser utilizadas para estimar os valores de altura média, do diâmetro à altura do peito e a área basal da vegetação analisada com acurácia semelhante àquelas realizadas com LiDAR. Além de apresentar o menor custo, as estimativas realizadas pela FAD-RPA permitiram a classificação de estágios sucessionais nas áreas de floresta secundária de vegetação Atlântica analisada.

Palavras-chave: Inventário florestal aprimorado, fotogrametria aérea digital, LiDAR.

ABSTRACT

CABRAL, Ricardo Pinheiro. **CLASSIFICATION OF THE SUCCESSIONAL STAGE OF VEGETATION IN ATLANTIC FOREST AREAS WITH THE USE OF AERIAL AND TERRESTRIAL 3D POINT CLOUD**. 2022. Dissertation (Master's degree in Forest Sciences) – Federal University of Espírito Santo, Jerônimo Monteiro, ES. Advisor: Dr. Gilson Fernandes da Silva.

The definition of strategies for conducting, recovering and restoring deforested and or degraded areas is due to the stage of ecological succession it is in. Usually, the classification of the successional stage is carried out in the field, from forest inventory campaigns. However, these campaigns are considerably costly and require a high execution time, and still have limited spatial coverage. Currently, forest inventories are being enhanced from the use of three-dimensional data obtained by remote sensing, with emphasis on metrics derived from Light Detection And Ranging (LiDAR) and Digital Aerial Photogrammetry (DAP). Therefore, the main objective of this work was to estimate some parameters of forest interest and to classify the stage of ecological succession of areas with degraded vegetation of the Atlantic Forest Biome with the use of 3D DAP data obtained by Remotely Piloted Aircraft (ARP). An analysis of the costs of traditional and improved inventory was also performed. Initially, the field estimation of the values of total height (h), diameter at 1,30 m of soil (dbh) and basal area (ba) of the individuals of 40 inventory plots (30 x 30 m each) was estimated in the field. In the same plots, 3D point clouds were generated by DAP-RPA and Portable LiDAR (PLS). Next, regression models were adjusted and validated to estimate the values of mean h and dbh , and ab from the traditional metrics based on the heights of the DAP and LiDAR point cloud. Finally, maps of the successional stage of the vegetation were generated with spatial resolution of 30 m. The maps were created based on pre-established intervals of mean h and dbh and ab , according to CONAMA resolution 29/94. Expenses were considered in the cost analysis for equipment acquisition, collection, processing and data analysis. Finally, the costs of inventories were compared. The estimation models based on DAP showed performance similar to models adjusted with LiDAR, with Values of R^2 ranging from 88,3% to 94% and RMSE (%) between 11,11 and 28,46 for DAP and R^2 between 83,6% and 96,4% and RMSE (%) between 8,58 and 33,63 for LiDAR. The maps of the succession stages estimated by DAP were compatible with the succession classes estimated in the 40 field plots. The cost of acquiring the equipment used in the dap was twice as high as the traditional method and ten times lower than the enhanced inventory performed with LiDAR. Analyzing the costs of data acquisition and processing per hectare, DAP presented a cost of only R\$83,40, against R\$16449,16 and R\$26268,33 for LiDAR and the traditional method, respectively. DAP metrics can be used to estimate the values of average height, diameter to breast height and basal area of vegetation analyzed with accuracy similar to those performed with LiDAR. In addition to presenting the lowest cost, the estimates made by DAP-RPA allowed the classification of successional stages in the secondary forest areas of Atlantic vegetation analyzed.

Keywords: Enhanced forest inventory, digital aerial photogrammetry, LiDAR.

SUMÁRIO

1	INTRODUÇÃO	12
1.1	Objetivo Geral	14
1.2	Objetivos Específicos	15
2	REVISÃO BIBLIOGRÁFICA	16
2.1	Mata Atlântica	16
2.2	Estágios sucessionais	17
2.3	Inventário florestal	18
2.3.1	Inventário florestal tradicional	18
2.3.2	Inventário florestal aprimorado	20
3	MATERIAL E MÉTODOS	25
3.1	Área de estudo	25
3.2	Métodos	26
3.2.1	Inventário florestal tradicional	27
3.2.2	Classificação do estágio sucessional	31
3.2.3	Fotogrametria Aérea Digital (FAD)	32
3.2.4	Light Detection And Ranging (LiDAR)	34
3.2.5	Modelo Digital do Terreno (MDT)	37
3.2.6	Métricas estruturais	37
3.2.7	Validação da FAD-ARP	39
3.2.8	Modelos de estimativa de h média, dap médio, ab e ni	40
3.2.9	Espacialização dos modelos FAD-RPA	42
3.2.10	Análise de custo-benefício	43
4	RESULTADOS E DISCUSSÃO	46
4.1	Resultados IFT e classificação de estágios das parcelas	46
4.2	Validação dos dados FAD-RPA	48
4.2.1	Modelo Digital do Terreno	48

4.2.2	Alturas das árvores	51
4.3	Modelos selecionados	54
4.3.1	Altura total média	55
4.3.2	DAP médio.....	57
4.3.3	Área basal (<i>ab</i>).	59
4.4	Mapas de espacialização dos modelos FAD-RPA	61
4.5	Análise de custo benefício.....	63
5	CONCLUSÃO.....	66
	REFERÊNCIAS	67
	APÊNDICE	77

1 INTRODUÇÃO

Em diferentes regiões do planeta, os efeitos extremos (temperatura do ar elevada, inundações, longos períodos de estiagem, incêndios florestais, dentre outros) decorrentes das mudanças climáticas globais estão cada vez mais recorrentes (DHAKAL et al., 2022; MUÑOZ-ROJAS et al., 2017). Em consequência desses efeitos, pesquisadores de diferentes áreas têm demonstrado preocupações com as condições atuais e futuras do clima e seus possíveis impactos na manutenção e conversação da vida na terra (ANDRADE; ROMEIRO, 2011; MMA, 2016; ONU, 2021). O modelo atual de desenvolvimento econômico e social adotado pelas grandes nações tem sido apontado como um dos principais responsáveis pelas mudanças climáticas. Esse modelo insustentável tem causado transformações consideráveis no equilíbrio ecológico e na biodiversidade existente no nosso planeta, resultado do elevado processo de desmatamento e degradação florestal em diferentes ecossistemas (CUNHA et al., 2008).

Diante do exposto, cada vez mais são necessários métodos de estimativas do desmatamento e degradação da vegetação em diferentes escalas espaciais, com baixo custo e curtos intervalos de tempo (DEVRIES et al., 2015). Para garantir que o ecossistema seja ecologicamente equilibrado, é necessário conhecer as características de cada tipo de ambiente para assim identificar as estratégias para manter, preservar ou recuperar o mesmo (CAMPO et al., 2021). Uma das maneiras mais eficientes de se identificar os estágios sucessionais de uma determinada floresta é por meio da quantificação do que existe na vegetação de interesse, o que pode ser alcançado com a realização de inventários florestais (PELLICO NETTO; BRENA, 1997). Goodbody et al. (2017) , afirmam que inventários florestais precisos melhoram a confiança para as tomadas de decisões em relação ao manejo de florestas.

Para um manejo sustentável, é necessário obter informações precisas sobre a composição e estrutura das florestas e os inventários florestais tornam-se essenciais no fornecimento dessas informações (TOMPALSKI et al., 2016). Entretanto, para obter um bom nível de confiança nas informações levantadas, é preciso mensurar de forma representativa a população que se deseja estudar (HIGUCHI; DOS SANTOS; JARDIM, 1981). Por outro lado, a tendência é que quanto mais representativa seja a amostra, maiores são os seus custos de obtenção. Este paradoxo entre custo e

precisão é um dos grandes dilemas de pesquisa quando se considera os inventários florestais realizados por métodos tradicionais (IFTs). Os métodos tradicionais implicam basicamente no uso de parcelas de área fixa, nas quais se medem o diâmetro e a altura total de todas as árvores dentro da parcela, no caso de florestas naturais, que também demanda a identificação das espécies, e, em algumas situações, a medição de outras variáveis de interesse.

Comparativamente, os IFTs são muito mais onerosos em florestas nativas do que em plantadas, tendo em vista as dificuldades de acesso, locação das parcelas, movimentações dentro da floresta e maior número de variáveis a serem consideradas. Além disso, exigem uma maior quantidade de recursos humanos, com muitos riscos operacionais envolvidos e, ainda assim, apresentam cobertura espacial limitada (NOGUEIRA et al., 2010). Com isso, as demandas atuais de informações excedem o escopo de muitos métodos de inventários florestais tradicionais, principalmente em formações florestais naturais (WHITE et al., 2016).

Uma alternativa eficaz e menos onerosa para a quantificação de parâmetros florestais é a utilização de técnicas de sensoriamento remoto (MORIN et al., 2022). Neste contexto, informações tridimensionais da vegetação coletadas por *Light Detection And Ranging* (LiDAR) e Fotogrametria Aérea Digital (FAD) por meio de RPA (*Remote Piloted Aircraft*) vem sendo utilizadas com sucesso para aprimorar os inventários tradicionais (GOODBODY et al., 2017).

Apesar da capacidade do dado LiDAR em representar a estrutura vertical da vegetação e o terreno onde ela se encontra, seu custo ainda pode ser considerado elevado, principalmente em países em desenvolvimento. Já as informações obtidas por FAD-RPA, geralmente, apresentam um menor custo e podem ser uma alternativa viável (KANGAS et al., 2018). Entretanto, a dificuldade da FAD em representar o sub-bosque e o terreno sob a floresta pode ser considerada uma limitação. Apesar disso, alguns estudos mostram um bom desempenho da FAD-ARP em estimar características de interesse da floresta.

Por outro lado, quando consideramos o bioma da Mata Atlântica, não é difícil justificar a sua grande importância, tendo em vista a sua alta biodiversidade e extensão. Atualmente, é considerado um dos conjuntos de ecossistemas mais ricos em diversidade biológica do planeta (BERNADETE et al., 2007). Contudo, pelas razões já expostas e por se tratar de um ecossistema composto por povoamentos florestais nativos, como já mencionado, a necessidade de inventários florestais

detalhados, acurados e em espaços de tempo os mais curtos possíveis seriam essenciais para a boa gestão desse recurso natural. Também como já mencionado, muitas vezes isso não ocorre por conta do custo elevado, por falta de tempo ou por razões operacionais.

A Mata Atlântica, de forma geral, sofreu e ainda sofre muitas pressões antrópicas, o que provocou uma grande fragmentação dos povoamentos florestais originais. Além desta fragmentação, o intenso desmatamento ocorrido desde o descobrimento do Brasil fez com que os remanescentes florestais adquirissem diferentes estágios de sucessão. Identificar e compreender as relações ecológicas nos diferentes estágios sucessionais é fundamental para a manutenção dos passivos florestais ainda existentes, bem como para propor estratégias de recuperação de áreas degradadas que outrora foram florestas.

Nesse sentido, são escassos os estudos utilizando sensoriamento remoto para a identificação e classificação dos estágios sucessionais de seus remanescentes, com a maioria dos estudos disponíveis ficando limitados a indicar a existência ou não de cobertura vegetal, sem indicar informações sobre a estrutura e maturidade (TEIXEIRA et al., 2019). Mais restritos ainda, são os trabalhos utilizando FAD para caracterizar estágios de sucessão neste bioma, apesar do grande potencial e baixo custo da obtenção de atributos florestais a partir dos produtos 3D gerados.

Com base nos desafios apresentados e na necessidade de novas alternativas para a obtenção de parâmetros para a classificação de estágios sucessionais em remanescentes florestais de Mata Atlântica, este trabalho teve os seguintes objetivos:

1.1 Objetivo Geral

Classificar o estágio de sucessão ecológica de áreas com vegetação tropical secundária do Bioma Mata Atlântica localizadas no norte do estado do Espírito Santo com a utilização de dados 3D de FAD obtida por Aeronave Remotamente Pilotada (RPA).

1.2 Objetivos Específicos

- Identificar parâmetros da vegetação para a classificação de estágios sucessionais em áreas com vegetação tropical secundária do Bioma Mata Atlântica;
- Validar os produtos obtidos por FAD-RPA;
- Ajustar modelos de estimativa de altura total média (h), Diâmetro a 1,30 m do solo (dap) e área basal (ab) a partir de métricas extraídas das nuvens de pontos FAD-RPA, FAD normalizada com o MDT LiDAR e LiDAR;
- Comparar métodos de sensoriamento remoto, entre eles a FAD-RPA e o LiDAR portátil;
- Mapear o estágio sucessional das áreas analisadas a partir dos modelos FAD-RPA ajustados, com base na resolução CONAMA 29/94;
- Realizar análise de custo-benefício comparando a obtenção de dados por meio de inventário florestal tradicional, aprimorado com FAD-RPA e LiDAR portátil.

2 REVISÃO BIBLIOGRÁFICA

2.1 Mata Atlântica

O bioma da Mata Atlântica caracteriza-se por possuir alta diversidade e endemismo, apresentando mais de vinte mil espécies de plantas (RIBEIRO et al., 2009). Em virtude da alta biodiversidade, é considerado um dos *Hotspots* da biodiversidade global, ou seja, um dos locais considerados prioridade para a conservação da biodiversidade no mundo (MYERS et al., 2000). É considerada a segunda maior floresta tropical do planeta e aproximadamente 92% de sua extensão se encontra distribuída por 17 dos estados brasileiros, com o restante encontrando-se em parte da Argentina e do Paraguai (PEREIRA et al., 2018).

A Lei Federal nº 11.428/2006 (BRASIL, 2006) dispõe sobre o Bioma Mata Atlântica e define como integrantes deste bioma as seguintes formações florestais nativas: Floresta Ombrófila Densa; Floresta Ombrófila Mista; Floresta Ombrófila Aberta; Floresta Estacional Semidecidual; e Floresta Estacional Decidual, bem como os manguezais, as vegetações de restingas, campos de altitude, brejos interioranos e encaves florestais do Nordeste.

O bioma da Mata Atlântica possui alta relação histórica com o desenvolvimento e urbanização do país e, devido a isso, sofreu grande degradação, perdendo mais de 93% de sua área original (TABARELLI et al., 2005). Dentre os biomas brasileiros, é um dos que mais sofreram com as atividades antrópicas, constituída hoje por fragmentos florestais predominantemente pequenos e em diferentes estágios de sucessão (RIBEIRO et al., 2009; TEIXEIRA et al., 2019).

Cerca de 72% da população brasileira vive no bioma da Mata Atlântica, portanto é cada vez maior o interesse e necessidade de sua recuperação (SILVA et al., 2017). Para isso, a correta identificação do estágio de sucessão para o diagnóstico da situação atual das áreas a serem recuperadas é fundamental (BRANCALION; GANDOLL; GANDOLFI; RODRIGUES, 2015).

2.2 Estágios sucessionais

O estágio sucessional de uma floresta pode ser conhecido por meio da análise florística e fitossociológica de espécies arbóreas. Comparar essas estruturas e atributos funcionais de uma vegetação que passou por diversos tipos de distúrbios pode fornecer informações importantes sobre a influência desses fatores e suas trajetórias sucessionais, o que ainda é uma tarefa árdua em fragmentos florestais impactados (LORENZONI-PASCHOA et al., 2019). O que pode fazer com que estas informações geradas possam auxiliar em estratégias de manejo, conservação da biodiversidade e de restauração para possíveis outras áreas degradadas (DIAS, 2019).

Para as florestas do Espírito Santo, a Resolução nº 29 de 1994 do Conselho Nacional do Meio Ambiente (CONAMA) é o instrumento legal que define vegetação primária, secundária e os estágios sucessionais da vegetação secundária da Mata Atlântica e dos ecossistemas associados. Vegetação primária é aquela de máxima expressão local, com grande diversidade biológica, sendo os efeitos das ações antrópicas mínimos ou sem indicações visíveis de distúrbio antropogênico, a ponto de não afetar significativamente suas características originais de estrutura e de espécies. (CHAZDON, 2012; CONAMA, 1994). Já as florestas secundárias são comunidades resultantes de processos sucessionais após a perda da vegetação primária por causas antrópicas ou naturais (GUARIGUATA; OSTERTAG, 2001; CHAZDON, 2012; MOREIRA; CARVALHO, 2013).

Após distúrbios de grande escala, os processos sucessionais levam a alterações nas espécies que formam comunidades florestais, no tamanho e estrutura das populações de espécies e nas propriedades do ecossistema. (CHAZDON et al., 2006). Esse processo sucessional, segue uma progressão de estágios durante os quais as florestas apresentam um enriquecimento gradual de espécies e um aumento em complexidade estrutural e funcional. Portanto, a sucessão da floresta secundária pode ser visualizada como um continuum desde um estágio inicial, onde os fatores que governam a colonização são mais importantes (GUARIGUATA; OSTERTAG, 2001).

Dessa forma, florestas secundárias precisam ser estudadas e monitoradas, pois desempenham importante papel na recuperação do solo através da acumulação

de biomassa e são extremamente importantes como reserva da diversidade genética, estoque de carbono e de nutrientes, reguladoras do ciclo hidrológico na troca de energia e no processo de sistema terrestre ecológico (FRICK, 2019).

Segundo a *Lei Nº 6.938/81*, muitas empresas precisam elaborar estratégias para mitigar ou compensar os impactos ambientais causados pelas atividades de seus empreendimentos (BRASIL,1981). Dentre algumas medidas de compensação, estão os projetos de recuperação de florestas nativas em áreas degradadas, sendo por vezes necessário a correta identificação dos estágios de sucessão das áreas a serem recuperadas para a escolha das estratégias de recuperação mais adequadas (CARDOSO, 2016). Para tal, os gestores florestais e órgãos públicos necessitam dispor de ferramentas de monitoramento florestal aprimoradas e com bom custo benefício (Morin et al., 2022).

2.3 Inventário florestal

2.3.1 Inventário florestal tradicional

Por meio do inventário florestal, além da estimativa do número de indivíduos do povoamento, é possível obter uma série de variáveis dendrometrias básicas, como é o caso do diâmetro a altura do peito (DAP) e altura total. Com essas informações é possível chegar a variáveis mais complexas como é o caso da área basal, volume de madeira, biomassa e estoque de carbono (SOARES; NETO; SOUZA, 2011). Sendo assim, as informações obtidas a partir dos inventários auxiliam no planejamento e tomada de decisões sobre implantação, condução e colheita de um povoamento florestal (Assis et al., 2009).

Os inventários podem ser divididos em inventários contínuos e temporários (LIMA, 2018). Os inventários temporários, ocorrem em única ocasião, na qual são alocadas parcelas, mas não necessitam de recorrência nas mensurações em

momentos posteriores, sendo usualmente utilizada para inventários pré-corte (SOARES; NETO; SOUZA, 2011). Nos inventários florestais contínuos, as parcelas são lançadas e as informações de interesse coletadas e, de acordo com o planejamento e necessidades de informações, ocorrem novas medições nas mesmas parcelas (GUEDES, 2014).

O inventário florestal pode ser dividido também em inventários do tipo censo ou amostragem (SOARES; NETO; SOUZA, 2011). No inventário tipo censo, as variáveis de interesse serão mensuradas para todos os indivíduos do povoamento, apresentando informações bem representativas, contudo, possui a desvantagem de apresentar elevado custo de execução, além de possuir alta demanda de mão de obra e tempo para execução (SOARES; NETO; SOUZA, 2011). Já no caso de inventários por amostragem, parte da população arbórea é mensurada, configurando as amostras, e por meio de ajustes estatísticos é possível estimar as variáveis mensuradas para o povoamento (UBIALLI et al., 2009).

Ao amostrar uma determinada floresta, será assumido que o valor médio da variável mensurada é igual a esperança desta variável em qualquer área do povoamento, sendo que o erro gerado é referente a variância das informações amostradas (DINIZ, 2007). Um cuidado ao trabalhar com a amostragem no inventário florestal, são os erros gerados, sendo que a análise dos resíduos é fundamental para as tomadas de decisão (LIMA, 2018).

A partir das limitações inerentes às operações de IFTs, surge o interesse em desenvolver novos métodos e tecnologias que possam auxiliar na obtenção de dados para os inventários tradicionais de forma mais acurada, segura e com menor custo operacional (KERSHAW JR et al., 2017).

O maior acesso aos RPAs, equipadas com sensores LiDAR e/ou câmeras RGBs, multi e hiperespectrais, também têm possibilitado a reconstrução da estrutura vertical das florestas com maior flexibilidade de tempo, escala espacial e, em alguns casos, menor custo, quando comparados aos inventários tradicionais (LAMPING et al., 2021).

2.3.2 Inventário florestal aprimorado

Métodos de inventários florestais aprimorados (sigla EFI, do inglês *Enhanced Forest Inventory*), podem ser considerados aqueles que sejam capazes de produzir informações com alto nível de precisão, com custos reduzidos e proporcionando aumento de lucratividade. Os EFIs oferecem informações com alto nível de detalhamento e ampla resolução espacial sobre a estrutura da floresta (WHITE et al., 2017). Para alcançar tal aprimoramento, é fundamental a utilização de técnicas de sensoriamento remoto (SR). O SR é utilizado para obter informações de objetos na superfície da Terra ou na atmosfera a partir da radiação emitida ou refletida por esses objetos, podendo ser útil para facilitar o fornecimento de informações espaciais que de outras formas seriam difíceis ou impossíveis de se obter (READ; TORRADO, 2009).

De acordo com Carvalho (2021), existem duas classificações de sensores quanto à fonte de radiação eletromagnética (REM), os sensores ativos e os passivos. Um sensor passivo mede a energia solar refletida pelos alvos, tendo como limitação o fato de que a maioria deles exigem operação a luz do dia. Já os sensores ativos são aqueles que geram seus próprios sinais, que são refletidos pelos alvos e posteriormente medidos (HORNING, 2008).

Devries et al., (2015) sugerem que o papel do SR é fundamental no monitoramento de florestas devido a oportunidade de estudar grandes áreas de florestas. Morin et al. (2022) ressaltam a necessidade de ferramentas aprimoradas de monitoramento florestal, sendo o SR uma alternativa eficaz para isso. Porém, os autores também destacam que, considerando dados obtidos por imagens de satélite, ainda é difícil estimar parâmetros florestais em florestas de idades irregulares e apresentam como alternativa a utilização de métricas obtidas por SR tridimensional (3D) para estimar parâmetros nestes tipos de florestas.

Dentre as principais formas de SR 3D estão o LiDAR (Light Detection And Ranging) e a fotogrametria aérea digital (FAD). Maesano et al. (2022) utilizaram dados de FAD obtidos através de uma aeronave remotamente pilotada para medir altura e área da copa de árvores em plantações de folhas largas, com diferentes idades e espécies, de forma automatizada. Wang; Wong; Abbas (2022) utilizaram LiDAR para a caracterização estrutural de diferentes espécies tropicais. Já (YOSHII;

MATSUMURA; LIN, 2022) integraram dados LiDAR e FAD para a caracterização de parâmetros de árvores e atributos de povoamentos.

Os EFIs podem se basear em dois tipos de abordagem, por área e por árvore individual. Na abordagem por área, o objetivo é ajustar modelos preditivos que utilizem métricas obtidas por SR 3D associadas com dados obtidos em parcelas de IFTs e posteriormente utilizar o modelo ajustado para estimar em toda a área avaliada pelo SR 3D, os mesmos parâmetros obtidos pelas parcelas de IFT, apresentando-os em *rasters* onde os pixels possuem área igual ou semelhante às parcelas de IFT (WHITE et al., 2017). Já a abordagem por árvore individual, consiste em ajustar modelos capazes estimar parâmetros individuais de cada árvore avaliada pelo SR 3D (WANG; KOCH, 2008).

2.3.2.1 Light Detection and Ranging (LiDAR)

A tecnologia LiDAR, sigla em inglês para *Light Detection and Ranging* (Detecção e alcance de luz, em português) é uma técnica de sensoriamento remoto ativo, visto que opera com sua própria fonte de radiação (GIONGO et al., 2010; SANTANA, 2015). O funcionamento do LiDAR baseia-se na transmissão de radiação eletromagnética pelo próprio equipamento e essa radiação, ao atingir um objeto, é retro espelhada para um receptor no próprio LiDAR, que é capaz de calcular a intensidade do retorno, distância e ângulo com base no tempo entre transmissão e recepção do sinal, formando assim uma nuvem de pontos com coordenadas X, Y e Z de cada retorno (ALMEIDA, 2017; DONG; CHEN, 2018; VASCONCELLOS, 2020).

Com um LiDAR é possível realizar a medição das três dimensões sem obter distorções geométricas, que costumam ocorrer com frequência em sistemas de sensoriamento passivo, além de não apresentar limitação de operação em baixa luminosidade, podendo coletar dados a noite e em dias nublados (DALLA CORTE et al., 2022).

A aquisição de dados LiDAR pode ser realizada a partir de plataformas orbitais, aéreas e terrestres (ALMEIDA, 2017; DALLA CORTE et al., 2022; VASCONCELLOS, 2020). O escaneamento laser aerotransportado é denominado ALS (*Airborne Laser Scanning*) e pode utilizar como plataformas aviões, helicópteros e RPAs (DALLA

CORTE et al., 2022). Já o escaneamento laser terrestre é denominado TLS (*Terrestrial Laser Scanning*) e são mais comumente utilizados em plataformas estáticas, fixas em um tripé, porém também podem ser utilizados em plataformas dinâmicas/portáteis, através de veículos, mochilas ou mesmo à mão (PLS – *Personal Laser Scanner*) (DALLA CORTE et al., 2022; FONSECA, 2018). As plataformas terrestres geralmente são utilizadas quando há necessidade de alta precisão e em levantamentos de áreas restritas (ALMEIDA, 2017; DALLA CORTE et al., 2022). Os sistemas portáteis utilizam a tecnologia SLAM (*Simultaneous Localization and Mapping* ou em português Mapeamento e Localização Simultâneos) (DALLA CORTE et al., 2022).

Quando aplicado ao setor florestal, o LiDAR proporciona a medição de variáveis biofísicas com maior precisão e possibilita a geração de mapas de alta resolução através de análises espaciais tridimensionais (BACCINI; ASNER, 2013). A partir de dados LiDAR, é possível gerar modelos digitais de terreno (MDT) precisos com facilidade, pois o escaneamento é capaz de penetrar a copa das árvores e obter informações da posição do solo, o que possibilita estimativas precisas da altura das árvores (VAUHKONEN et al., 2012).

2.3.2.2 Fotogrametria aérea digital

A FAD é uma técnica que utiliza princípios de estereoscopia aliados a algoritmos de imagens sobrepostas e parâmetros de posição e orientação da aeronave durante o voo para a obtenção de produtos em forma de nuvem de pontos tridimensional 3D (CARVALHO, 2021). A terminologia da palavra fotogrametria se origina dos termos em grego *photos* (luz), *gramma* (escrita) e *metron* (medida) (TOMMASELLI, 2009), significando, assim, o ato de se medir graficamente por meio da luz (TOMMASELLI, 2009; WHITMORE; THOMPSON, 1966).

A partir de duas imagens planas obtidas de posições diferentes (pares estereoscópicos) de uma mesma cena, a fotogrametria possibilita uma percepção tridimensional dos objetos (WOLF; DEWITT; WILKINSON, 2014). O cálculo de sobreposição dessas duas imagens é dado em relação à porcentagem da dimensão total da foto, lateral e longitudinalmente. Sobrepondo fotos sucessivas

longitudinalmente na linha de voo, conseguimos a visualização tridimensional e a restituição estereoscópica. Já a sobreposição lateral serve para evitar lacunas entre as linhas de voo, ou seja, uma margem de segurança (GRANSHAW, 2016).

Além de permitir uma percepção tridimensional, a fotogrametria também possibilita uma visualização espacialmente contínua do terreno avaliado (LEBERL et al., 2010). Inicialmente as imagens eram obtidas por câmeras a bordo de aeronaves e a análise era realizada analogicamente por meio de estereoscópios (CARVALHO, 2021). O uso em conjunto de aviões e fotografia, fez a fotogrametria ter uma importância fundamental em levantamentos topográficos (ZHU, 2006).

Com a popularização e desenvolvimento de novas tecnologias, a fotogrametria vem sendo realizada com o uso de imagens obtidas por aeronaves remotamente pilotadas (RPA) (NĂSI et al., 2015; REMONDINO et al., 2014). A utilização de RPAs, tornou a aquisição de imagens para o processamento fotogramétrico mais flexível (WHITEHEAD; HUGENHOLTZ, 2014). Estudos mostram as diversas vantagens na utilização de RPAs para a obtenção de dados nas mais diversas áreas (JAYATHUNGA; OWARI; TSUYUKI, 2018; SALAMÍ; BARRADO; PASTOR, 2014; SHAHBAZI; THÉAU; MÉNARD, 2014; WATTS; AMBROSIA; HINKLEY, 2012).

Atualmente, existem algoritmos computacionais capazes de realizar fotogrametria em ambiente virtual (CARVALHO, 2021). Esses algoritmos são denominados *structure from motion* (SfM). Os algoritmos são capazes de reconhecer pixels análogos em diferentes fotos e a partir disso produzir uma nuvem de pontos tridimensionais. A obtenção de nuvens de pontos 3D a partir de imagens provenientes de RPA, é denominado fotogrametria aérea digital (FAD) (GOODBODY et al., 2019).

Vários estudos vem sendo realizados com FAD para aplicações florestais (HULET et al., 2014; NÆSSET, 2002). Entre os desafios na utilização de FAD para aplicações florestais, o que mais se destaca é a dificuldade de obtenção do modelo digital de terreno (MDT).

Os dados FAD possuem dificuldade em reconstruir a estrutura do terreno, já que são obtidos a partir de fotografias e a nuvem de pontos fica limitada às copas das árvores (VARGAS, 2007). Estudos mostram que a inexistência do componente arbóreo possibilita, de maneira acurada, a reconstrução do terreno pela FAD (HUNG et al., 2017). Dessa forma, em áreas com vegetação aberta e fragmentada, onde é possível reconhecer a posição do solo com facilidade, os resultados obtidos por FAD são semelhantes aos obtidos por LiDAR, já em áreas de grandes extensões de

vegetações densas, a FAD tem dificuldade em caracterizar com precisão a topografia da área e isso pode ocasionar uma normalização de nuvem pouco precisa (ALMEIDA et al., 2020; DIETMAIER et al., 2019).

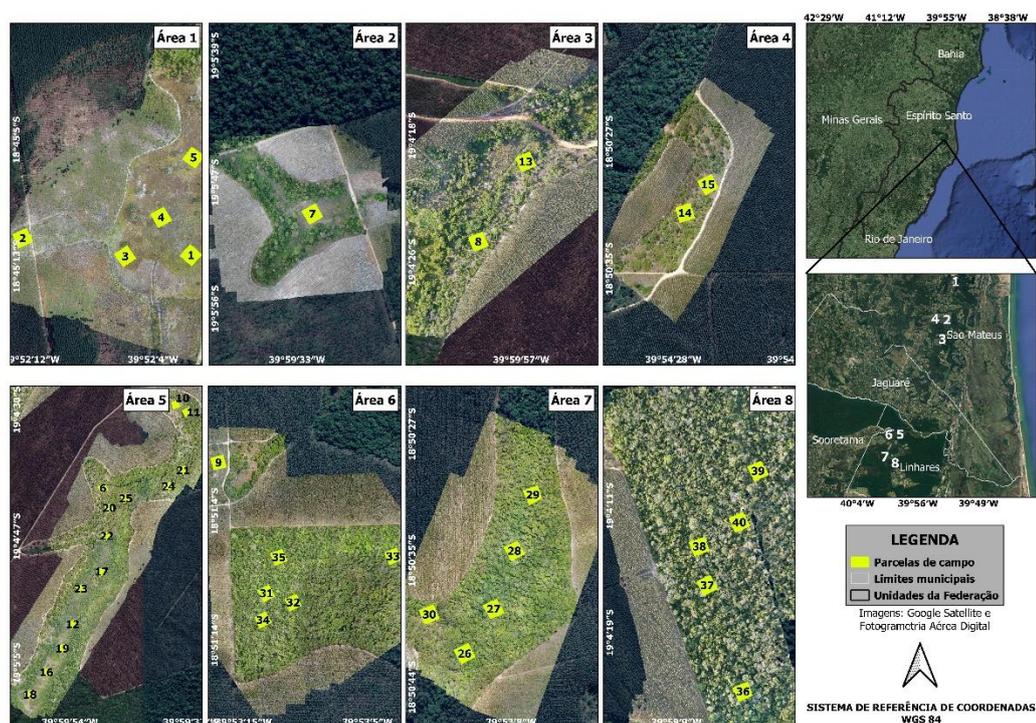
Apesar dos desafios, muitos trabalhos tem obtido bons resultados na utilização de fotogrametria para a obtenção de atributos florestais (GANZ; KÄBER; ADLER, 2019; GYAWALI et al., 2022; KRAUSE et al., 2019) principalmente em áreas de vegetação esparsa (HUNG et al., 2017). Muitos autores realizaram comparações entre a estimativa de atributos florestais a partir de dados LiDAR e de FAD e observaram que ambos podem ser igualmente recomendados (GOODBODY; COOPS; WHITE, 2019; IQBAL et al., 2019; KANGAS et al., 2018).

3 MATERIAL E MÉTODOS

3.1 Área de estudo

O estudo foi realizado em oito áreas inseridas no contexto do bioma da Mata Atlântica, localizadas no norte do estado do Espírito Santo, Brasil (Figura 1). De acordo com a classificação Köppen-Geiger (ALVARES et al., 2013), a região possui predominantemente o clima do tipo “Aw”, tropical chuvoso, com estação seca no inverno. Possui temperatura média anual de 23,6 °C e precipitação média anual de 1,290 mm, apresentando relevo predominantemente plano (80%) e em menor proporção por relevo acidentado (19%) com altitude média de 55 m (ALVARES et al., 2013; INCAPER, 2020). O solo da região é classificado como Argissolo Amarelo Distrocoeso (IBGE, 2021). As oito áreas estudadas contemplaram aproximadamente 201 ha.

Figura 1. Mapa de localização das 8 áreas estudadas e as respectivas parcelas de campo.

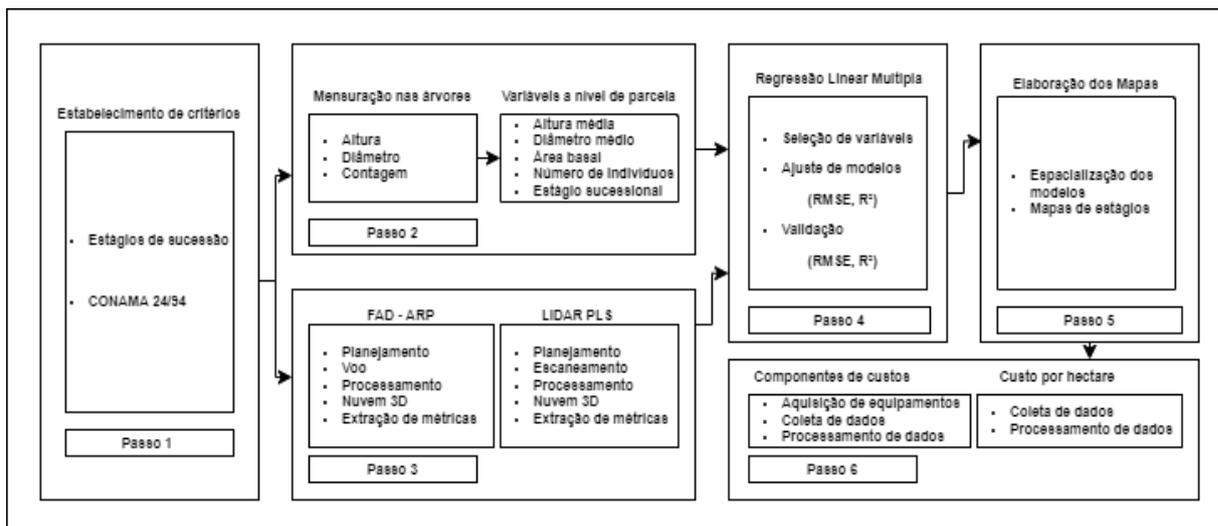


Fonte: O autor.

3.2 Métodos

Para a avaliação da utilização de FAD-RPA como ferramenta para a realização de inventários florestais para a classificação de estágios de sucessão de Mata Atlântica e comparação com LiDAR PLS em termos de acurácia e de custos, foram seguidas algumas etapas estruturadas, que são apresentadas com mais detalhes na Figura 2. Inicialmente (passo 1), foram definidos os critérios para classificação dos estágios de sucessão baseando-se na resolução CONAMA 29/94. No passo 2, foi realizado um inventário de campo pelo método tradicional buscando abranger a maior variação de vegetação possível. Dessa forma, foram medidos altura (h), diâmetro a 1,30 metros do nível do solo (dap) e área basal (ab) em 40 parcelas de área fixa de 0,09 ha que variaram desde pastagem limpa até o estágio avançado de sucessão. Posteriormente (passo 3), nas mesmas parcelas, nuvens de pontos 3D foram geradas por FAD-RPA e LiDAR PLS. No passo 4, foram ajustados e validados modelos de regressão para estimar os valores de h e dap médio e ab a partir das métricas tradicionais baseadas nas alturas da nuvem de pontos da FAD e do LiDAR. A acurácia dos dois métodos foi comparada pela análise do RMSE e do R^2 dos modelos. No passo 5, mapas do estágio sucessional da vegetação foram gerados com resolução espacial de 30 m, a partir da aplicação dos modelos obtidos para FAD-RPA e seguindo os intervalos pré-estabelecidos de ht e dap médio e ab , conforme resolução CONAMA 29/94. Por fim (passo 6), foi realizada uma comparação entre os custos do inventário pelo método tradicional e pelo método aprimorado pela utilização LiDAR PLS e FAD-RPA.

Figura 2 – Fluxo de etapas estruturadas para a realização do trabalho

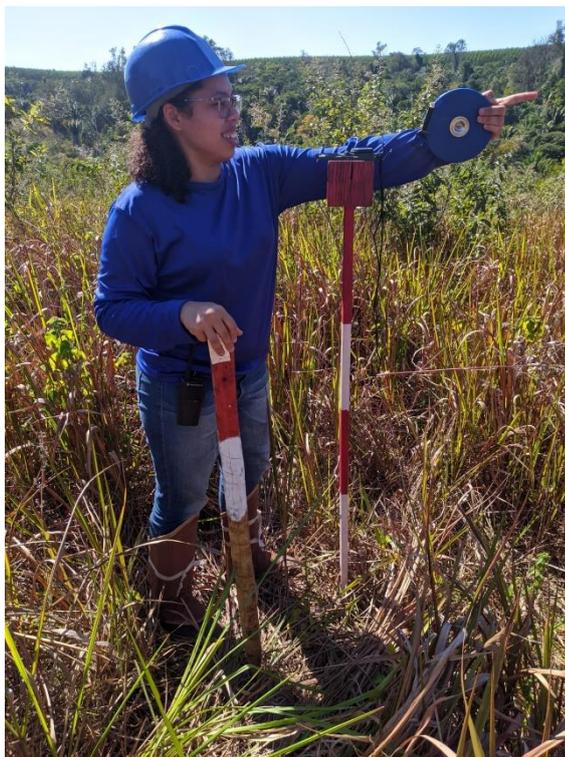


Fonte: O Autor.

3.2.1 Inventário florestal tradicional

As coletas de dados pelo método do inventário florestal tradicional foram realizadas em duas campanhas, sendo a primeira entre os dias 25 e 30 de julho e a segunda entre os dias 13 e 25 de setembro, ambas no ano de 2021. Foram alocadas, aleatoriamente, 40 parcelas permanentes de formato quadrangular (30 x 30 m), perfazendo uma área total mensurada de 3,6 ha (Figura 1). A área das parcelas (0,09 ha) buscou reduzir possíveis efeitos de clareiras e árvores muito grandes na extrapolação dos dados para hectare. As parcelas foram locadas, prioritariamente, em locais com relevo plano, além de respeitada uma distância mínima de 25 metros das bordas da vegetação, quando possível, e uma distância mínima de pelo menos 50 metros entre as parcelas. As parcelas foram orientadas em direção ao norte magnético, com a utilização de uma bússola, e seus vértices marcados com estacas com o auxílio de esquadros de agrimensor e trenas (Figuras 3 e 4) e georreferenciados com GNSS RTK de precisão utilizando o Sistema de Coordenadas de Referência (SRC) SIRGAS 2000 UTM 24 S, com valores médios de RMSE nas coordenadas X e Y de 0,34 m.

Figura 3 – Demarcação de um dos vértices de uma parcela.



Fonte: o autor.

Figura 4 – Demarcação de vértices de uma parcela com o auxílio de bússola e esquadro.



Fonte: o autor.

As coletas de dados foram iniciadas sempre pelo vértice A, que está sempre ao sudoeste (SW). Os demais vértices (B, C e D) foram marcados no sentido horário e seguindo a ordem alfabética. Foram mensurados todos indivíduos arbóreos adultos, com fustes vivos e Diâmetro à Altura do Peito (*dap*), medido a 1,30 m do solo, maior ou igual a 5 cm, que estivessem com a base de seu tronco completamente dentro do limite da parcela. Toda árvore mensurada foi identificada com a numeração sequencial dentro da parcela (Figura 5). Árvores com mais de um fuste abaixo de 1,30 m foram consideradas multifustes e tiveram todos os fustes, com diâmetro mínimo de inclusão, mensurados e identificados com o mesmo número seguido de um diferenciador alfabético (exemplo: 1a, 1b, 1c....1n). A altura total (*h*) das árvores, correspondendo ao comprimento entre a base do tronco e o ápice da copa, foi medida com o auxílio de uma régua graduada de 15 m (Figura 6). Para a medição das árvores em que a altura ultrapassava o limite da régua, foi utilizado o Clinômetro Suunto PM-5/360PC (SUUNTO, 2022). Esse instrumento é baseado em princípios trigonométricos, logo, é fundamental conhecer a distância entre o observador e a árvore para que as leituras (inferior e superior) sejam feitas corretamente. Além disso, é necessário considerar a topografia do local (Soares et al. 2010). Neste caso, a distância entre o observador e as árvores variou de acordo com a especificidade de cada uma, visando encontrar a melhor posição para medir cada árvore. Para obter as alturas totais das árvores foi utilizada a Equação 1 apresentada abaixo:

$$ht = L(tg\alpha \pm tg\beta) \quad (1)$$

Em que: *ht* é a altura total; α e β são os ângulos inferior e superior, respectivamente; e, *L* é a distância entre o observador e a árvore.

Figura 5 – Demarcação dos indivíduos mensurados e coleta de *dap*.



Fonte: o autor.

Figura 6 – mensuração de altura com régua graduada.



Fonte: o autor.

3.2.2 Classificação do estágio sucessional

Inicialmente, as áreas de estudo foram escolhidas a partir de mapas pré-existentes, fornecidos pela empresa proprietária das áreas. Estes mapas utilizavam seis classes de vegetação que eram caracterizadas a partir de critérios visuais. Tais classes são apresentadas na Tabela 1 e foram utilizadas para facilitar a distribuição das parcelas de IFT, buscando a maior variação de vegetação possível. Portanto, foram alocadas cinco parcelas em cada uma dessas classes utilizadas pela empresa proprietária da área.

Após a realização do IFT, as parcelas foram reclassificadas de acordo com os critérios definidos pela Resolução CONAMA 29/94 (Tabela 2). Para que uma parcela fosse classificada como pertencente a um determinado estágio, foi estabelecido que a mesma deve apresentar ao menos dois parâmetros enquadrados no estágio em questão. É importante observar que os critérios estabelecidos pelo CONAMA possuem faixas de sobreposição entre os estágios, havendo a possibilidade de uma mesma área se enquadrar em dois estágios. Neste caso, a área em questão será considerada em transição entre o estágio inicial e médio e entre o estágio médio e avançado.

Tabela 1 - Classes de vegetações utilizadas para a distribuição das parcelas e número de parcelas amostradas.

Classe de vegetação	Número de parcelas
Pasto Limpo (PL)	5
Pasto sujo ralo (PSR)	5
Pasto sujo denso (PSD)	5
Pasto sujo denso Infestado com Exóticas (PSDE)	5
Vegetação secundária em estágio inicial (VSIE)	5
Vegetação secundária em estágio inicial (VSI)	5
Vegetação secundária em estágio médio (VSM)	5
Vegetação secundária em estágio avançado (VSA)	5
TOTAL	40

Fonte: o autor.

Tabela 2 - Critérios para classificação dos estágios de sucessão das áreas estudadas.

Classe	Fisionomia	Altura média (m)	DAP médio (cm)	Área basal (m ² /ha)
Estágio inicial	Herbáceo/arbustiva de porte baixo	1 a 7	1 a 13	2,1 a 10
Estágio médio	Arbórea e/ou arbustiva predominando sobre a herbácea	5,1 a 13	10 a 20	10,1 a 18
Estágio avançado	Arbórea dominante sobre as demais, formando um dossel fechado relativamente uniforme no porte	> 10	> 18	> 18

Fonte: Resoluções CONAMA 29 de 1994, para o estado do Espírito Santo.

3.2.3 Fotogrametria Aérea Digital (FAD)

3.2.3.1 Fotografias com RPA

Imagens de alta resolução espacial foram obtidas por uma Aeronave Remotamente Pilotada (ARP) de plataforma multirrotor modelo DJI Mavic 2 PRO (SZ DJI Technology Co., Ltd., Shenzhen, China) (Figura 7) entre os dias 21 e 30 de setembro do ano de 2021. A aeronave estava equipada com uma câmera RGB, com 20 megapixel sensor CMOS e resolução de 5472 x 3648. A câmera fica instalada em um *gimbal* para reduzir as possíveis vibrações mecânicas no momento da tomada das fotos. As condições meteorológicas eram de céu claro (< 5% de nuvens) e velocidade do vento inferior a 10 m s⁻¹ (DANDOIS; OLANO; ELLIS, 2015). Os voos foram realizados a uma altura de 120 m, respeitando a ICA 100-40 (DECEA, 2015), usando o método *visual line of sight* (VLOS) e com sobreposição longitudinal de 75% e lateral de 65% (HUNG et al., 2017). As fotos foram salvas no formato “.jpg” em um cartão de memória SanDisk 128 GB Extreme microSDXC (WESTERN DIGITAL

CORPORATION, 2022). Foram mapeados aproximadamente 201 ha com a realização 8 voos. O tempo médio de cada voo foi de aproximadamente 10 min.

Figura 7 – RPA DJI Mavic 2 PRO, utilizado para os levantamentos aerofotogramétricos.



Fonte: o autor.

3.2.3.2 Processamento de Structure from Motion

As imagens obtidas pela RPA foram processadas utilizando o *software* Agisoft Metashape (AGISOFT, 2022), que utiliza algoritmos de Structure from motion (SfM) para realizar o alinhamento das imagens e geração da nuvem de pontos 3D. Para cada uma das áreas, foram utilizadas as mesmas configurações de processamento descritas a seguir. Para o alinhamento das fotos e obtenção da nuvem esparsa, foi utilizada a precisão “elevada” e parâmetros de limites de pontos chaves e de amarração de 40000 e 10000 pontos, respectivamente. No processo de alinhamento das fotos, foram utilizados pontos de controle do terreno (PCTs). Os PCTs foram distribuídos pelas áreas sobrevoadas, com uma média de 4 PCTs por levantamento. As coordenadas dos PCTs foram coletadas utilizando RTK com precisão submétrica utilizando o SRC SIRGAS 2000 UTM 24 S. No final do alinhamento, a média do RMSE para os oito levantamentos foi de 0,55 m em X e Y e 0,95 m em Z. Na criação da nuvem densa de pontos, os parâmetros foram definidos como qualidade média e modo de filtragem de profundidade “agressiva”. O *ground sample distance* (GSD) médio para os oito levantamentos foi de aproximadamente 2,5 cm por pixel. As ortofotos foram obtidas pelo modo de combinação “mosaico”.

3.2.4 Light Detection And Ranging (LiDAR)

3.2.4.1 Coleta de dados

As parcelas foram escaneadas utilizando o sensor LiDAR PLS GeoSLam ZEB-HORIZON 3D, modelo GS_510254 (GEOSLAM, 2022a) (Figura 8), entre os dias 21 e 29 de setembro de 2021. As cinco parcelas da classe pastagem não foram mapeadas, em função da inexistência de indivíduos arbóreos. As condições meteorológicas eram de céu claro (< 5% de nuvens) e velocidade do vento inferior a 10 m s^{-1} . O ZEB-HORIZON é um modelo de LiDAR terrestre portátil (PLS) de 6,96 kg e é composto por um scanner a laser 2D com comprimento de onda de 903 nm e possui uma *Inertial Measurement Units* (IMU) de acionamento motorizado (GEOSLAM, 2022a). A velocidade de aquisição do laser é de 300000 pontos por segundo com raio de alcance de aproximadamente 100 metros ao redor do equipamento. Possui 16 sensores, campo de visão de $270^\circ \times 360^\circ$, visão angular vertical e horizontal de 2° e $0,38^\circ$, respectivamente, e precisão relativa pode chegar a $\pm 6 \text{ mm}$, a depender do ambiente. Posteriormente foi realizado o ajuste da geolocalização das nuvens no *software* GEOSLAM HUB (GEOSLAM, 2022b), considerando as estacas dos vértices como referência física.

Figura 8 – LiDAR PLS GeoSLam ZEB-HORIZON 3D, modelo GS_510254.



Fonte: o autor.

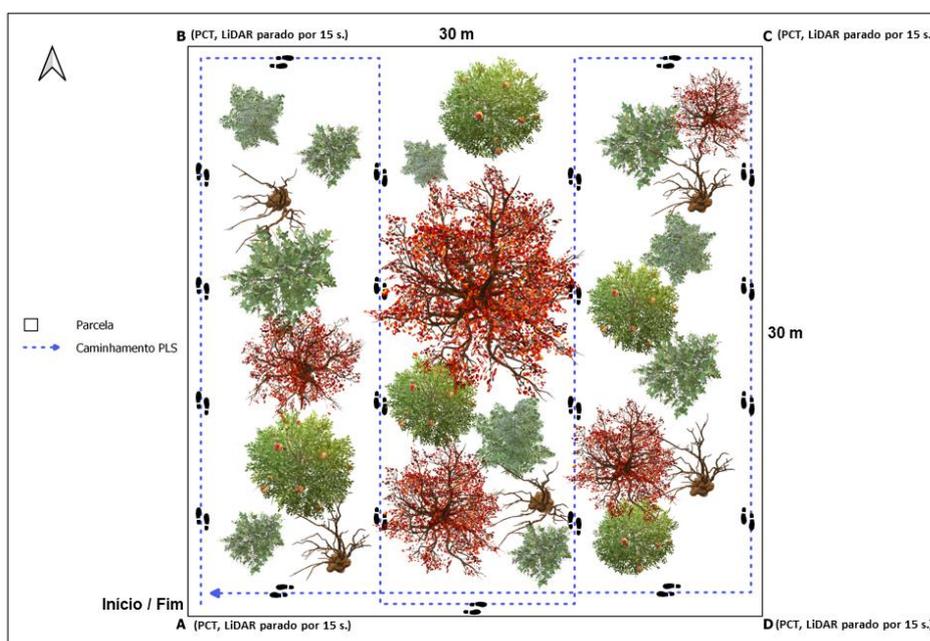
O escaneamento foi realizado por um operador (Figura 9) que conduziu o equipamento segurando-o com as mãos a uma altura de aproximadamente 1,40 m do solo enquanto realizava um caminhamento de forma lenta (aproximadamente 25 cm por segundo) por todo o interior, em zigue-zague, iniciando e finalizando sempre no vértice “A” de cada parcela (Figura 10). O tempo médio de escaneamento de cada parcela foi de aproximadamente 5 minutos.

Figura 9 – Operador realizando o escaneamento com o LiDAR PLS.



Fonte: o autor.

Figura 10 – Caminhamento com o LiDAR PLS no interior da parcela.



Fonte: o autor

3.2.4.2 Pre-elaboração das nuvens de pontos

A nuvem de pontos 3D foi obtida a partir dos dados brutos coletados no campo e do servidor GeoSLam (GEOSLAM, 2022a). O aplicativo utiliza um Sistema baseado em *Simultaneous Localization and Mapping (SLAM)*, que combina os dados do escaneamento a laser 2D com os dados da IMU para gerar as nuvens de pontos 3D com precisão (GEOSLAM, 2022b). Por fim, foram produzidas nuvem de pontos 3D para cada uma das parcelas, com densidade média de aproximadamente 800 pontos por metro quadrado. As coordenadas dos quatro vértices das parcelas de inventário foram coletadas com GNSS RTK, seguindo o SRC SIRGAS 2000 UTM 24 S, com média de RMSE de 0,34 m em X e Y, e foram utilizadas como PCTs para o georreferenciamento das nuvens 3D. Para a demarcação de locais como PCTs nas nuvens de pontos, o PLS deve ficar estático por 15 segundos no local escolhido (Figura 11).

Figura 11 – Coleta de ponto de controle com o LiDAR PLS no vértice da parcela.



Fonte: o autor.

3.2.5 Modelo Digital do Terreno (MDT)

Para a obtenção do modelo digital de terreno (MDT), primeiramente foi realizada a classificação dos pontos da nuvem 3D entre pontos de solo ou não. O algoritmo utilizado para a classificação dos pontos de solo foi o “*Progressive Morphological Filter*”, disponível no pacote “LidR” (ROUSSEL et al., 2020) do *software* R (R CORE TEAM, 2022). Após a classificação dos pontos de solo, foi realizada uma filtragem, mantendo somente os pontos do solo. Por fim, foi realizada a construção do MDT a partir de interpolação dos pontos de solo pelo método de “*Invert distance weighting*” (IDW), que baseia-se na suposição de que o valor de altitude de um ponto não amostrado pode ser obtido de forma aproximada a partir da média ponderada dos valores dos pontos amostrados dentro de uma certa distância (d) ou de um determinado número de vizinhos mais próximos (k) (ROUSSEL et al., 2020).

3.2.6 Métricas estruturais

Com a obtenção do MDT, foi realizada a normalização das nuvens de pontos, ou seja, a altitude do MDT foi subtraída da elevação dos pontos da nuvem, permitindo a manipulação das nuvens 3D como se tivessem sido adquiridas em uma superfície plana, removendo a influência do terreno nas medições acima do solo (ROUSSEL et al., 2020). Após a normalização das nuvens de pontos, foi realizada a estimativa de métricas estruturais baseadas em informações da altura dos pontos nas nuvens, utilizando o *software* FUSION/LDV 3.42 (US FOREST SERVICE, 2022). Foi utilizada uma altura limiar de 1,5 metros para a remoção de pontos do solo e separação de vegetação rasteira (ALMEIDA et al., 2020). As métricas foram calculadas a partir de nuvens de pontos FAD, FAD-MDT_{LIDAR} e LiDAR para descrever a estrutura de cada parcela. As métricas extraídas estão descritas na tabela 3.

Tabela 3 – Métricas estruturais extraídas das nuvens de pontos derivadas de FAD-RPA, FAD MDTLiDAR e LiDAR PLS

Tipo de métrica	Variável
	Mínimo (H_{\min})
	Máximo (H_{\max})
	Média (H_{mean})
	Modo (H_{mode})
	Coefficiente de variação (H_{cv})
	Desvio padrão (H_{SD})
	Variância (H_{v})
	Interquartil (H_{Iq})
	Assimetria (H_{skew})
	Curtose (H_{kurt})
Altura	Percentis ($HP_{01}, HP_{05}, HP_{10}, HP_{20}, HP_{25}, HP_{30}, HP_{40}, HP_{50}, HP_{60}, HP_{70}, HP_{75}, HP_{80}, HP_{90}, HP_{95}, HP_{99}$)
	Médias generalizadas da raiz quadrada ($H_{\text{SQRTmeanSQ}}$)
	Médias generalizadas da raiz cúbica ($H_{\text{CURTmeanCUBE}}$)
	Desvio absoluto médio (HAAD)
	Desvio absoluto mediano da altura mediana ($HMAD_{\text{Median}}$)
	Desvio absoluto mediano da moda da altura ($HMAD_{\text{Mode}}$)
	Momentos lineares (HL_1, HL_2, HL_3, HL_4)
	Altura de assimetria do momento linear (HL_{skew})
	Altura da curtose do momento linear (HL_{kurt})
	Coefficiente de variação dos Momentos lineares (HL_{cv})
	Relação de alívio do dossel (HCRR) $(H_{\text{mean}} - H_{\text{min}})/(H_{\text{max}} - H_{\text{min}})$
	Total de todos os retornos (CCH)
	Todos os retornos acima da altura média (CCH_{mean})
	Todos os retornos acima do valor da moda da altura (CCH_{mode})
Cobertura de copa	Porcentagem de todos os retornos > altura média em relação ao número total de pontos ($CC\%H_{\text{mean}}$)
	Porcentagem de todos os retornos > altura do modo em relação ao número total de pontos ($CC\%H_{\text{mode}}$)
	Todos os retornos acima de 1,0 m (CCH_{1m})
	Porcentagem de todos os retornos > altura de 1m em relação ao número total de pontos

Fonte: o autor.

3.2.7 Validação da FAD-ARP

A validação dos produtos da FAD foi realizada em duas etapas, sendo a primeira a validação dos produtos topográficos obtidos, ou seja, o MDT, e a segunda foi a validação dos dados da estrutura vertical da nuvem de pontos 3D normalizada.

3.2.7.1 Validação do MDT

Os valores de altitude (Z) dos vértices das parcelas (160 pontos) coletados em campo com o RTK foram utilizados para avaliar a acurácia do MDT gerado pela FAD. Para avaliar a influência da vegetação na representação do relevo, os vértices foram classificados em: (i) com vegetação e (ii), sem vegetação. A acurácia foi avaliada pelos valores das estatísticas de RMSE e viés (absoluto e percentual) e R² (Equações 2, 3 e 4 respectivamente).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad RMSE(\%) = \frac{RMSE}{\bar{Y}} 100 \quad (2)$$

$$Viés = \frac{\sum_{i=1}^n Y_i - \sum_{i=1}^n \hat{Y}_i}{n} \quad Viés(\%) = \frac{Viés}{\bar{Y}} 100 \quad (3)$$

$$R^2 = \frac{\sum_{i=1}^n (\hat{Y}_i - \hat{Y}_m)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (4)$$

Em que: Y_i = variável dependente observada, \hat{Y}_i = variável dependente estimada, \bar{Y} = média da variável dependente observada, \hat{Y}_m = média da variável dependente estimada e n = número de observações.

3.2.7.2 Validação da estrutura vertical das nuvens FAD-ARP

Para a validação da estrutura vertical da nuvem FAD e FAD-MDT_{LIDAR}, foram comparadas as alturas máximas e alturas dominantes das parcelas de inventário e campo com as métricas “H_{max}” e “HP₉₅”, respectivamente, das nuvens de pontos FAD de cada parcela. Para determinação das alturas dominantes das parcelas, foi utilizada a média de 20% das árvores mais altas por hectare. Para fins de comparação, a mesma análise foi realizada com os dados FAD-MDT_{LIDAR}. As métricas H_{max} e HP₉₅ das nuvens de pontos foram extraídas com a utilização do software FUSION/LDV 3.42 e são respectivamente o valor de altura ponto mais alto da nuvem de pontos e o valor da altura em que 95% dos pontos da nuvem são inferiores a ela (GORGENS; SILVA; RODRIGUES, 2014). Foram avaliadas as estatísticas de RMSE e viés (absoluto e percentual) e R² (equações 2 e 3, respectivamente).

3.2.8 Modelos de estimativa de *h* média, *dap* médio, *ab* e *ni*

Modelos de regressão múltipla foram ajustados para estimar os valores de altura média (*h*), diâmetro a altura do peito médio (*dap*) e área basal (*ab*) das árvores ao nível de parcela. Como variáveis preditoras, foram consideradas as métricas estruturais extraídas das nuvens de pontos normalizadas obtidas pela FAD, FAD-MDT_{LIDAR} e LiDAR. Os modelos ajustados para LiDAR e FAD-MDT_{LIDAR} foram utilizados para comparação com a eficiência e qualidade dos modelos gerados a partir das nuvens normalizadas FAD, sendo comparados RMSE% e R².

Para a seleção das variáveis independentes foi realizada análise de correlação de Pearson ($\hat{\rho}$) (equação 5) para verificar a colinearidade entre elas (GORGENS; SILVA; RODRIGUES, 2014). São consideradas variáveis multicolineares quando dois ou mais preditores estão relacionados entre si e explicam a variável dependente de forma semelhante (GORGENS; SILVA; RODRIGUES, 2014). Foram consideradas como variáveis não multicolineares, aquelas que apresentaram valores de $\hat{\rho}$ dentro de um limiar entre -0,8 e 0,8. A análise de multicolinearidade foi realizada após o ajuste

dos modelos, mantendo-se apenas uma variável preditora dentro cada grupo de variáveis multicolineares entre si.

$$\hat{\rho}_{x_1x_2} = \frac{\sum_i^n (x_1 - \bar{x}_1)(x_2 - \bar{x}_2)}{\sqrt{\sum_i^n (x_1 - \bar{x}_1)^2} \sqrt{\sum_i^n (x_2 - \bar{x}_2)^2}} \quad (5)$$

Em que: $\hat{\rho}_{x_1x_2}$ = coeficiente de correlação linear de Pearson da amostra; x_1 e x_2 = valores observados para as variáveis x_1 e x_2 , respectivamente; \bar{x}_1 e \bar{x}_2 = média dos valores observados nas variáveis x_1 e x_2 , respectivamente.

Foi utilizado o método de busca exaustiva com o auxílio do software RStudio com o uso do pacote *Leaps* (LUMLEY, 2015). O método exaustivo testa e compara todas as variáveis independentes (X) e encontra o melhor subconjunto para prever a variável dependente (Y) na regressão linear com a utilização do algoritmo *branch-and-bound* (ramificação e limitação). Foram selecionadas as variáveis independentes para o ajuste dos modelos de cada uma das variáveis dependentes em cada um dos conjuntos de dados (FAD, LiDAR e FAD-MDT_{LiDAR}).

Para cada variável dependente em cada conjunto de dados, foram selecionados subgrupos com uma, duas, três, quatro e cinco variáveis independentes. Após a seleção das variáveis predictoras, foram realizados os ajustes dos modelos de RLM (Equação 6).

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_p X_{pi} + \varepsilon_i \quad (6)$$

Em que: Y_i = valor da variável dependente na i-ésima observação, correspondendo a altura média, DAP médio e área basal; β = coeficientes do modelo; $X_{1i}, X_{2i}, \dots, X_{pi}$ são os valores das p-ésima variáveis independentes na i-ésima observação (dados das nuvens de ponto FAD, FAD-MDT_{LiDAR} ou LiDAR); ε_i = erro aleatório do modelo.

Para a escolha do melhor modelo para cada variável dependente em cada conjunto de dados, foram comparados os RMSE% e coeficiente de determinação ajustado (Equações 2 e 4).

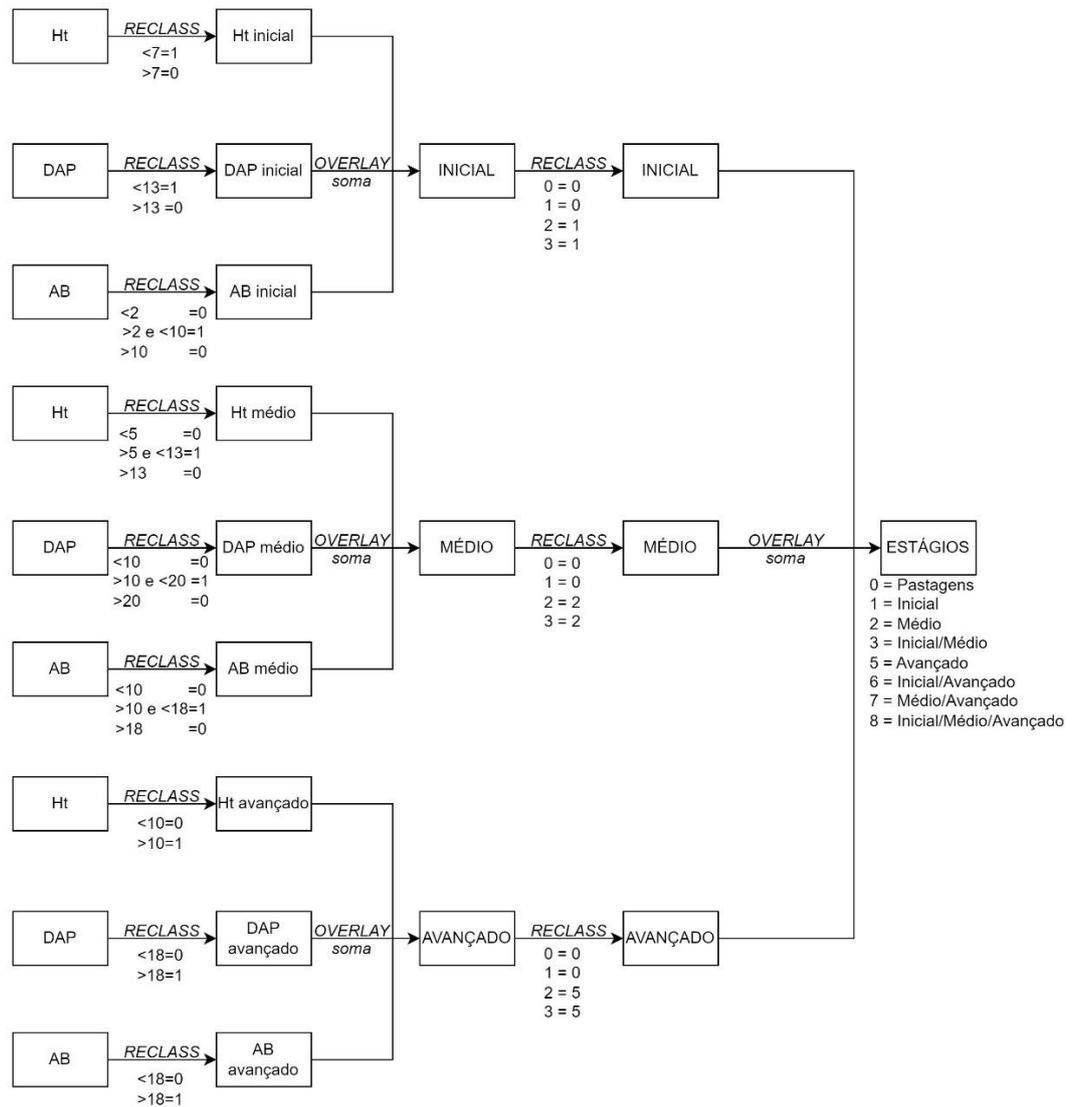
Para a validação dos modelos escolhidos, os conjuntos de dados foram divididos em 80% para ajuste e 20% para validação, com iteração de 1000 vezes. Posteriormente foram comparados as frequências de RMSE.

3.2.9 Espacialização dos modelos FAD-RPA

Com os modelos de FAD-RPA ajustados para cada variável da vegetação, foi utilizado o *software* FUSION/LDV 3.42 (US FOREST SERVICE, 2022) para a obtenção de *rasters* onde os valores dos *pixels* correspondem aos valores obtidos para cada uma das métricas utilizadas nos modelos. Estes *rasters* foram obtidos com resolução espacial de 30 m x 30 m por *pixel* (mesmo tamanho das parcelas) e posteriormente foram utilizados na aplicação dos modelos ajustados, obtendo-se os mapas de *h*, *dap* e *ab* para cada uma das oito áreas avaliadas

A partir da espacialização dos dados da vegetação, foram criados mapas de classificação dos estágios de sucessão, conforme critérios definidos na Tabela 1. Para isso, os mapas obtidos para a estimativa de *h*, *dap* e *ab* foram utilizados como arquivos de entrada, seguindo o fluxograma apresentado na Figura 12. Para que um *pixel* seja classificado em um determinado estágio, deve ter pelo menos dois parâmetros da vegetação enquadrados nesta classe.

Figura 12 – Fluxograma de classificação do estágio de sucessão



Fonte: o autor.

3.2.10 Análise de custo-benefício

Para a análise de custo benefício, foram comparados os três métodos de obtenção de dados, sendo eles a FAD, o LiDAR PLS e o IFT. Para isso, foram analisados três componentes de custos associados a cada método: equipamentos (incluindo licenças de *softwares*), aquisição de dados e processamento e análise de dados. Primeiramente, foram calculados os custos totais de cada método e posteriormente foi identificado separadamente o custo total de aquisição de

equipamentos e o custo de aquisição e análise de dados por hectare mensurado. Os custos foram calculados com valores atualizados para o mês de junho de 2022.

Para o método de FAD, foram realizados oito voos que mapearam uma área total de 201 ha. Para a área mensurada pelos métodos de IFT e PLS, foram consideradas as somas das áreas das 40 parcelas de 0,09 ha, totalizando 3,6 ha.

No componente de custos de equipamentos, foram considerados os custos de aquisição dos equipamentos e *softwares* necessários para cada método, sendo considerada a utilização de um computador do mesmo modelo para os três métodos. Para os métodos de FAD e PLS foi necessário a coleta de pontos com GPS RTK e para isso foi considerado o aluguel do equipamento modelo x por R\$250,00/dia. Ao todo, foram gastos 12 dias para coletar 178 pontos, chegando a um custo de R\$16,85/ponto. Considerando ainda uma jornada de 11 horas de trabalho diários, obtém-se uma média de 1,85 pontos/h, que foi utilizada para calcular o custo da hora/homem necessária para a coleta dos pontos durante os cálculos da componente aquisição de dados.

Os custos associados a etapa de aquisição de dados foram calculados considerando a hora/homem necessária para cada etapa inerente a cada método e também a diária de aluguel de carro e hospedagem. Para os três métodos, foram consideradas equipes com três membros. Portanto, para este componente, todas as horas/homem foram multiplicadas por três, exceto para o planejamento de voo. O valor da diária de hospedagem é para um quarto de três hóspedes. Para as diárias de hospedagem e veículo, foram considerados os dias necessários para a coleta de dados acrescidos de duas diárias para chegada e retorno. Para a coleta dos pontos de controle com o GPS RTK, foi considerada uma média de cinco GPCs para cada um dos oito voos de FAD e quatro pontos por parcela para as coletas com PLS.

Para avaliar os custos associados à componente de processamento e análise de dados, foi calculada a hora/homem necessária para cada etapa inerente a cada um dos métodos. Foi considerado apenas uma pessoa para a análise de dados nos três métodos.

O valor da hora/homem foi baseado na hora técnica de R\$153,00/hora para o um profissional de ciências agrárias no estado do Espírito Santo (SEEA; AEFES; CREA-ES, 2012). É necessário ressaltar que, para esta pesquisa, as coletas dos três métodos foram realizadas simultaneamente na mesma expedição. Portanto, para calcular cada método separadamente, os custos dos componentes de aquisição de

dados e análise e processamento de dados foram diluídos para a menor unidade de cada item e avaliadas quantas unidades foram necessárias para cada método.

4 RESULTADOS E DISCUSSÃO

4.1 Resultados IFT e classificação de estágios das parcelas

Os valores de h , dap e ab , além de outros parâmetros das 40 parcelas do IFT, são apresentados na Tabela 4 juntamente com a classificação do estágio de sucessão de cada parcela de acordo com os critérios definidos pelo CONAMA 29/94.

Tabela 4 – Parâmetros observados no IFT e classificação de acordo com o CONAMA.

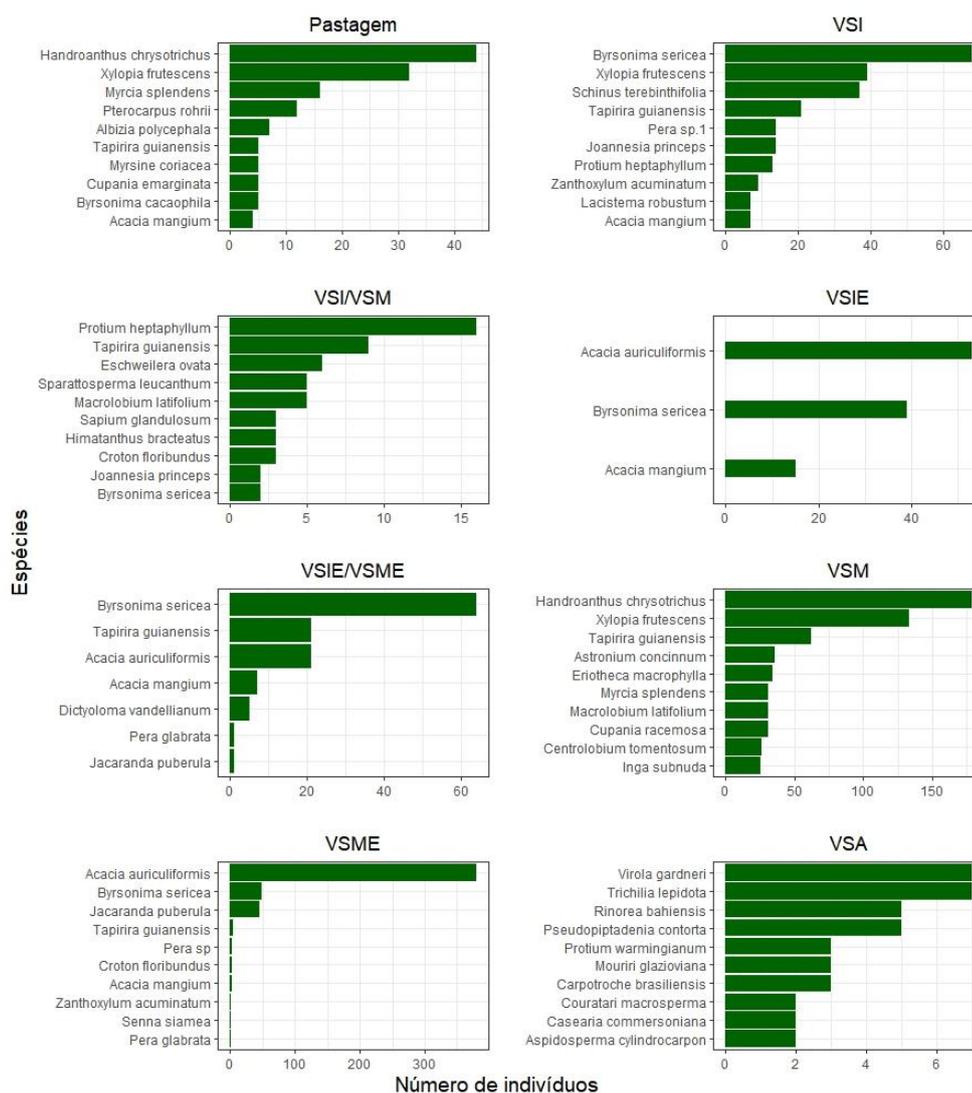
Parcela	dap	h	ab	ni	CONAMA
1	0	0	0	0	Pastagem
2	0	0	0	0	Pastagem
3	0	0	0	0	Pastagem
4	0	0	0	0	Pastagem
5	0	0	0	0	Pastagem
6	5,99	4,22	0,6057	14	VSI
7	8,86	5,80	0,1393	1	VSI
8	8,89	5,80	5,0260	44	VSI
9	6,72	4,98	0,7516	6	VSI
10	6,75	4,74	0,5210	8	VSI
11	12,61	8,17	3,6055	13	VSI/VSM
12	9,64	7,74	2,8332	22	VSI
13	13,63	9,61	10,9484	32	VSME
14	7,56	5,85	2,6988	32	VSI
15	9,27	7,86	1,9157	17	Pastagem
16	6,97	6,57	1,6313	22	VSIE
17	11,82	7,73	5,5644	31	VSIE/VSME
18	9,87	8,03	0,5608	5	Pastagem
19	10,86	7,12	3,6803	16	VSIE/VSME
20	8,04	7,91	4,9073	61	VSIE
21	11,35	8,95	14,6125	84	VSME
22	9,67	7,37	11,4459	81	VSME
23	10,22	7,17	6,1436	44	VSIE/VSME
24	11,14	9,76	14,9510	69	VSME
25	10,35	11,66	14,8890	116	VSME
26	12,32	11,14	9,4958	55	VSI/VSM
27	11,35	9,37	18,0306	106	VSM
28	11,45	9,83	16,6769	101	VSM
29	11,65	9,58	16,9390	96	VSM
30	8,29	8,63	7,8337	95	VSI
31	9,12	9,71	13,4685	154	VSM
32	9,91	9,01	18,0307	131	Pastagem
33	9,19	8,00	13,8694	125	VSM
34	9,81	9,75	13,4069	120	VSM
35	9,45	8,19	13,0573	109	VSM
36	14,24	13,22	22,7074	86	VSA
37	11,80	9,93	19,9209	102	VSM
38	9,71	9,54	13,4571	120	VSM
39	11,51	9,77	17,9446	108	VSM
40	10,18	9,35	15,6695	124	VSM

Fonte: o autor.

As parcelas em que as siglas dos estágios foram acrescidas da letra “E”, indicam que foi observada a ocorrência de infestação por espécies exóticas invasoras. As parcelas que não atenderam aos critérios de nenhum dos três estágios propostos pela resolução CONAMA 29/94, foram consideradas como sendo “Pastagem”. Dessa forma é possível observar que os critérios estabelecidos pelo CONAMA nem sempre representam a realidade, onde algumas parcelas como a “32”, que de acordo com o observado em campo não apresenta características de pastagem, acabam tendo seus parâmetros não enquadrados em nenhum dos estágios propostos pelo CONAMA.

A Figura 13 apresenta a frequência das principais espécies encontradas em cada estágio.

Figura 13 – Frequência de espécies por estágio de sucessão.



Fonte: o autor.

4.2 Validação dos dados FAD-RPA

4.2.1 Modelo Digital do Terreno

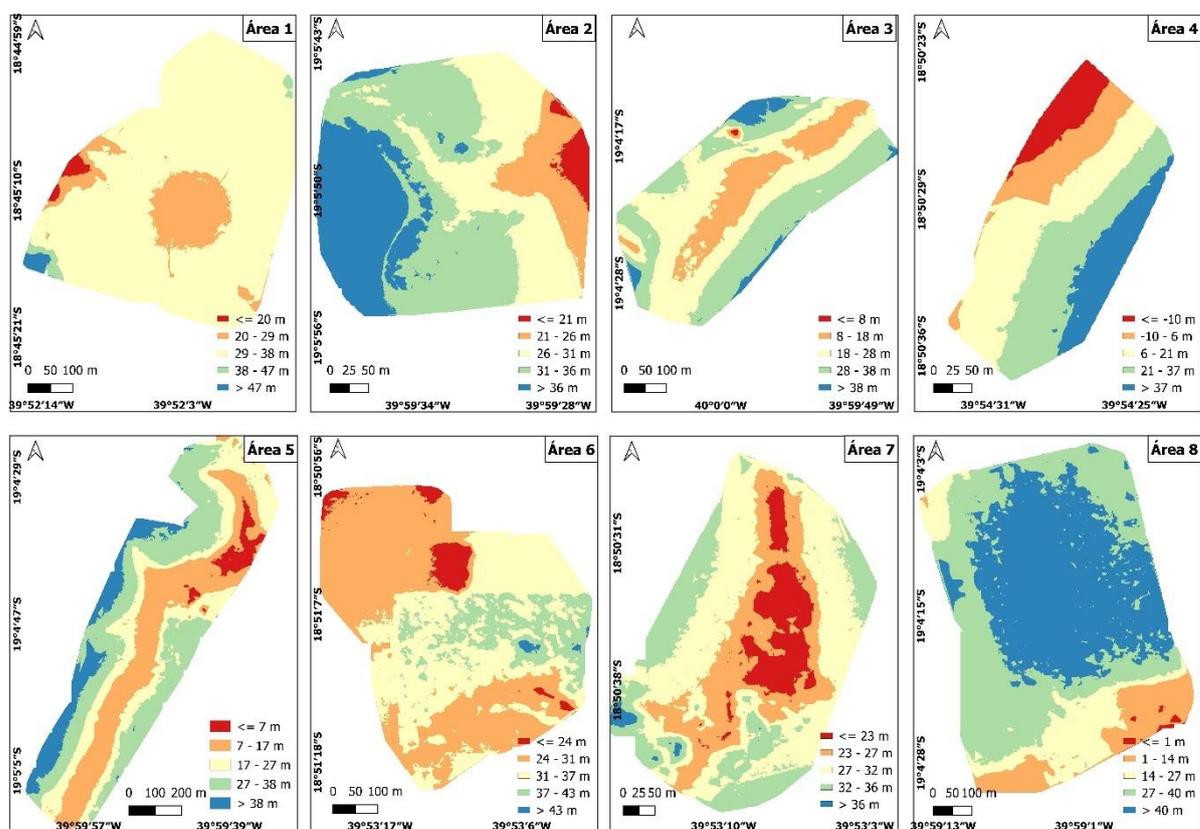
Na Figura 14, podemos observar os Modelos Digitais do Terreno (MDT) gerados por FAD-RPA para cada uma das oito áreas analisadas, além do limite das parcelas de inventário. Os valores de altitude do terreno dos vértices das parcelas coletados no campo com o RTK variaram entre 2,5 e 41,7 m, já os estimados pela FAD, entre 3,7 e 47,8 m.

A Tabela 5 apresenta a avaliação da acurácia dos valores de elevação estimados pela FAD-RPA. Na Figura 15 estão os gráficos de dispersão entre os valores medidos e estimados de altitude do terreno. Foi observada uma boa correlação ($R^2 > 0,7$) entre os valores estimados por FAD e os valores observados com RTK. A FAD foi capaz de reconstituir com eficiência mediana a posição do solo em áreas sem vegetação ou fragmentada (RMSE de 3,3 m, 15,6% e R^2 de 0,87), notando-se uma maior dificuldade na reconstrução da topografia do terreno em áreas com vegetação mais densa (RMSE de 7,4 m, 38,1% e R^2 de 0,80), assim com observado por Almeida et al. (2020). À medida que a cobertura florestal fica densa, mais delicado é o procedimento de reconstrução da elevação do terreno, chegando-se ao caso de não se obter pontos de altimetria do solo (HUNG et al., 2017).

Assim como observado em outros estudos (GIL et al., 2013) podemos observar que, de maneira geral ($n = 160$), a FAD também superestimou (Viés = -3,72 m, -18,60%) os valores de elevação, com um erro total de 6,25 m (31,23%). A superestimativa observada neste estudo pode estar relacionada com a não capacidade da FAD em penetrar o dossel e sub-bosque da vegetação (GOODBODY et al., 2017; GUERRA-HERNÁNDEZ et al., 2017; MLAMBO et al., 2017; PANAGIOTIDIS et al., 2017; ZAHAWI et al., 2015). Essa limitação fica ainda mais evidente quando consideramos apenas os valores de elevação do terreno dos vértices

das parcelas sob vegetação ($n = 103$), com R^2 de 0,8, RMSE de 38,13% (7,40 m) e Viés de -26,16% (-5,07 m). Já nos vértices das parcelas sem a presença de vegetação ($n = 57$), a capacidade de reconstrução do terreno pela FAD aumenta consideravelmente, com valores de RMSE de 15,6% (3,3 m), Viés de -6% (-1,28 m) e R^2 de 8,7. Apesar do melhor desempenho em pontos sem a presença de vegetação, os valores encontrados neste estudo são inferiores aos observados em outros trabalhos (ALMEIDA et al., 2020; KACHAMBA et al., 2016). Além de não conseguir penetrar o dossel da floresta, a baixa capacidade da FAD em representar o terreno pode estar relacionada com outras fontes, como as características do voo, o sensor utilizado na tomada das fotografias, o algoritmo de processamento de *Structure from motion* (SfM), além das características fisiográficas da área. O algoritmo utilizado de classificação de pontos representativos do terreno também pode ter sido uma fonte de erro no momento de geração do MDT (ALCUDIA-AGUILAR et al., 2019; MENG et al., 2017).

Figura 14 – Modelos Digitais de Terreno (MDT) obtidos com dados FAD-RPA.



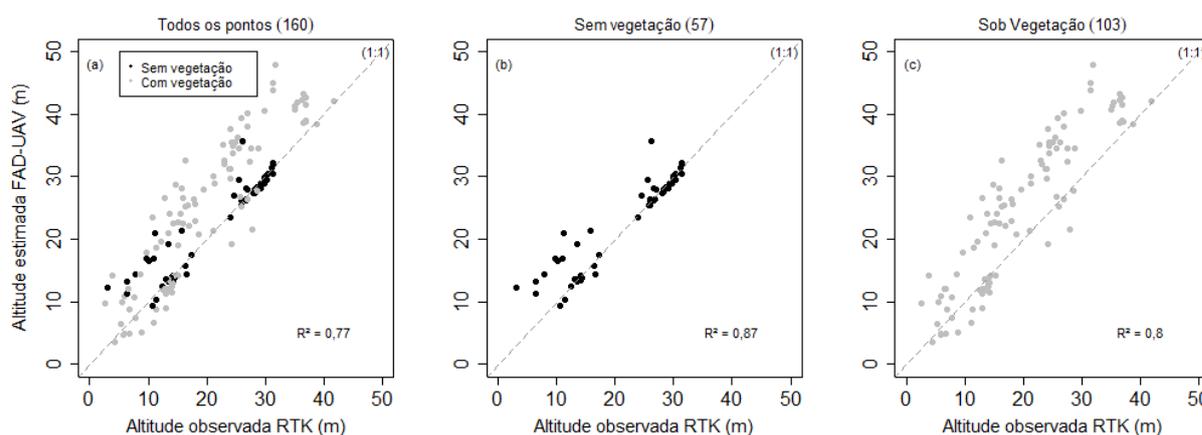
Fonte: o autor.

Tabela 5 – Estatísticas da comparação entre a altitude do MDT gerado por aerofotogrametria e a altitude dos pontos de controle do terreno obtidas por RTK em áreas sob vegetação (Presente) e em áreas sem vegetação (Ausente).

Vegetação	RMSE	RMSE (%)	Viés	Vies (%)	R ²
Sem Vegetação (n = 57)	3,30	15,62	-1,28	-6,07	0,87
Sob Vegetação (n = 103)	7,40	38,13	-5,07	-26,16	0,80
Geral (n = 160)	6,25	31,23	-3,72	-18,60	0,77

Fonte: O autor (2022).

Figura 15 - Gráficos de dispersão entre os valores de altitude do MDT gerado por aerofotogrametria e a altitude dos pontos de controle do terreno obtidas por RTK, onde: (a) todos os pontos, (b) pontos em locais sem vegetação e (c) pontos em locais sob vegetação.



Fonte: O autor (2022).

Portanto, para o levantamento de fragmentos com extensas áreas, recomenda-se a realização de voos que recubram áreas externas ao fragmento, buscando locais onde seja possível a visualização do terreno, como em estradas ou clareiras, possibilitando uma melhora na representação da altimetria do terreno. A análise apresentada diz respeito à qualidade do MDT nos pontos avaliados, não sendo possível obter conclusões sobre toda a extensão da área. Para complementar a análise sobre a acurácia do MDT e demais produtos obtidos pela FAD, também foram comparadas as alturas máximas das parcelas medidas no campo com as estimadas por FAD.

4.2.2 Alturas das árvores

4.2.2.1 Altura máxima x H_{max}

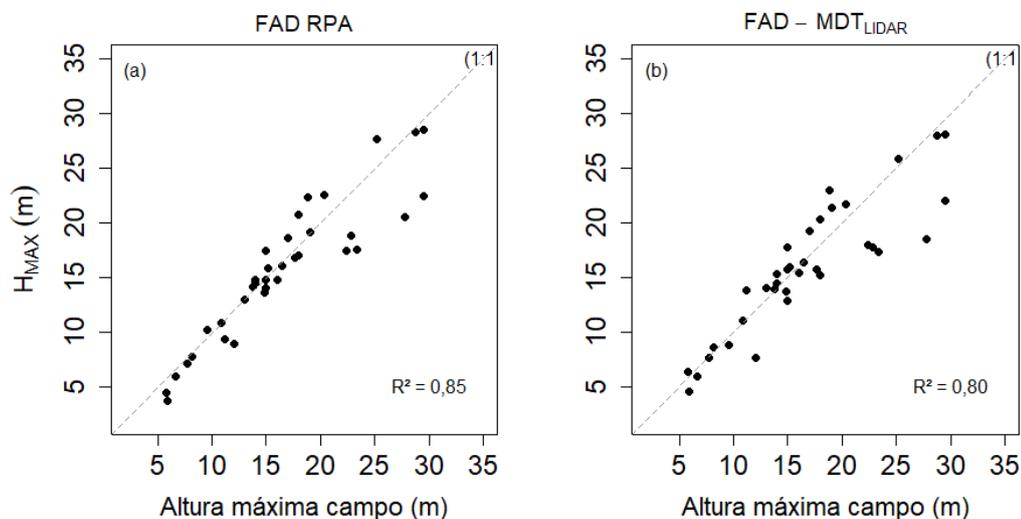
Na Tabela 6 são apresentadas os resultados da análise de acurácia das estimativas da altura máxima das árvores por parcela pela FAD-ARP e FAD-DTMLiDAR. Na Figura 16 estão os gráficos de dispersão entre os valores de altura máxima medidas no campo e estimadas (H_{max}) pelas duas nuvens de pontos 3D. É possível observar uma alta correlação ($R^2 > 0,8$) entre os valores estimados por FAD e FAD-DTMLiDAR e os valores observados na campanha de campo. Pode-se notar uma clara correspondência entre os valores de H_{max} estimados pelas nuvens de pontos FAD e FAD-DTMLiDAR, com estatísticas semelhantes entre elas (Tabela 6). Ambas nuvens 3D subestimaram (Tabela 6 e Figura 16) os valores de altura máxima, resultado já esperado e observado em outros estudos com a nuvem de pontos normalizada com o DTM LiDAR (Goodbody et al., 2017). Além da semelhança entre as estimativas das alturas máximas, o desempenho também foi satisfatório, com valores de RMSE e Viés inferiores a 18,21% e 0,71%, respectivamente. Almeida et al. (2020) encontraram um RMSE igual a 24% em uma floresta tropical secundária de Mata Atlântica no nordeste do Brasil na estimativa das alturas máximas.

Tabela 6 – Estatística da comparação entre a métrica H_{max} obtida por FAD-RPA e FAD-MDTLiDAR e as alturas máximas das parcelas obtidas pelo IFT.

Método	RMSE	RMSE (%)	Viés	Vies (%)	R²
FAD-RPA	2,63	15,92	0,77	4,71	0,85
FAD-DTMLiDAR	3,00	18,21	0,71	4,31	0,80

Fonte: O autor (2022).

Figura 16 - Gráficos de dispersão entre a métrica H_{max} obtida por (a) FAD-RPA e (b) FAD-MDT_{LIDAR} comparadas com as alturas máximas das parcelas de campo.



Fonte: O autor (2022).

Apesar das dificuldades inerentes à obtenção do MDT pela FAD, este método se mostrou satisfatório para a estimativa da altura máxima da parcela, apresentando alta correlação entre o ponto mais alto da nuvem de pontos (H_{max}) e a altura da maior árvore. Ganz; Käber; Adler, (2019) demonstraram que a obtenção de altura de árvores por meio de FAD pode ser mais precisa do que as técnicas tradicionais de triangulação, sendo tão confiáveis quanto LiDAR. Assim como observado neste estudo, Dandois; Ellis, (2013) estimaram a altura de dossel a partir de dados FAD e de dados híbridos de FAD com LiDAR e encontraram R^2 de 0,83 e 0,84 e RMSE de 9,3 m e 6,8 m, respectivamente. Além das características da vegetação, o relevo plano/levemente ondulado das áreas analisadas podem ter contribuído com o bom desempenho observado nas estimativas das alturas, demonstrando assim que nuvens de pontos derivadas apenas de FAD podem ser utilizadas em áreas com vegetação e relevo semelhantes ao do deste estudo.

4.2.2.2 Altura dominante HP_{95}

Na Tabela 7 são apresentadas as estatísticas da métrica HP_{95} (percentil 95), extraídas das nuvens de pontos FAD e FAD-DTM_{LIDAR}, comparadas com as alturas

dominantes das parcelas observadas no campo. Já na Figura 17 estão os gráficos de dispersão entre os valores de altura dominante e HP_{95} . É possível observar uma alta correlação ($R^2 > 0,84$) entre os valores estimados e observados pelas duas nuvens de pontos e um erro total semelhante entre elas, com valores de RMSE de aproximadamente 1,8 m (15%). Os resultados obtidos se assemelham ao apresentado por Carvalho (2021), que encontrou uma relação linear entre a altura dominante e métricas obtidas por FAD. As estimativas de altura dominante diretamente pela métrica HP_{95} , de forma geral, apresentaram valores mais baixos do que as alturas obtidas no campo, tanto para nuvem de pontos FAD quanto para a nuvem da FAD-DTMLIDAR. Entretanto, a estimativa da FAD apresentou uma maior subestimação (4,83%) dos valores de HP_{95} .

A métrica HP_{95} representa a altura na qual 95% dos pontos da nuvem se encontram abaixo dela, enquanto que a altura dominante representa a média de 20% das maiores árvores da parcela (GORGENS; SILVA; RODRIGUES, 2014; SCHNEIDER; SCHNEIDER, 2008).

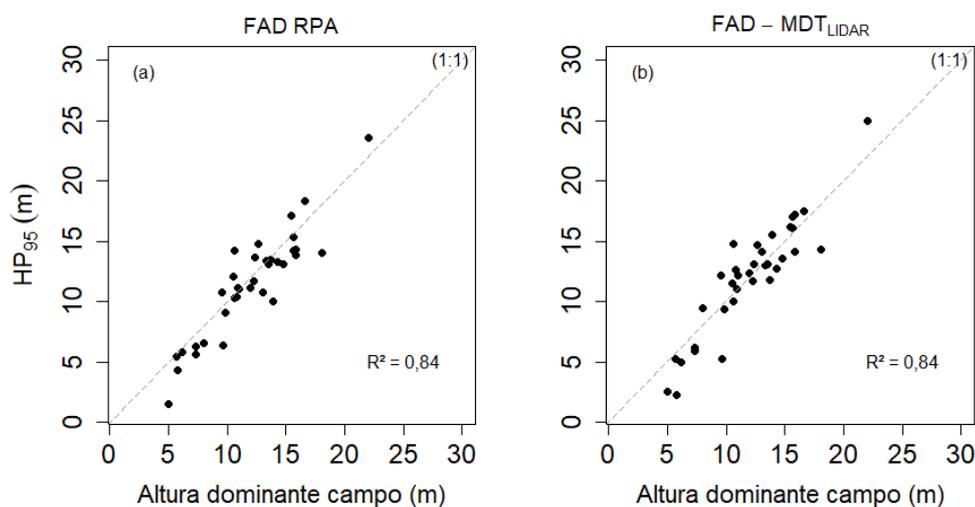
Tabela 7 - Estatística da comparação entre a métrica HP_{95} (percentil 95) obtidas por FAD e FAD-MDTLIDAR e as alturas dominantes das parcelas obtidas pelo IFT.

Método	RMSE	RMSE (%)	Viés	Vies (%)	R^2
FAD	1,80	15,04	0,58	4,84	0,84
FAD PLS	1,87	15,63	0,05	0,44	0,84

Fonte: O autor (2022).

A análise dos gráficos e das estatísticas, indica que, assim como para altura máxima, tanto FAD quanto FAD-DTMLIDAR tem uma tendência a subestimar os valores de altura dominante. Observa-se que não houve grandes diferenças entre as estatísticas de FAD e de FAD-DTMLIDAR, sendo que, para os dados obtidos neste trabalho, os dois métodos apresentaram acurácia semelhantes. A tendência a subestimar os valores de altura também foi verificada por Ganz; Käber; Adler, (2019), e é um indicativo de que a superestimação das altitudes do MDT, apresentada no tópico “4.2.1”, ocorreu por toda a extensão avaliada, não somente nos locais onde foram obtidos os pontos de controle do terreno.

Figura 17 - Gráficos de dispersão entre a métrica HP95 (percentil 95) obtida por (A) FAD e (B) FAD-MDT_{LIDAR} comparada com as alturas dominantes das parcelas de IFT.



Fonte: O autor (2022).

4.3 Modelos selecionados

Modelos de regressão linear múltipla foram ajustados para estimar os valores de altura média (h) diâmetro médio (dap) e área basal (ab) de indivíduos pertencentes às 40 parcelas de inventário florestal tradicional. Alguns autores avaliaram a contribuição de dados espectrais associados às nuvens de pontos aerofotogramétricas para a previsão de atributos florestais a partir de uma abordagem por área e concluíram que o benefício foi insignificante (TOMPALSKI et al., 2019).

Em uma ampla revisão realizada por (GOODBODY et al., 2017), constatou-se que os estudos tem demonstrado que dados de nuvens de pontos FAD podem gerar inventários florestais precisos. Em concordância com a literatura, os resultados obtidos neste estudo, apresentados a seguir nos tópicos “4.3.1”, “4.3.2” e “4.3.3”, indicam que a FAD demonstrou-se confiável para estimativa de altura média, DAP médio e área basal por meio de uma abordagem por área.

4.3.1 Altura total média

Na Tabela 8 são apresentados os modelos e seus respectivos parâmetros estimados, que apresentaram melhor desempenho para a estimativa de altura total média (h) a partir de nuvens de pontos FAD-RPA, LiDAR e FAD-MDT_{LiDAR}. De modo geral, todos os coeficientes associados às variáveis foram significativos, indicando que as variáveis preditoras selecionadas possuem relação com a variável resposta. Para todas as fontes de dados, foram selecionadas quatro métricas como variáveis preditoras.

Tabela 8 – Modelos selecionados para estimar altura média a partir de FAD-RPA, FAD-MDT_{LiDAR} e LiDAR.

Fonte	Modelos
FAD-RPA	Hcv + HMADmedian + HP30 + CC%1m
FAD-MDT _{LiDAR}	Hmin + HLcv + Hlkurt + HP75
LiDAR	Hiq + HLcv + HSQRTmeanSQ + CC%1m

Fonte: O autor (2022).

Na Tabela 9 são apresentadas as estatísticas dos modelos selecionados para estimar a h . Observa-se que, para as três fontes de dados, o desempenho foi satisfatório e semelhante entre as diferentes fontes, com a FAD-MDT_{LiDAR} apresentando erros um pouco mais elevados (RMSE de 12,97%, 0,95m), indicando que, para este parâmetro, o uso de dados híbridos não foi satisfatório para a melhoria da estimativa através de nuvem de pontos FAD. Gyawali et al. (2022), não encontraram diferenças significativas entre a estimativa de altura por FAD ou por LiDAR, o que corrobora o presente estudo, que evidenciou a FAD-RPA errando apenas 2,53% a mais que o LiDAR (RMSE de 11,11%, 0,81m e RMSE de 8,58%, 0,63m). Portanto, dados FAD podem ser utilizados para a estimativa de altura média por RLM, através de uma abordagem por área, apresentando resultados com qualidade próximas aos dados LiDAR.

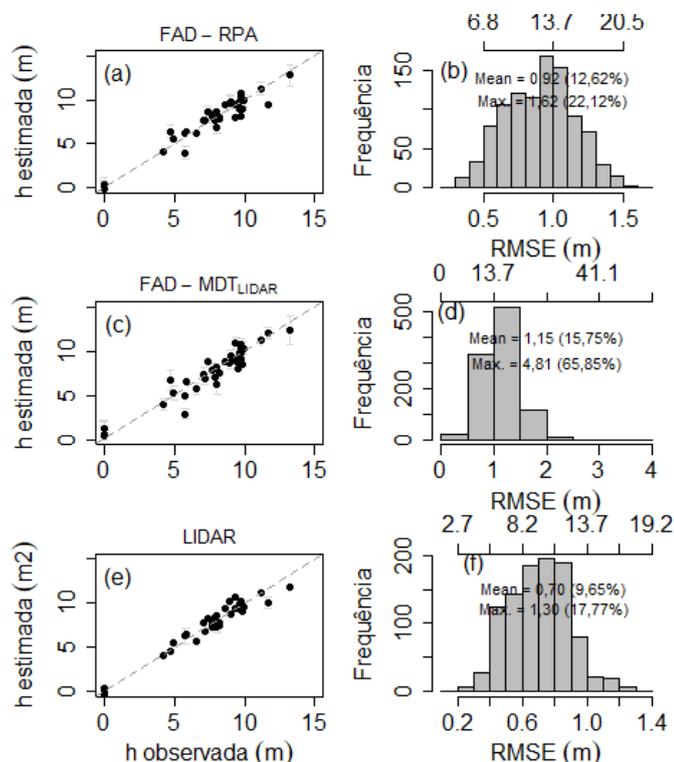
Tabela 9 - Estatísticas de ajuste e validação dos melhores modelos selecionados para estimar altura média a partir de FAD-RPA, FAD-MDT_{LIDAR} e LiDAR.

Fonte	BIC	Ajuste			Validação		
		RMSE	RMSE%	R ²	RMSE	RMSE%	R ²
FAD-RPA	118,92	0,81	11,11	94,0%	0,92	12,62	88,20%
FAD-MDT _{Lidar}	197,82	0,95	12,97	91,8%	1,15	15,75	86,58%
LiDAR	98,20	0,63	8,58	96,4%	0,70	9,65	93,59%

Fonte: O autor (2022).

As estatísticas apresentadas na tabela 9 corroboram os histogramas de frequência de RMSE observada nas validações dos modelos (Figura 18), apresentando valores médios semelhantes aos valores de RMSE encontrados no ajuste. Nota-se que os três métodos apresentaram distribuição normal.

Figura 18 – Gráficos de dispersão entre os valores de h média estimados e observados para (a), (c) e (e) e os histograma de frequência de RMSE na validação de modelos (b), (d) e (f), ambos para FAD, FAD-MDT_{LIDAR} e LiDAR.



Fonte: o autor.

Em revisão realizada por Goodbody; Coops; White, (2019), observou-se que a utilização de nuvens de pontos FAD normalizadas com MDTs de LiDAR, pode ser recomendada para a atualização de inventários aprimorados. No presente trabalho,

os desempenhos apresentados por FAD-MDT_{LiDAR} e FAD-RPA foram semelhantes, porém houve uma piora em relação aos resultados observados com dados FAD-RPA sozinhos, indicando que é possível realizar o ajuste de modelos estatísticos utilizando dados FAD-RPA de forma confiável sem a utilização MDT's LiDAR, a depender de fatores como características da vegetação avaliada e qualidade do levantamento aerofotogramétrico.

4.3.2 DAP médio.

Os modelos que apresentaram melhor desempenho para a estimativa de *dap* são apresentados na Tabela 10, com seus respectivos parâmetros estimados e as variáveis selecionadas. De modo geral, todos os coeficientes associados às variáveis foram significativos, indicando que as variáveis preditoras selecionadas possuem relação com a variável resposta. Em todas as fontes de dados foram selecionadas quatro métricas como variáveis preditoras para o melhor ajuste.

Tabela 10 - Melhores modelos para estimar DAP médio a partir de FAD-RPA, FAD-MDT_{LiDAR} e LiDAR.

Fonte	Modelos
FAD-RPA	Hmode + HLcv + HP40 + CC%1m
FAD-MDT _{LiDAR}	Hmin + HL1 + HLcv + CC%Hmode
LiDAR	HLcv + Hlkurt + HP05 + HP40

Fonte: O autor (2022).

Na Tabela 11 são apresentadas as estatísticas dos modelos selecionados para estimar o *dap*. Observa-se que os três métodos apresentaram desempenho satisfatório para estimar diâmetro. Assim como para *h*, a FAD-MDT_{LiDAR} apresentou o pior desempenho, com RMSE de 18,14% e R² de 82,16%. Estudos realizados por SHIMIZU et al. (2022), encontram resultados diferentes, indicando que a integração de dados de fotogrametria com LiDAR é benéfica para a estimativa de atributos florestais. Já FAD-RPA e LiDAR apresentaram resultados muito semelhantes, com FAD-RPA apresentando RMSE de 12,23% e R² de 91,89% e LiDAR com RMSE de 11,47% e R² de 92,87%

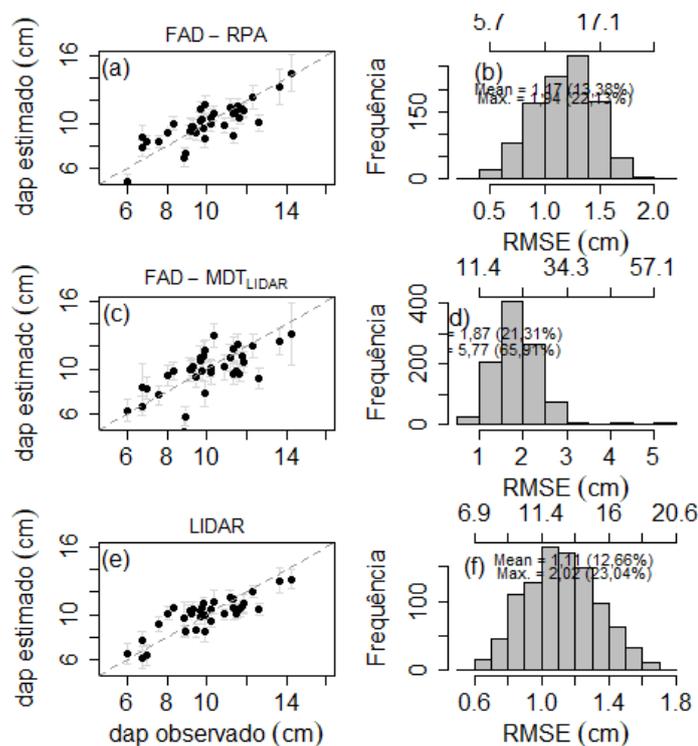
Tabela 11 - Estatísticas de ajuste e validação dos melhores modelos selecionados para estimar DAP médio a partir de FAD-RPA, FAD-MDT_{LIDAR} e LiDAR.

Fonte	BIC	Ajuste			Validação		
		RMSE	RMSE%	R ²	RMSE	RMSE%	R ²
FAD-RPA	141,14	1,07	12,23	91,89%	1,17	13,38	82,90%
FAD-MDT _{Lidar}	197,82	1,59	18,14	82,16%	1,87	21,31	69,94%
LiDAR	135,96	1,00	11,47	92,87%	1,11	12,66	83,25%

Fonte: O autor.

As estatísticas apresentadas na Tabela 11 corroboram os histogramas de frequência de RMSE observada nas validações dos modelos (Figura 19), apresentando valores médios semelhantes aos valores de RMSE encontrados no ajuste. Nota-se que os três métodos apresentaram distribuição normal. Os resultados observados em nosso estudo corroboram os encontrados por Moe et al. (2020), que indicam que a FAD-RPA pode prever valores de *dap* com precisão comparável à estimativa realizada com dados LiDAR.

Figura 19 - Gráficos de dispersão entre os valores de *dap* média estimados e observados (a), (c) e (e) e os histograma de frequência de RMSE na validação de modelos (b), (d) e (f), ambos para FAD-RPA, FAD-MDT_{LIDAR} e LiDAR.



Fonte: o autor.

De forma geral, o ajuste de modelos de RLM para a estimativa de DAP médio a partir de dados de nuvens de pontos FAD, FAD-MDT_{LIDAR} e LiDAR, apresentou resultados razoáveis.

Os resultados encontrados para dados FAD-MDT_{LIDAR} foram inferiores em relação aos outros dois métodos. Estudos realizados por (SHIMIZU et al., 2022) encontram resultados diferentes, indicando que a integração de dados de fotogrametria com LiDAR é benéfica para a estimativa de atributos florestais.

FAD e LiDAR apresentaram resultados de ajustes muito semelhantes, com a FAD obtendo RMSE sutilmente menor. Tais fatos corroboram os resultados encontrados por Moe et al., (2020), que indicam que a FAD pode prever valores de DAP com precisão comparável à previsão realizada com dados LiDAR.

4.3.3 Área basal (ab).

Os modelos que apresentaram melhor desempenho de ajuste para a estimativa da área basal a partir de nuvens de pontos FAD, FAD-MDT_{LIDAR} e LiDAR, são apresentados na tabela 12, com seus respectivos parâmetros estimados e as variáveis selecionadas. De modo geral, todos os coeficientes associados às variáveis foram significativos, indicando que as variáveis preditoras selecionadas possuem relação com a variável resposta. Para o ajuste dos modelos para as três fontes de dados foram necessárias apenas três métricas como variáveis preditoras

Tabela 12 - Melhores modelos para estimar área basal a partir de FAD-RPA, FAD-MDT_{LIDAR} e LiDAR.

Fonte	Modelos
FAD-RPA	Hmode + HP01 + CC%1m
FAD-MDT _{Lidar}	Hmin + Hmean + CCHmode
LiDAR	Hmax + Hiq + HL1

Fonte: O autor.

Na tabela 13 são apresentadas as estatísticas dos modelos selecionados para estimar área basal. Observa-se que os três métodos apresentaram desempenhos semelhantes. Diferente do observado para *h* e *dap*, o modelo para estimativa por FAD

apresentou os melhores resultados de RMSE e $R^2(\%)$ em relação aos outros dois métodos.

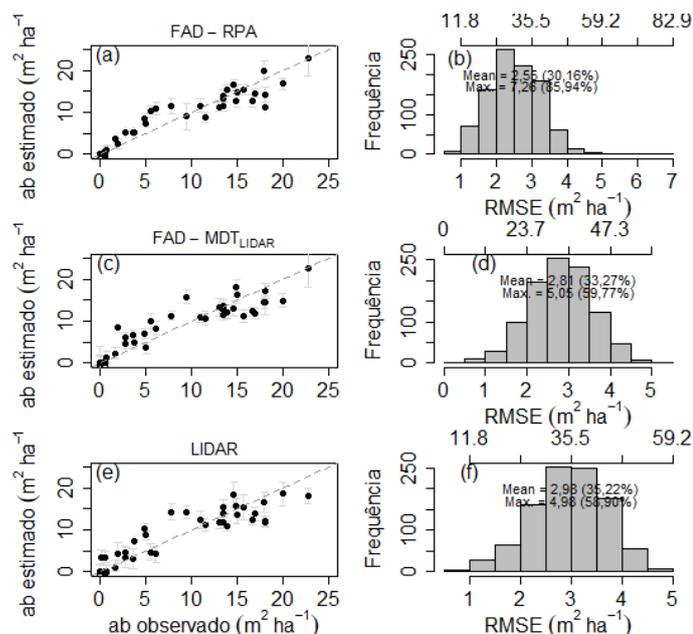
Tabela 13 - Estatísticas de ajuste e validação dos melhores modelos selecionados para estimar área basal a partir de FAD-RPA, FAD-MDT_{LIDAR} e LiDAR.

Fonte	BIC	Ajuste			Validação		
		RMSE	RMSE%	R^2	RMSE	RMSE%	R^2
FAD-RPA	202,13	2,40	28,46	88,3%	2,55	30,16	87,18%
FAD-MDT _{LIDAR}	213,04	2,76	32,61	84,6%	2,81	33,27	84,56%
LiDAR	215,51	2,84	33,63	83,6%	2,98	35,22	83,41%

Fonte: O autor (2022).

As estatísticas apresentadas na Tabela 13 corroboram os histogramas de frequência de RMSE observada nas validações dos modelos (Figura 20), apresentando valores médios semelhantes aos valores de RMSE encontrados no ajuste. Nota-se que os três métodos apresentaram distribuição normal.

Figura 20 – Gráficos de dispersão entre os valores de *ab* estimados e observados (a), (c) e (e) e os histograma de frequência de RMSE na validação de modelos (b), (d) e (f), ambos para FAD-RPA, FAD-MDT_{LIDAR} e LiDAR.



Fonte: o autor.

Os três métodos demonstraram-se confiáveis para a estimativa de área basal a partir de modelos estatísticos obtidos por RLM, corroborando o que vem sendo

encontrado na literatura. (IQBAL et al., 2019; KUKKONEN; MALTAMO; PACKALEN, 2017). A integração de dados de FAD com LiDAR demonstrou-se inferior em relação ao uso de dados exclusivamente de FAD para a estimativa desta variável, diferentemente do observado por Ullah et al., (2019), que encontraram resultados próximos para dados LiDAR e dados FAD integrados com MDT LiDAR.

Em geral, os estudos publicados vem demonstrando melhores desempenhos para dados LiDAR (GOBAKKEN; BOLLANDSÅS; NÆSSET, 2015; IQBAL et al., 2019; KUKKONEN; MALTAMO; PACKALEN, 2017). Entretanto, estimativa por meio de dados FAD foi superior à utilização de dados LiDAR no presente estudo.

4.4 Mapas de espacialização dos modelos FAD-RPA

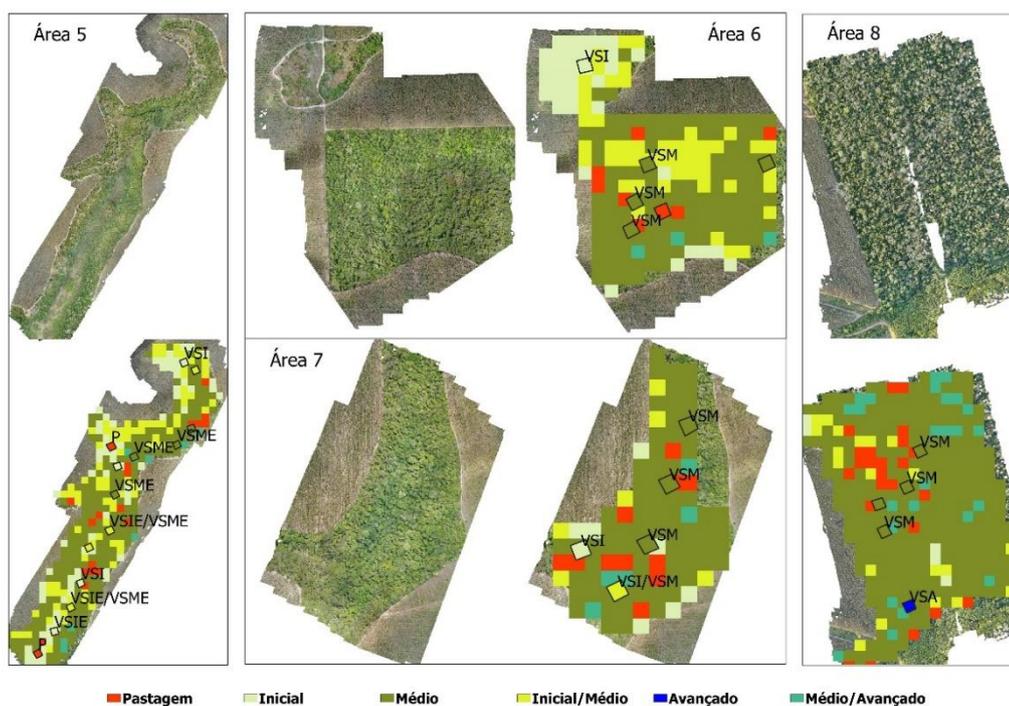
As Figuras 21 e 22 apresentam os mapas resultantes da estimativa dos estágios de sucessão de acordo com os parâmetros estabelecidos pela resolução CONAMA 29/94 após a execução dos procedimentos descritos no fluxograma apresentado na Figura 12. Algumas áreas se enquadraram simultaneamente nos critérios do estágio inicial e do estágio médio. Outras, se enquadraram simultaneamente no estágio médio e estágio avançado. Dessa forma, foram consideradas áreas em transição do estágio inicial para o médio ou do estágio médio para o avançado. Além da espacialização da estimativa dos estágios, as Figuras 21 e 22 também apresentam as parcelas do IFT e seus respectivos estágios de acordo com o CONAMA 29/94. Para as parcelas onde foram identificadas infestações por exóticas durante o IFT, as siglas de identificação dos estágios foram acrescidas da letra "E".

Figura 21 – Espacialização da estimativa do estágio de sucessão das áreas de 1 a 4, a partir de nuvens de pontos FAD-RPA.



Fonte: o autor.

Figura 22 – Espacialização da estimativa do estágio de sucessão das áreas de 5 a 8, a partir de nuvens de pontos FAD-RPA.



Fonte: o autor.

4.5 Análise de custo benefício

A Tabela 14, apresenta os custos totais obtidos neste trabalho para a classificação de estágios de sucessão em uma floresta de mata atlântica a partir de FAD-RPA, LIDAR PLS e IFT, com seus respectivos componentes de custos. As tabelas com os valores detalhados dos itens e subcomponentes de cada metodologia, são apresentadas nos apêndices A, B e C. O LIDAR PLS apresentou o maior custo total, com R\$466.309,12, seguido do IFT com R\$136.009,94 de custo total e, por fim, a FAD-RPA apresentou o menor custo total, com R\$103.659,42.

Tabela 14 – Custos obtidos para obtenção de dados por FAD-RPA, LIDAR PLS e IFT.

Componente	FAD-RPA	LIDAR PLS	IFT
	Valor	Valor	Valor
Equipamento	R\$ 86.895,23	R\$ 407.092,15	R\$ 41.443,94
Aquisição de dados	R\$ 12.912,13	R\$ 56.724,60	R\$ 92.118,00
Processamento e análise de dados	R\$ 3.852,06	R\$ 2.492,37	R\$ 2.448,00
Total	R\$ 103.659,42	R\$ 466.309,12	R\$ 136.009,94

Fonte: o autor.

A partir dos dados apresentados na Tabela 15, é possível observar separadamente os custos de aquisição de equipamentos e os custo de aquisição e processamentos dos dados para as três metodologias. Nota-se que o alto custo do LIDAR PLS tem grande influência do componente de aquisição de equipamentos, representando R\$407.092,15, enquanto que para o FAD-RPA o componente representa R\$86.895,23 e para o IFT, apenas R\$41.443,94. Quanto ao custo de aquisição e processamento de dados por hectare, a capacidade e velocidade de amostragem apresentada pela FAD-RPA resultou em um custo por hectare consideravelmente menor do que os outros métodos avaliados, sendo apenas R\$83,40/ha, seguido por LIDAR PLS com R\$16.449,16/ha e o IFT com R\$26.268,33/ha.

Tabela 15 – Custo de equipamentos e custo por hectare para aquisição de dados por FAD-RPA, LIDAR PLS e IFT.

Item	FAD-RPA	LIDAR PLS	IFT
Área da amostra (hectares)	201	3,6	3,6
Custo de equipamentos	R\$ 86.895,23	R\$ 407.092,15	R\$ 41.443,94
Custo de aquisição e processamento de dados por hectare	R\$ 83,40	R\$ 16.449,16	R\$ 26.268,33

Fonte: o autor

Apesar de possuir menor custo de aquisição de equipamentos, as operações de aquisição de dados pelo IFT são lentas e com capacidade de amostragem limitadas (NAVARRO et al., 2020). As limitações inerentes às operações de IFT tornaram o custo por hectare mais elevado, assim como descrito por Nogueira et al., (2010), além de expor os operadores a maiores riscos e por mais tempo.

Atualmente, o custo de aquisição de equipamentos para operações com LIDAR PLS ainda é muito elevado, sendo a aquisição do próprio sistema LIDAR o principal fator (BERBERT, 2016; PEREIRA, 2018). A aquisição de dados de inventário florestal pelo método LIDAR PLS, consegue ser mais rápida do que em comparação ao IFT, mas ainda possui grandes limitações em termos do tamanho da área amostrada em comparação à FAD-RPA. Araújo et al., (2021) destacam que, levantamentos PLS para fins de modelagem 3D apresentam custos mais elevados e exigem mais trabalho em campo, enquanto que levantamentos FAD para os mesmos fins, apresentam-se como solução confiável e de baixo custo.

A FAD possui custo intermediário de aquisição de equipamentos quando comparado aos outros dois métodos avaliados. Como demonstrado, o custo com equipamentos para operações de FAD pode ser aproximadamente duas vezes maior do que o de IFT e aproximadamente cinco vezes menor do que para PLS. Entretanto, a capacidade de recobrimento de área a ser amostrada é significativamente maior do que para PLS e IFT. Enquanto as amostragem realizadas por IFT e PLS limitaram-se ao tamanho das parcelas, totalizando 3,6 ha de amostra para cada método, a FAD pode recobrir uma área de 201 ha de amostra. Dessa forma, a FAD se mostra adequada ao uso florestal devido ao baixo custo operacional e alta intensidade de recobrimento (REX; KÄFER; DALLA CORTE, 2020; TANG; SHAO, 2015)

Naturalmente, a adoção de uma metodologia de coleta de dados LiDAR por meio de plataforma aérea (ALS), resultaria em capacidade de amostragem similar à FAD. Entretanto, a inclusão do custo de aquisição de um RPAS capaz de operar com um sistema LiDAR, aumentaria ainda mais os custos de aquisição de equipamentos. Tal fato foi confirmado por Kangas et al., (2018), quando avaliaram o custo de aquisição de dados ALS e FAD para tomada de decisões florestais e concluíram que a melhor acurácia do ALS não afeta significativamente os resultados para tomada de decisão e ALS e FAD podem ser igualmente recomendadas para o planejamento do manejo florestal.

5 CONCLUSÃO

A coleta de dados de campo a partir do método de inventário florestal tradicional, permitiu a obtenção de parâmetros da vegetação para a correta identificação de estágios de sucessão ecológica em áreas com vegetação secundária do bioma da Mata Atlântica. Além disso, os dados de campo coletados representaram a estrutura da área de estudo de forma ampla, com dados variando desde pastagens limpas até vegetações em estágio avançado de sucessão, apresentando-se como boa fonte para ajuste de modelos estatísticos.

A fotogrametria aérea digital apresenta tendência a superestimar a altitude do terreno, principalmente em área de vegetação densa, ocasionando uma tendência de subestimação da altura da nuvem de pontos. Portanto, não é indicado a realização de estimativa de alturas a partir da comparação direta com métricas da nuvem de pontos FAD-RPA. Entretanto, a alta correlação com dados de campo, permitiu bons ajustes de modelos estatísticos para a estimativa de altura total média (h), diâmetro a 1,30 m do solo (dap) e área basal (ab), apresentando resultados semelhantes aos encontrados com a utilização de dados FAD integrados com dados LiDAR ou com dados exclusivamente LiDAR. Os modelos obtidos com dados FAD-RPA, permitiram a obtenção de mapas de espacialização das estimativas de h , dap e ab , além da espacialização dos estágios de sucessão ecológica.

A fotogrametria aérea digital demonstrou ser um método tecnicamente eficaz e economicamente acessível para a estimativa dos atributos florestais necessários para a classificação de estágios sucessionais na mata atlântica, demonstrando-se mais econômico do que com LiDAR e com o método tradicional.

REFERÊNCIAS

- AGISOFT. **Agisoft Metashape: Agisoft Metashape**. Disponível em: <<https://www.agisoft.com/>>. Acesso em: 7 ago. 2022.
- ALCUDIA-AGUILAR, A. *et al.* Allometric estimation of the biomass of *Musa* spp. in homegardens of Tabasco, Mexico. **Tropical and Subtropical Agroecosystems**, v. 22, n. 1, 2019.
- 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, G. J. F. de. **Uso do laser scanner terrestre na estimativa de parâmetros biométricos em povoamentos florestais**. Tese de Doutorado. Universidade de São Paulo.
- ALVARES, C. A. *et al.* Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013.
- ANDRADE, D. C.; ROMEIRO, A. R. Degradação ambiental e teoria econômica: algumas reflexões sobre uma “Economia dos Ecossistemas”. **Economia**, v. 12, n. 1, 2011.
- ARAÚJO, J. P. D. C. *et al.* 34. Uso do lidar na geomorfologia: aplicações e desafios futuros. **Revisões da geomorfologia brasileira**, p. 931-956, 2021.
- ASSIS, A. L. *et al.* Development of a sampling strategy for young stands of *Eucalyptus* sp. using geostatistics. **Cerne**, v. 15, n. 2, p. 166-173, 2009.
- ÁVILA, G. C. *et al.* Proposta de um plano de recuperação de áreas degradadas (prad) para a área de preservação permanente (app) do arroio estância velha–estância velha/rs. Simpósio Nacional de Qualidade Ambiental. 10, 2016, Porto Alegre.
- BACCINI, A.; ASNER, G. P. Improving pantropical forest carbon maps with airborne LiDAR sampling. **Carbon Management**, v. 4, n. 6, p. 591-600, 2013.
- BERBERT, M. L. D. G. **Potencial do LiDAR terrestre como ferramenta para o manejo de florestas naturais**. 2016. 36p. Trabalho de Conclusão de Curso (Hraduação em Engenharia Florestal) – Instituto de Florestas, Universidade Federal Rural do Rio de Janeiro, Seropédica, 2016.
- BRANCALION, P. H. S.; GANDOLFI, S.; RODRIGUES, R. R. **Restauração Florestal**. 1. ed. Oficina de Textos. 2015. 432p.
- Brasil. 2006. Lei nº11.428 de 22 de dezembro de 2006: Dispõe sobre a utilização e proteção da vegetação nativa do Bioma Mata Atlântica e dá outras providências.

Disponível em :<http://www.planalto.gov.br/ccivil_03/_ato2004-2006/2006/lei/l11428.htm> . Acesso em: 3 ago. 2022.

BRASIL. LEI Nº 6.938, de 31 de agosto de 1981. Brasília, DF: Congresso Nacional, 1981. Disponível em: <http://www.planalto.gov.br/ccivil_03/leis/l6938.htm>. Acesso em: 9 maio. 2022.

BRASIL. RESOLUÇÃO CONAMA nº 029, de 07 de dezembro de 1994. **Diário Oficial da União**, Poder Executivo, Brasília, DF, 30 dez. Seção 1, p.21349-21350.

CAMPO, A. D. D *et al.* Assessing reforestation failure at the project scale: The margin for technical improvement under harsh conditions. A case study in a Mediterranean Dryland. **Science of The Total Environment**, v. 796, p. 148952, 2021.

CARVALHO, R. C. **Inventário de uma floresta de produção com a utilização de imagens msi/sentinel-2 e fotogrametria aérea digital**. 2021. 95 p. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal do Espírito Santo, Jerônimo Monteiro, 2021.

CHAZDON, R. L. *et al.* Rates of change in tree communities of secondary Neotropical forests following major disturbances. **Philosophical Transactions of the Royal Society B: Biological Sciences**, v. 362, n. 1478, p. 273-289, 2007.

CHAZDON, R. L. Regeneração de florestas tropicais. **Boletim do Museu Paraense Emílio Goeldi-Ciências Naturais**, v. 7, n. 3, p. 195-218, 2012.

CRUZ, C. B. M.*et al.* Classificação orientada a objetos no mapeamento dos remanescentes da cobertura vegetal do bioma Mata Atlântica, na escala 1: 250.000. **XIII Simpósio Brasileiro de Sensoriamento Remoto, INPE, Florianópolis, Brasil**, 2007.

CUNHA, N. R. S. *et al.* A intensidade da exploração agropecuária como indicador da degradação ambiental na região dos Cerrados, Brasil. **Revista de Economia e Sociologia Rural**, v. 46, p. 291-323, 2008.

DALLA CORTE, A. P. *et al.* **Aplicações do LiDAR para o inventário florestal – Enfoque unidade de área**. 1. ed. Ponta Grossa: Atena Editora, 2022. 118 p.

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.

DECEA. MINISTÉRIO DA DEFESA COMANDO DA AERONÁUTICA. n 415/DGCEA, de 9 de novembro de 2015. **ICA 100-40**, que trata dos “Sistemas de Aeronaves Remotamente Pilotadas e o Acesso ao Espaço Aéreo Brasileiro”. Publicado no BCA nº 212, de 19 de novembro de 2015.

DEVRIES, B. *et al.* Robust monitoring of small-scale forest disturbances in a tropical montane forest using Landsat time series. **Remote Sensing of Environment**, v. 161, p. 107-121, 2015.

DHAKAL, C. *et al.* Climate change adaptation and its impact on household farm income and revenue risk exposure. **Resources, Environment and Sustainability**, p. 1-51, 2022.

DIAS, P. B. **FLORÍSTICA E ESTRUTURA EM AMBIENTE DE BORDA-INTERIOR EM REMANESCENTE DE FLORESTA OMBRÓFILA DENSE DAS TERRAS BAIXAS**. 2019. 116 p. Dissertação (Mestrado em Ciências Florestais) - Universidade Federal do Espírito Santo, Jerônimo Monteiro, 2019.

DIETMAIER, A. *et al.* Comparison of LiDAR and digital aerial photogrammetry for characterizing canopy openings in the Boreal Forest of Northern Alberta. **Remote Sensing**, v. 11, n. 16, p. 1919, 2019.

DINIZ, F. S. **Métodos de amostragem e geoestatística aplicados ao inventário florestal**. 2007. 87 p. 2007. Tese de Doutorado. Dissertação (Mestrado em Ciência Florestal)-Universidade Federal de Lavras, Lavras.

DONG, P.; CHEN, Q. **LiDAR Remote Sensing and Applications**. Boca Raton, FL : Taylor & Francis, 2018.: CRC Press, 2018.

FONSECA, A. L. B. **Estimação de volume de madeira em povoamento de eucalipto utilizando dados de Laser Scanner Terrestre**. 2018. 115 p. Tese (Doutorado em Engenharia Civil) – Universidade Federal de Viçosa, Viçosa, 2018.

FRICK, E. C. L. Identificação de diferentes estágios sucessionais e idade da floresta: abordagens do sensoriamento remoto. **Periódico Eletrônico Fórum Ambiental da Alta Paulista**, v. 15, n. 2, 2019.

GANZ, S.; KÄBER, Y.; ADLER, P. Measuring tree height with remote sensing—A comparison of photogrammetric and LiDAR data with different field measurements. **Forests**, v. 10, n. 8, p. 694, 2019.

GEOSLAM. **GeoSLAM Hub: Transform 3D Data Into Actionable Information**. Disponível em: <<https://geoslam.com/hub/>>. Acesso em: 7 ago. 2022b.

GEOSLAM. **ZEB Horizon: The Ultimate Mobile Mapping Solution**. Disponível em: <<https://geoslam.com/solutions/zeb-horizon/>>. Acesso em: 7 ago. 2022a.

GIL, A. L. *et al.* A comparison between LiDAR and photogrammetry digital terrain models in a forest area on Tenerife Island. **Canadian Journal of Remote Sensing**, v. 39, n. 5, p. 396–409, 2013.

GIONGO, M. *et al.* LiDAR: princípios e aplicações florestais. **Pesquisa Florestal Brasileira**, v. 30, n. 63, p. 231–244, 28 out. 2010.

GOBAKKEN, T.; BOLLANDSÅS, O. M.; NÆSSET, E. Comparing biophysical forest characteristics estimated from photogrammetric matching of aerial images and airborne laser scanning data. **Scandinavian Journal of Forest Research**, v. 30, n. 1, p. 73–86, 2 jan. 2015.

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. 1, p. 71-81, 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. **Current Forestry Reports**, v. 5, n. 2, p. 55-75, 2019.

GORGENS, E. B.; SILVA, A. G. P. DA; RODRIGUES, L. C. E. **LiDAR: Aplicações florestais**. 1. ed. Curitiba: Editora CRV, 2014.

GRANSHAW, S. I. Photogrammetric Terminology: Third Edition. **The Photogrammetric Record**, v. 31, n. 154, p. 210–252, jun. 2016.

GUARIGUATA, M. R.; OSTERTAG, R. Neotropical secondary forest succession: changes in structural and functional characteristics. **Forest Ecology and Management**, v. 148, n. 1–3, p. 185–206, 2001.

GUEDES, I. C. DE L. **Uso de métodos da estatística espacial em biometria e inventário florestal**. 2014, 138 p. Tese (Doutorado) - Universidade Federal de Lavras, Lavras, 2014.

GUERRA-HERNÁNDEZ, J. *et al.* Use of Multi-Temporal UAV-Derived Imagery for Estimating Individual Tree Growth in Pinus pinea Stands. **Forests**, v. 8, n. 8, p. 300, 18 ago. 2017.

GYAWALI, A. *et al.* Comparison of Individual Tree Height Estimated from LiDAR and Digital Aerial Photogrammetry in Young Forests. **Sustainability 2022, Vol. 14, Page 3720**, v. 14, n. 7, p. 3720, 22 mar. 2022.

HIGUCHI, N. P.; DOS SANTOS, J.; JARDIM, F. C. S. Tamanho de parcela amostral para inventários florestais. **Acta amazônica**, v. 12, p. 91-103, 1982.

HORNING, N. Remote Sensing. **Encyclopedia of Ecology**, p. 2986–2994, 1 jan. 2008.

HULET, A. *et al.* Utilizing National Agriculture Imagery Program Data to Estimate Tree Cover and Biomass of Piñon and Juniper Woodlands. **Rangeland Ecology & Management**, v. 67, n. 5, p. 563–572, set. 2014.

HUNG, M. N. W. B. *et al.* Levantamento com veículo aéreo não tripulado para geração demodelo digital do terreno em bacia experimental com vegetação florestal esparsa. **RA'E GA - O Espaço Geografico em Analise**, v. 43, p. 215-231, 2018.

IBGE, I. B. DE G. E E. **BDIA - Banco de Dados de Informações Ambientais**. Disponível em: <<https://bdiaweb.ibge.gov.br/#/consulta/pedologia>>. Acesso em: 6 ago. 2022.

INCAPER. Programa de Assistência Técnica e Extensão Rural, PROATER 2020 - 2023, São Mateus. p. 1–55, 2020.

IQBAL, I. A. *et al.* A comparison of area-based forest attributes derived from airborne laser scanner, small-format and medium-format digital aerial photography. **International Journal of Applied Earth Observation and Geoinformation**, v. 76, p. 231–241, abr. 2019.

JAYATHUNGA, S.; OWARI, T.; TSUYUKI, S. The use of fixed-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, dez. 2018.

KACHAMBA, D. J. *et al.* Biomass Estimation Using 3D Data from Unmanned Aerial Vehicle Imagery in a Tropical Woodland. **Remote Sensing**, v. 8, n. 11, p. 968, 23 nov. 2016.

KANGAS, A. *et al.* Value of airborne laser scanning and digital aerial photogrammetry data in forest decision making. **Silva Fennica**, v. 52, n. 1, p. 19, 2018.

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

KRAUSE, S. *et al.* UAV-Based Photogrammetric Tree Height Measurement for Intensive Forest Monitoring. **Remote Sensing 2019, Vol. 11, Page 758**, v. 11, n. 7, p. 758, 2019.

KUKKONEN, M.; MALTAMO, M.; PACKALEN, P. Image matching as a data source for forest inventory – Comparison of Semi-Global Matching and Next-Generation Automatic Terrain Extraction algorithms in a typical managed boreal forest environment. **International Journal of Applied Earth Observation and Geoinformation**, v. 60, p. 11–21, ago. 2017.

LEBERL, F. *et al.* Point Clouds. **Photogrammetric Engineering & Remote Sensing**, v. 76, n. 10, p. 1123–1134, 1 out. 2010.

LIMA, N. DA S. **Amostras virtuais no monitoramento da produção florestal**. 2018. 67 p. Dissertação (Mestrado em Energia na Agricultura) – Universidade Estadual Paulista, Botucatu, 2018.

LORENZONI-PASCHOA, D. S. L. *et al.* Estágio sucessional de uma floresta estacional semidecidual secundária com distintos históricos de uso do solo no sul do Espírito Santo. **Rodriguésia**, v. 70, 2019.

LUMLEY, T. **Package “leaps”: regression subset selection**. Disponível em: <<https://cran.r-project.org/web/packages/leaps/leaps.pdf>>. Acesso em: 4 fev. 2022.

MAESANO, M. *et al.* Automated Inventory of Broadleaf Tree Plantations with UAS Imagery. **Remote Sensing**, v. 14, n. 8, p. 1931, 2022.

MENG, R. *et al.* Using high spatial resolution satellite imagery to map forest burn severity across spatial scales in a Pine Barrens ecosystem. **Remote Sensing of Environment**, v. 191, p. 95–109, 2017.

MLAMBO, R. *et al.* Structure from Motion (SfM) Photogrammetry with Drone Data: A Low Cost Method for Monitoring Greenhouse Gas Emissions from Forests in Developing Countries. **Forests**, v. 8, n. 3, p. 68, 3 mar. 2017.

MMA, M. DO M. A. **ENREDD+ National REDD+ Strategy**. Brasília: 2016. Disponível em: <<http://redd.mma.gov.br>>. Acesso em: 4 ago. 2022.

MOE, K. T. *et al.* Application of UAV Photogrammetry with LiDAR Data to Facilitate the Estimation of Tree Locations and DBH Values for High-Value Timber Species in Northern Japanese Mixed-Wood Forests. **Remote Sensing**, v. 12, n. 17, p. 2865, 2020.

MOREIRA, B.; CARVALHO, F. A. A comunidade arbórea de um fragmento urbano de Floresta Atlântica após 40 anos de sucessão secundária. **Biotemas**, v. 26, n. 2, p. 59–70, 2013.

MORIN, D. *et al.* Improving Heterogeneous Forest Height Maps by Integrating GEDI-Based Forest Height Information in a Multi-Sensor Mapping Process. **Remote Sensing**, v. 14, n. 9, p. 2079, 2022.

MUÑOZ-ROJAS, M. *et al.* Soil Mapping and Processes Models for Sustainable Land Management Applied to Modern Challenges. In: **Soil Mapping and Process Modeling for Sustainable Land Use Management**. Elsevier, 2017. p. 151–190.

MYERS, N. *et al.* Biodiversity hotspots for conservation priorities. **Nature**, v. 403, n. 6772, p. 853–858, fev. 2000.

NÆSSET, E. Determination of Mean Tree Height of Forest Stands by Digital Photogrammetry. **Scandinavian Journal of Forest Research**, v. 17, n. 5, p. 446–459, 5 jan. 2002.

NÄSI, R. *et al.* Using UAV-Based Photogrammetry and Hyperspectral Imaging for Mapping Bark Beetle Damage at Tree-Level. **Remote Sensing**, v. 7, n. 11, p. 15467–15493, 2015.

NAVARRO, A. *et al.* The application of Unmanned Aerial Vehicles (UAVs) to estimate above-ground biomass of mangrove ecosystems. **Remote Sensing of Environment**, v. 242, p. 111747, 1 jun. 2020.

NOGUEIRA, M. M. *et al.* Procedimentos simplificados em segurança e saúde do trabalho no manejo florestal. **Belém, PA: Instituto Floresta Tropical-Fundação Floresta Tropical**, 2010.

ONU. **Relatório Anual das Nações Unidas no Brasil 2021 - Portal ODS**. Disponível em: <<https://portalods.com.br/publicacoes/relatorio-anual-das-nacoes-unidas-no-brasil-2021/>>. Acesso em: 4 ago. 2022.

PANAGIOTIDIS, D. *et al.* Determining tree height and crown diameter from high-resolution UAV imagery. **International Journal of Remote Sensing**, v. 38, n. 8–10, p. 2392–2410, 19 maio 2017.

PELLICO NETTO, S.; BRENA, D. A. **Inventário Florestal**. 1. ed. Curitiba, 1997, 316 p.

PEREIRA, I. M. *et al.* Forest Structure and the Species Composition of the Parque Estadual Mata Atlântica, Located in Goiás State, Brazil. **International Journal of Ecology**, v. 2018, p. 1–9, 2018.

PEREIRA, I. S. **Desempenho de dispositivos eletrônicos para a análise estrutural da floresta de terra firme na amazônia central**. Manaus: INSTITUTO NACIONAL DE PESQUISAS DA AMAZÔNIA –INPA, 2018. 46 p. Dissertação (Mestrado em Ciências de Florestas Tropicais) – Instituto Nacional de Pesquisas da Amazônia, Manaus, 2018.

R CORE TEAM. **R: The R Project for Statistical Computing**. Disponível em: <<https://www.r-project.org/>>. Acesso em: 7 ago. 2022.

READ, J. M.; TORRADO, M. Remote Sensing. **International Encyclopedia of Human Geography**, p. 335–346, 1 jan. 2009.

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

REX, F. E.; KÄFER, P. S.; DALLA CORTE, A. P. VANTS: potenciais para a engenharia florestal. **Geociências, sociedades e sustentabilidade: uma coletânea de artigos**. p 101, 2020.

RIBEIRO, M. C. *et al.* The Brazilian Atlantic Forest: How much is left, and how is the remaining forest distributed? Implications for conservation. **Biological Conservation**, v. 142, n. 6, p. 1141–1153, 2009.

ROUSSEL, J. R. *et al.* lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. **Remote Sensing of Environment**, v. 251, p. 112061, 2020.

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.

SANTANA, Sidney Henrique Campelo de. **Análise da biomassa florestal de Pinus uncinata por meio de ferramentas de sensoriamento remoto passivo e ativo**. 2015. Dissertação de Mestrado. Universidade Federal de Pernambuco.

SCHNEIDER, P. R.; SCHNEIDER, P. S. P. Introdução ao manejo florestal (566 p.). **Editora UFSM**, 2008.

SEEA; AEFES; CREA-ES. **Tabela de serviços e honorários profissionais no campo da engenharia agrônômica para o estado do espírito santo**. Vitória, ES: 2012. Disponível em: <http://www.creaes.org.br/img/Tabela_honorarios_agronomia_web.pdf>. Acesso em: 17 maio. 2022.

SHAHBAZI, M.; THÉAU, J.; MÉNARD, P. Recent applications of unmanned aerial imagery in natural resource management. **GIScience & Remote Sensing**, v. 51, n. 4, p. 339–365, 2014.

SHIMIZU, K. et al. Integrating terrestrial laser scanning and unmanned aerial vehicle photogrammetry to estimate individual tree attributes in managed coniferous forests in Japan. **International Journal of Applied Earth Observation and Geoinformation**, v. 106, p. 102658, fev. 2022.

SILVA, L. et al. Supressão do bioma mata atlântica no município de paraíba do sul-rj, analisado sob a óptica ambiental e social, entre os anos 2002 a 2012. *In*: Simpósio de Gestão Ambiental e Biodiversidade, 6., 2017, Três Rios. **Anais [...]**. 2017.

SOARES, C. P. B.; NETO, F. DE P.; SOUZA, A. L. DE. **Dendrometria e Inventário Florestal**. 2ª ed. Viçosa, MG: **Editora UFRV**, 2010.

TABARELLI, M. et al. Desafios e oportunidades para a conservação da biodiversidade na Mata Atlântica brasileira. **Megadiversidade**, v. 1, n. 1, p. 132-138, jul, 2005.

TANG, L.; SHAO, G. Drone remote sensing for forestry research and practices. **Journal of Forestry Research**, v. 26, n. 4, p. 791-797, 2015.

TEIXEIRA, G. M. et al. **Análise De Classificadores De Estágios Sucessionais Em Um Fragmento De Mata Atlântica** **BIOFIX Scientific Journal**, v. 4, n. 2, p. 88-96, 2019.

TOMMASELLI, A. M. GARCIA. Fotogrametria básica. *In*: **Fotogrametria Básica**. Presidente Prudente: UNESP, 2009. p. 5–18.

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** **2016**, v. 7, n. 11, p. 255, 28 out. 2016.

TOMPALSKI, P. et al. Quantifying the contribution of spectral metrics derived from digital aerial photogrammetry to area-based models of forest inventory attributes. **Remote Sensing of Environment**, v. 234, p. 111434, dez. 2019.

UBIALLI, J. A. *et al.* Comparação de métodos e processos de amostragem para estimar a área basal para grupos de espécies em uma floresta ecotonal da região norte matogrossense. **Acta Amazonica**, v. 39, n. 2, p. 305–314, 2009.

ULLAH, S. *et al.* Potential of Modern Photogrammetry Versus Airborne Laser Scanning for Estimating Forest Variables in a Mountain Environment. **Remote Sensing**, v. 11, n. 6, p. 661, 19 mar. 2019.

US FOREST SERVICE. **FUSION/LDV: Software for LiDAR Data Analysis and Visualization**. 2022. Disponível em: <<http://forsys.cfr.washington.edu/fusion/fusionlatest.html>>. Acesso em: 8 ago. 2022.

VARGAS, R. M. DE A. **Avaliação dos dados laser scanner para determinar modelos de terreno em áreas cobertas por floresta ombrófila densa alterada na amazônia**. 2007. 178 p. Tese (Doutorado em Engenharia Civil). Universidade Federal de Santa Catarina. Florianópolis, 2007.

VASCONCELLOS, B. N. DE. **Estimativa de variáveis dendrométricas individuais de *Araucaria angustifolia* por meio de dados laser scanner aéreo e terrestre**. 2017. 185 p. Tese (Doutorado em Engenharia Florestal) Universidade Federal do Paraná. Curitiba, 2020.

VAUHKONEN, J. *et al.* Comparative testing of single-tree detection algorithms under different types of forest. **Forestry**, v. 85, n. 1, p. 27–40, jan. 2012.

WANG, M.; WONG, M. S.; ABBAS, S. Tropical Species Classification with Structural Traits Using Handheld Laser Scanning Data. **Remote Sensing**, v. 14, n. 8, p. 1948, 2022.

WANG, Y.; KOCH, B. A lidar point cloud based procedure for vertical canopy structure analysis and 3d single tree modelling in forest. **Sensors**, v. 8, p. 3938–3951, 2008.

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, 8 jun. 2012.

WESTERN DIGITAL CORPORATION. **Cartão microSDXC™ SanDisk Extreme® PRO UHS-I, Melhor Cartão Micro SD | Western Digital**. Disponível em: <<https://www.westerndigital.com/pt-br/products/memory-cards/sandisk-extreme-pro-uhs-i-microsd#SDSQXCD-128G-GN6MA>>. Acesso em: 7 ago. 2022.

WHITE, J. C. *et al.* A model development and application guide for generating an enhanced forest inventory using airborne laser scanning data and an area-based approach. 2017.

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, 2 set. 2016.

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. 02, n. 03, p. 69–85, set. 2014.

WHITMORE, G.; THOMPSON, M. Introduction to photogrammetry. **Manual of Photogrammetry, American Society for Photogrammetry**, p. 1–16, 1966.

WOLF, P. R.; DEWITT, B. A.; WILKINSON, B. E. **Elements of Photogrammetry with Applications in GIS**. McGraw-Hill Education, 2014.

YOSHII, T.; MATSUMURA, N.; LIN, C. Integrating UAV-SfM and Airborne Lidar Point Cloud Data to Plantation Forest Feature Extraction. **Remote Sensing**, v. 14, n. 7, p. 1713, 2022.

ZAHAWI, R. A. *et al.* Using lightweight unmanned aerial vehicles to monitor tropical forest recovery. **Biological Conservation**, v. 186, p. 287–295, jun. 2015.

ZHU, Q. Photogrammetry education for multidisciplinary geomatics in China. **Geospatial Information Science**, v. 9, n. 4, p. 273–280, jan. 2006.

APÊNDICE

Apêndice A – Componentes de custo de inventário florestal tradicional.

Componente	Sub-componente	Item	Quantidade	Unidade	Valor	Total
Equipamento	Equipamento	Estacas	1	Conjunto	R\$ 490,00	R\$ 490,00
Equipamento	Equipamento	Régua telescópica 15 m	1	Unidade	R\$ 500,00	R\$ 500,00
Equipamento	Equipamento	Clinômetro	1	Unidade	R\$ 1.899,00	R\$ 1.899,00
Equipamento	Equipamento	Trena + nylon + fita métrica	1	Kit	R\$ 186,55	R\$ 186,55
Equipamento	Equipamento	Epis	3	Kit	R\$ 300,00	R\$ 900,00
Equipamento	Equipamento	Computador Dell precision 3930 Rack + Monitor Dell 34" WQHD	1	Unidade	R\$ 35.722,23	R\$ 35.722,23
Equipamento	Software	Mata Nativa	1	Licença	R\$ 1.417,00	R\$ 1.417,00
Equipamento	Software	Pacote Office	1	Licença	R\$ 329,16	R\$ 329,16
Aquisição de dados	Aquisição de dados	Acesso à parcela	13	Hora/homem	R\$ 459,00	R\$ 5.967,00
Aquisição de dados	Aquisição de dados	Demarcação de parcela	59	Hora/homem	R\$ 459,00	R\$ 27.081,00
Aquisição de dados	Aquisição de dados	Coleta de dados	106	Hora/homem	R\$ 459,00	R\$ 48.654,00
Aquisição de dados	Aquisição de dados	Aluguel Carro	24	Diária	R\$ 224,00	R\$ 5.376,00
Aquisição de dados	Aquisição de dados	Hospedaem	24	Diária	R\$ 210,00	R\$ 5.040,00
Processamento e análise de dados	Processamento e análise de dados	Tabulação dos dados	8	Hora/homem	R\$ 153,00	R\$ 1.224,00
Processamento e análise de dados	Processamento e análise de dados	Processamento e análise dos dados	8	Hora/homem	R\$ 153,00	R\$ 1.224,00
Total		3,6 ha				R\$ 136.009,94
Custo por hectare	Equipamentos					R\$ 41.443,94
	aquisição e análise de dados por hectare	1 ha				R\$ 26.268,33

Fonte: O autor (2022).

Apêndice B - Componentes de custo de inventário com LiDAR terrestre.

Componente	Sub-componente	Item	Quantidade	Unidade	Valor	Total
Equipamento	Equipamento	Zeb horizon	1	Unidade	R\$ 367.700,00	R\$ 367.700,00
Equipamento	Equipamento	Aluguel RTK	160	R\$/ponto	R\$ 16,85	R\$ 2.696,00
Equipamento	Equipamento	Computador Dell precision 3930 Rack + Monitor Dell 34" WQHD	1	Unidade	R\$ 35.722,23	R\$ 35.722,23
Equipamento	Equipamento	Facão	3	Unidade	R\$ 24,64	R\$ 73,92
Equipamento	Equipamento	EPIs	3	Kit	R\$ 300,00	R\$ 900,00
Equipamento	Software	GeoSlam	1	Licença		R\$ -
Aquisição de dados	Aquisição de dados	Acesso à parcela	13	Hora/homem	R\$ 459,00	R\$ 5.967,00
Aquisição de dados	Aquisição de dados	Coleta de dados	10	Hora/homem	R\$ 459,00	R\$ 4.590,00
Aquisição de dados	Aquisição de dados	Coleta dos GCPs com RTK	86,4	Hora/homem	R\$ 459,00	R\$ 39.657,60
Aquisição de dados	Aquisição de dados	Aluguel Carro	15	Diária	R\$ 224,00	R\$ 3.360,00
Aquisição de dados	Aquisição de dados	Hospedagem	15	Diária	R\$ 210,00	R\$ 3.150,00
Processamento e análise de dados	Processamento e análise de dados	Processamento das Nuvens de pontos Georreferenciamento	6,6	Hora/homem	R\$ 153,00	R\$ 1.009,80
Processamento e análise de dados	Processamento e análise de dados	das nuvens de pontos	3,3	Hora/homem	R\$ 153,00	R\$ 504,90
Processamento e análise de dados	Processamento e análise de dados	Normalização das nuvens de pontos	3,3	Hora/homem	R\$ 153,00	R\$ 504,90
Processamento e análise de dados	Processamento e análise de dados	Extração das métricas	1,76	Hora/homem	R\$ 153,00	R\$ 269,28
Processamento e análise de dados	Processamento e análise de dados	Aplicação dos modelos	1,33	Hora/homem	R\$ 153,00	R\$ 203,49
Total		3,6 ha				R\$ 466.309,12
Custo por hectare	Equipamentos aquisição e análise de dados por hectare	1 ha				R\$ 407.092,15
						R\$ 16.449,16

Fonte: O autor (2022).

Apêndice C - Componentes de custo de inventário com FAD.

Componente	Sub-componente	Item	Quantidade	Unidade	Valor	Total
Equipamento	Equipamento	DJI Mavic 2 pro + kit fly more + cartão SD	1	Unidade	R\$ 21.999,00	R\$ 21.999,00
Equipamento	Equipamento	Aluguel RTK	40	R\$/ponto	R\$ 16,85	R\$ 674,00
Equipamento	Equipamento	Computador Dell precision 3930 Rack + Monitor Dell 34" WQHD	1	Unidade	R\$ 35.722,23	R\$ 35.722,23
Equipamento	Software	Agisoft	1	Licença	R\$ 28.500,00	R\$ 28.500,00
Aquisição de dados	Aquisição de dados	Planejamento de voo	1	Hora/homem	R\$ 153,00	R\$ 153,00
Aquisição de dados	Aquisição de dados	Coleta dos GCPs com RTK	21,62	Hora/homem	R\$ 459,00	R\$ 9.923,58
Aquisição de dados	Aquisição de dados	Voo	1,45	Hora/homem	R\$ 459,00	R\$ 665,55
Aquisição de dados	Aquisição de dados	Aluguel Carro	5	diária	R\$ 224,00	R\$ 1.120,00
Aquisição de dados	Aquisição de dados	Hospedagem	5	diária	R\$ 210,00	R\$ 1.050,00
Processamento e análise de dados	Processamento e análise de dados	Alinhamento de fotos	2	Hora/homem	R\$ 153,00	R\$ 306,00
Processamento e análise de dados	Processamento e análise de dados	Apontamento de GPCs	2	Hora/homem	R\$ 153,00	R\$ 306,00
Processamento e análise de dados	Processamento e análise de dados	Limpeza de Nuvem de Pontos	1,33	Hora/homem	R\$ 153,00	R\$ 203,49
Processamento e análise de dados	Processamento e análise de dados	Construção da nuvem densa	8,7	Hora/homem	R\$ 154,00	R\$ 1.339,80
Processamento e análise de dados	Processamento e análise de dados	Normalização das nuvens de pontos	8	Hora/homem	R\$ 153,00	R\$ 1.224,00
Processamento e análise de dados	Processamento e análise de dados	Extração das métricas	1,76	Hora/homem	R\$ 153,00	R\$ 269,28
Processamento e análise de dados	Processamento e análise de dados	Aplicação dos modelos	1,33	Hora/homem	R\$ 153,00	R\$ 203,49
Total		201 ha				R\$ 103.659,42
Custo por hectare	Equipamentos					R\$ 86.895,23
	aquisição e análise de dados por hectare	1 ha				R\$ 83,40

Fonte: O autor (2022).