

INSTITUTO NACIONAL DE PESQUISAS DA AMAZÔNIA – INPA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS DE
FLORESTAS TROPICAIS – PPG/CFT



QUALIDADE DOS PRODUTOS DE AEROFOTOGRAMETRIA POR DRONE
PARA UMA FLORESTA MADURA NA AMAZÔNIA CENTRAL

Jessé Burlamaque Maciel

MANAUS – AM
MAR/2022

JESSÉ BURLAMAQUE MACIEL

**QUALIDADE DOS PRODUTOS DE AEROFOTOGRAMETRIA POR DRONE
PARA UMA FLORESTA MADURA NA AMAZÔNIA CENTRAL**

Orientador: Dr. Niro Higuchi

Membros da Banca Avaliadora: Dr. Bruce Walker Nelson (INPA), Dr. Rogério Ribeiro Marinho (UFAM) e Dr. Adriano José Nogueira Lima (INPA)

Dissertação apresentada ao Instituto Nacional de Pesquisas da Amazônia - INPA, como parte dos requisitos para obtenção do título de Mestre em Ciências de Florestas Tropicais.

MANAUS – AM

MAR/2022

M152p Maciel, Jessé Burlamaque

Qualidade dos Produtos de Aerofotogrametria por Drone para uma Floresta Madura na Amazônia Central. / Jessé Burlamaque Maciel; orientador Niro Higuchi; - Manaus:[s. l.], 2022.

1.9 MB

52 p. : il. color.

Dissertação (Mestrado - Programa de Pós Graduação em Ciências De Florestas Tropicais.) - Coordenação do Programa de Pós-Graduação, INPA, 2022.

1. Aerofotogrametria. 2. Floresta Amazônica. I. Higuchi, Niro. II.
Título

CDD 577.3

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS DE FLORESTAS TROPICAIS

**ATA DE DEFESA PÚBLICA DE DISSERTAÇÃO
MESTRADO**

Ata da Defesa Remota de **Jessé Burlamaque Maciel**, ocorrido no dia 29/03/2022, via Plataforma de Videoconferência Zoom.

Aos vinte e nove dias de março do ano de 2022, às 9h (horário de Manaus/AM), realizou-se a Defesa Pública de Dissertação de **JESSÉ BURLAMAQUE MACIEL**, aluno do Programa de Pós-Graduação *Stricto sensu* em Ciências de Florestas Tropicais, intitulada “**Qualidade dos produtos de aerofotogrametria e suas relações com dados de campo para uma floresta madura na Amazônia Central**”, sob a orientação do Prof. Dr. Niro Higuchi (INPA), em conformidade com o Art. 52 do Regimento Geral da Pós-Graduação do Instituto Nacional de Pesquisas da Amazônia (MCTI/INPA) e Art. 67 do Regimento Interno do Programa de Pós-Graduação em Ciências de Florestas Tropicais, como parte das atividades para conclusão e obtenção do Título de Mestre em Ciências de Florestas Tropicais. A **Banca Examinadora** foi constituída pelos seguintes membros titulares: Bruce Walker Nelson (INPA), Rogério Ribeiro Marinho (UFAM) e Adriano José Nogueira Lima (INPA). O Presidente da Banca Examinadora deu início à Seção e informou os procedimentos do exame. O aluno fez uma exposição do seu estudo, e ao término foi arguido oralmente pelos membros da comissão. Após as arguições, os membros da banca se reuniram para avaliação e chegaram ao seguinte parecer:

Nome	Parecer		Assinaturas
Bruce Walker Nelson	<input checked="" type="checkbox"/> Aprovou	<input type="checkbox"/> Reprovou	
Rogério Ribeiro Marinho	<input checked="" type="checkbox"/> Aprovou	<input type="checkbox"/> Reprovou	
Adriano José Nogueira Lima	<input checked="" type="checkbox"/> Aprovou	<input type="checkbox"/> Reprovou	
Menção:	<input type="checkbox"/> “Com Distinção”	<input type="checkbox"/> “Com Louvor”	<input type="checkbox"/> “Com Distinção e Louvor”

Nada mais havendo a tratar, foi lavrada a presente Ata que, após lida e aprovada, foi assinada pela Coordenação:



Niro Higuchi
Presidente da Banca / Orientador



Adriano José Nogueira Lima
Coordenador do PPG-CFT/INPA
PO. N° 163/2021

AGRADECIMENTOS

Agradeço primeiramente a Deus pela bênção e força concedida durante toda a minha jornada.

Agradeço o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES).

Agradeço ao Instituto Nacional de Pesquisas da Amazônia (INPA) pela oportunidade de realizar este mestrado.

Agradeço o apoio logístico e técnico-científico da equipe do Laboratório de Manejo Florestal do Instituto Nacional de Pesquisas da Amazônia (LMF/INPA) e toda a sua equipe. Especialmente Dr Niro Higuchi, Dr Adriano Lima, Dr Daniel Marra, Dr Moacir e Lidiane Lima.

Agradeço também a equipe da Hdom® Consultoria Ambiental (Hdom) na pessoa do Dr Francisco Higuchi, Dr Mateus Bonnadiman e Klícia Figueiredo que sempre apoiaram e incentivaram o ensino acadêmico e o desenvolvimento deste estudo.

Agradeço ainda a minha esposa Pamela Iwabuchi, aos meus pais Obede e Franciclei Maciel. e a minha irmã Jéssica Maciel que me apoiaram revisando, contribuindo e principalmente incentivando.

Agradeço também aos amigos do LMF/INPA que contribuíram para o desenvolvimento do estudo, ao Carlos Enrique Celes e Raquel Araújo com a idealização projeto, a Adriana Simonetti, a Kelly Moreira, o Jarlison Coelho, o Gustavo Spanner e o Márcio Amaral.

Enfim, a todos que contribuíram para a realização deste trabalho.

RESUMO

Imagens de Aeronaves Remotamente Pilotadas (ARP) vem sendo amplamente utilizada no setor florestal e no meio acadêmico, no entanto, ainda há questões relacionadas a precisão, qualidade e potenciais aplicações das informações adquiridas. O monitoramento da floresta da perspectiva aérea por sensoriamento remoto aerofotogramétrico, é uma das formas de analisar espacialmente a estrutura e os efeitos de distúrbios na dinâmica da floresta, com possibilidade de potencializar os resultados quando relacionados com dados de campo do inventário florestal (IF). Vários autores constataram que para alcançar a qualidade desses produtos é preciso rigor na aquisição, especialmente porque estamos produzindo modelos matemáticos de uma superfície rugosa, irregular e extremamente dinâmica por meio de algoritmos de visão computacional, como o *Structure from Motion* (SfM). Além disso, não há um consenso sobre protocolos de aquisição e parametrização para perguntas específicas relacionadas aos tipos de floresta e condições ambientais. O objetivo deste projeto é avaliar a qualidade geométrica e radiométrica dos produtos de aerofotogrametria com base nas métricas extraídas da estrutura da floresta, obtidos por diferentes métodos de aquisição com ARP. Aqui os resultados sugerem que diferentes combinações altitude, sobreposição e iluminação podem influenciar na qualidade de produtos de ARP. Na maioria dos métodos não houve grandes diferenças em relação à área e perímetro médio da copa. No entanto, a qualidade pode ser alcançada combinando iluminação por luz difusa (céu nublado), alta sobreposição e proximidade ao alvo.

Palavras-chave: aeronaves remotamente pilotadas, structure from motion, estrutura florestal, qualidade, luz difusa.

ABSTRACT

Images from Remotely Piloted Aircraft (RPA) have been widely used in the forestry sector and in academia, however, there are still issues related to accuracy, quality and potential applications of the information acquired. Monitoring the forest from an aerial perspective by aerophotogrammetric remote sensing is one way to spatially analyze the structure and the effects of disturbances on forest dynamics, with the possibility of enhancing the results when related to field data from the forest inventory (FI). Several authors have found that to achieve the quality of these products requires rigor in the acquisition, especially because we are producing mathematical models of a rough, irregular and extremely dynamic surface by means of computer vision algorithms, such as Structure from Motion (SfM). Furthermore, there is no consensus on acquisition protocols and parameterization for specific questions related to forest types and environmental conditions. The goal of this project is to evaluate the geometric and radiometric quality of aerophotogrammetry products based on metrics extracted from the forest structure, obtained by different acquisition methods with ARP. Here the results suggest that different combinations altitude, overlap and illumination can influence the quality of PRA products. For most methods there were no major differences in mean canopy area and perimeter. However, quality can be achieved by combining diffuse light illumination (cloudy sky), high overlap, and proximity to the target.

Keywords: remotely piloted aircraft, structure from motion, forest structure, quality, stray light.

SUMÁRIO

RESUMO.....	4
SUMÁRIO.....	5
1. INTRODUÇÃO.....	6
2. OBJETIVOS.....	8
3. REVISÃO BIBLIOGRÁFICA	9
3.1. A floresta tropical amazônica.....	9
3.2. Manejo Florestal	9
3.2.1. Inventário Florestal	10
3.2.2. Monitoramento florestal.....	11
3.3. Sensoriamento Remoto	13
3.3.1. Comportamento Espectral do Dossel.....	15
3.3.2. Aeronaves Remotamente Pilotadas (ARP).....	16
3.3.3. Aerofotogrametria <i>Structure from Motion</i>	17
3.3.4. ARP-SfM em inventários florestais.....	22
4. MATERIAL E MÉTODOS	26
4.1. Área de Estudo	26
4.2. Coleta de Dados	27
4.2.1. Dados de campo.....	27
4.2.2. Dados remotos	28
4.4. Análises.....	31
4.4.1. Processamento dos dados.....	31
4.4.2. Análise estatística.....	32
5. RESULTADOS	34
6. CONCLUSÃO	43
7. APÊNDICE	45
8. REFERÊNCIAS BIBLIOGRÁFICAS	46

1. INTRODUÇÃO

O inventário florestal (IF) é o principal gerador de dados quantitativos e qualitativos sobre as florestas. Porém, na Amazônia frequentemente é um trabalho extensivo, oneroso (Péllico Netto e Brena, 1997; Lima, 2010) e em muitos casos, limitado em extensão espacial e temporal (Lloyd *et al.*, 2009). Em florestas densas, como as tropicais o levantamento de informações de alta qualidade é fundamental para aperfeiçoar o mapeamento e monitoramento da biomassa, o que contribui para maior eficácia nas decisões de gestão e conservação (Running, 2009; Chambers *et al.*, 2009a; Negrón-Juárez *et al.* 2011; Réjou-Méchain *et al.* 2019).

O sensoriamento remoto (SR) de alta resolução espacial tem sido implementado para fornecer dados complementares ao IF, notadamente no contexto do monitoramento do recurso florestal. Sobretudo pela possibilidade de monitorar a floresta da perspectiva aérea para quantificar padrões espaciais, magnitude e severidade de distúrbios; auxiliar nas estimativas da estrutura e aferir sobre a qualidade (Philips *et al.*, 2008; Houghton *et al.* 2009, Marra *et al.* 2014, Espírito-Santo *et al.*, 2014; McMahon *et al.*, 2018; Chambers *et al.* 2007; Stark *et al.* 2015; Buma e Barret, 2015). O SR pode auxiliar a quantificar os efeitos de distúrbios na dinâmica da comunidade florestal, potencializando os resultados com dados obtidos em campo, como composição florística e estimativas de estoque (Hopkinson *et al.*, 2016; Stark, 2012; Valbuena *et al.*, 2017, McMahon *et al.*, 2018, Vidal *et al.* 2008).

O uso de imagens de Aeronaves Remotamente Pilotadas (ARP) ganhou notoriedade nos setores científicos e de serviços para mapeamento em escala espacial detalhada (White *et al.*, 2016; Iglhaut *et al.*, 2019). Contudo, questões relacionadas à precisão, qualidade e potenciais aplicações das informações adquiridas demandam respostas. A fotogrametria baseada em *Structure from Motion* (SfM) com ARP é um método eficiente na aquisição de dados da estrutura do dossel e de baixo custo, porém, enfrenta desafios técnicos e logísticos na região Amazônica (Lawley *et al.*, 2016; Tang e Shao, 2015; Bourgoïn *et al.*, 2018; Aguilar *et al.*, 2019). Mais ainda, não existe um consenso sobre protocolos de

aquisição e parametrização para perguntas específicas relacionadas aos tipos de floresta e condições ambientais (Iglhaut *et al.*, 2019).

Vários autores constataram que para alcançar a qualidade desses dados é preciso rigor na aquisição, especialmente por se tratar da produção de modelos matemáticos de uma superfície rugosa, irregular e extremamente dinâmica (Dandois & Ellis, 2013; White *et al.*, 2016; Iglhaut *et al.*, 2019). Portanto, as florestas são desafiadoras para os algoritmos de correspondência SfM. Desse modo, fatores como altitude, sobreposição e intensidade da incidência de luz podem determinar a qualidade da imagem produzida, com efeitos sobre os resultados de estudos que adotem tais dados.

A distância da ARP para a floresta por exemplo, está diretamente relacionada com a altitude, com efeitos sobre a sobreposição. Em muitos casos o planejamento do voo é feito em função apenas da distância ao solo, subestimando a sobreposição. Por outro lado, a altitude também será primordial na definição da escala e detalhamento dos objetos de interesse. Além disso, a intensidade da incidência de luz, quando não considerada no planejamento e em conjunto com esses fatores pode alterar a geometria dos objetos, o que resulta no aumento de oclusões e erros sistemáticos. Portanto, para os estudos que visam obter medidas da estrutura da floresta para combiná-las com dados de campo é necessário que os níveis de incerteza sejam baixos e conhecidos.

Atualmente, há poucas informações sobre a influência desses fatores na qualidade da imagem produzida (Iglhaut *et al.* 2019). Este estudo sistematiza a fundamentação técnica e metodológica para a obtenção de informações precisas e quantificáveis da estrutura do dossel por ARPs. Norteado pelo seguinte ponto: Diferentes intensidades de iluminação, sobreposição e altitudes de voo podem causar diferenças nas métricas da estrutura do dossel da floresta. Com estes resultados foi possível estimar variáveis do dossel da floresta com maior confiabilidade e correlacioná-las com informações de campo.

Para suprir essa lacuna, foi verificado os fatores de maior influência na qualidade dos produtos gerados por aerofotogrametria com ARP, a altitude de voo, a sobreposição entre as imagens e a condição de iluminação na hora da aquisição das imagens.

2. OBJETIVOS

Geral:

Analisar a qualidade e a precisão dos produtos de aerofotogrametria adquiridos por diferentes métodos de aquisição.

Específicos:

- i) Analisar o erro do posicionamento dos objetos imageados com diferentes métodos de georreferenciamento para os produtos de ARP;
- ii) Comparar a geometria dos objetos imageados em diferentes configurações de sobreposição, altitude e intensidade de incidência de luz;

3. REVISÃO BIBLIOGRÁFICA

Foi realizado uma revisão da literatura sobre aspectos conceituais envolvidos na temática do estudo, como: A floresta tropical Amazônica, Manejo florestal, Inventário Florestal, Monitoramento da floresta, aspectos conceituais do Sensoriamento Remoto, Comportamento espectral do dossel, Aeronaves Remotamente Pilotadas e aspectos matemáticos envolvidos no processamento dos dados e por fim uma revisão do estado da arte do uso de Aeronaves Remotamente Pilotadas como fornecedores de dados de estrutura.

3.1. A floresta tropical amazônica

As florestas de terra firme predominam na floresta amazônica, ocupam cerca de 5.473.000 km² na América do Sul (3.483.000 km² no Brasil) (Furley, 2007) e cobrem relevos ondulados. O termo 'terra-firme' se aplica para todas as florestas que não são sazonalmente inundadas. Estas podem ser divididas em: florestas densas, florestas densas com lianas, florestas abertas com bambus, florestas de encosta, campina alta ou campinarana e florestas secas (Braga, 1979).

A maioria das florestas de terra firme apresenta quatro estratos verticais. O estrato superior, localizado entre 20 e 40 m, possui uma copa densa e contínua, da qual emergem algumas árvores que chegam a 60 m. Abaixo, entre 5 e 20 m, há um estrato arbóreo e depois um estrato de arbusto, com indivíduos entre 2 e 5 m. E finalmente, há um estrato herbáceo com plantas e ervas jovens, com indivíduos menores que 2 m (Rizzini, 1997).

3.2. Manejo Florestal

O manejo florestal na Amazônia e em florestas tropicais surgiram como adaptações dos padrões de sistemas silviculturais utilizados no manejo de outros tipos de florestas, baseados em duas categorias: i) monocíclicos e ii) policíclicos. No caso da Amazônia, o sistema policíclico é comumente adotado, onde apenas os indivíduos que atingiram o diâmetro mínimo determinado para corte são

explorados, permanecendo, portanto, os demais indivíduos como estoque para corte futuro. Diante disso, técnicas de manejo adequadas que auxiliem a gestão e conservação devem ser aplicadas para utilização eficaz desse recurso. O monitoramento do crescimento da floresta restante será primordial para futuras retiradas.

Portanto, a finalidade do manejo florestal é permitir que as florestas forneçam continuamente benefícios econômicos, ecológicos e sociais seguindo um planejamento para o aproveitamento dos recursos disponíveis, contudo respeitando os mecanismos de sustentação do ecossistema, sem comprometer a sua estrutura natural e o seu capital inicial (Higuchi, 1994; IBAMA, 2002; Gama *et al.* 2005). O manejo florestal pode ser considerado a forma mais adequada de utilização dos recursos da floresta, especialmente por estar voltado para a conservação, buscando minimizar os distúrbios, como também por atender às necessidades de desenvolvimento social e econômico (Costa, 2000).

3.2.1. Inventário Florestal

No contexto do manejo, o inventário florestal (IF) é o principal gerador de dados quantitativos e qualitativos das florestas. Segue uma abordagem multitemporal por meio de inventários contínuos e podem fornecer informações de composição, estrutura, estoque e dinâmica florestal. Os dados devem ser confiáveis, visto que os inventários consideram uma amostra da estrutura florestal para estimar informações em grande escala do estado da floresta (Cummings *et al.* 2002; Vidal *et al.* 2008; Rodig *et al.* 2017).

O IF fornece informações que caracterizam a floresta, com possibilidade de adotar diferentes abordagens para uma diversidade de objetivos. Entre eles o planejamento estratégico e operacional, cobertura florestal, fitofisionomia, biomassa, volume crescente de estoque, balanço de carbono, potencial madeireiro, entre outros relacionados ao indivíduo arbóreo e a comunidade (White *et al.* 2015; Brown *et al.* 1989; Kangas & Maltamo, 2006). Assim, a informação produzida é o princípio para a tomada de decisões, seja para gestão ou para conservação do recurso florestal.

Nesse sentido, a coleta de dados em campo para o inventário florestal é trabalhosa, demorada e de custo elevado na Amazônia. Geralmente as populações florestais são extensas, de difícil acesso e na maioria das vezes precisam ser inventariadas em curto espaço de tempo (Péllico Netto e Brena, 1997; Lima, 2010). Tais características são influenciadas também pela diversidade de espécies, variação topográfica e estruturas verticais complexas (Liebermann *et al.* 2018).

Embora o IF esteja estabelecido, técnicas de sensoriamento remoto de alta resolução espacial tem sido empregadas como fornecedoras de dados complementares, possibilitando a melhora em qualidade e em quantidade de informações produzidas (Puliti *et al.*, 2015; Espírito-Santo *et al.*, 2014). A partir dos dados remotos representados por imagens, diversos mapas e análises espaciais podem ser desenvolvidas, com possibilidade de entender a distribuição espacial de árvores, de distúrbios observáveis no dossel e de características gerais da paisagem de uma perspectiva aérea (Liebermann *et al.* 2018). No contexto do manejo florestal, o IF necessita ser especializado, portanto, pode ser compreendido como uma forma de mapeamento, quando incorporado a variável geográfica, embora ainda existam desafios relacionados a precisão, consistência das informações e erros não quantificados.

3.2.2. Monitoramento florestal

O monitoramento florestal permite inferir sobre a dinâmica das florestas, recrutamento, mortalidade e crescimento. Tais processos estão relacionados com o tempo de residência do carbono e da dinâmica da comunidade (Chambers *et al.* 2000; McMahon *et al.*, 2018), evidenciado na composição, diversidade das espécies (Chambers *et al.*, 2009a; Laurance & Carrant, 2008), proliferação de espécies sucessivas (Laurance *et al.*, 1998) e acumulação de liteira (Sizer *et al.*, 2000). O monitoramento permite por exemplo, a identificação de distúrbios, que possibilita inferir sobre esses processos apresentados, uma vez que podem criar aberturas no dossel quando uma ou mais árvores morrem. E em seguida a remodelagem da estrutura da floresta com preenchimento com indivíduos mais novos (Whitmore, 1989, Chambers *et al.*, 2009a).

Compreender a extensão e dinâmica destes distúrbios com o IF associado ao SR pode auxiliar estudos relacionados ao papel da floresta na biosfera, especialmente na relação do carbono emitido para a atmosfera (Houghton, 2009; IPCC, 2014). Estima-se que as florestas da Amazônia armazenem entre 86 e 96 Pg de carbono na biomassa acima do solo (Malhi *et al.*, 2006; Saatchi *et al.*, 2007). Assim, a mortalidade de árvores nessa região pode exercer grande influência na concentração de CO₂ na atmosfera (Phillips *et al.*, 2009; Espírito-Santo *et al.*, 2014; IPCC, 2014).

Diversos estudos adotam dados de campo para estudar os mecanismos de morte de árvores e seus efeitos na comunidade, ainda assim podem ser limitados sazonalmente ou em extensão espacial, visto que a formação de clareiras é bastante imprevisível (Hubbell *et al.*, 1999, Lloyd *et al.*, 2009). Trabalhos como de Fontes *et al.* (2018) mostram o poder de observações finas na escala temporal no monitoramento da mortalidade, utilizando dados de campo em um transecto de 10 ha de floresta. Enquanto que estudos como o de Espírito-Santo *et al.* (2014) mostram o poder da combinação de inventário florestal com dados de SR para monitorar distúrbios de 0,01 ha à 2.651 ha em toda a Amazônia, com resultados que indicam que eventos de mortalidade em pequena escala respondem pelas maiores perdas de biomassa acima do solo ($\sim 1,28 \text{ Pg C y}^{-1}$), se comparado a mortalidade causada por distúrbios de escala intermediária e grande escala ($\sim 0,01 \text{ Pg C y}^{-1}$ e $\sim 0,003 \text{ Pg C y}^{-1}$).

Nesse contexto, estudos que adotam dados de campo e remotos se destacam, uma vez que são mais eficientes em monitorar a floresta em escala espacial e temporal, se comparado com cada método isolado. A combinação de dados espectrais de sensores remotos orbitais gratuitos com dados de mortalidade medidos em campo pode por exemplo, otimizar o monitoramento de distúrbios em nível de sub-pixel com aproximadamente 100 m² (Negrón-Juárez *et al.* 2011). Ainda nessa linha, estudos como de Getzin *et al.* 2014 utilizando ARP em floresta não manejada obtiveram detalhamento ainda maior de aberturas no dossel, identificando o domínio de aberturas menores que 5 m², apresentando padrões espaciais contrastantes.

Portanto, o monitoramento de aberturas no dossel pode contribuir para melhorar as estimativas regionais do *turnover* da floresta e complementar

estudos de composição florística e suas relações, principalmente a dinâmica e tempo de residência do carbono na floresta (Negrón-Juárez *et al.* 2011; Running, 2009; Chambers *et al.*, 2009a). Deste modo, métodos que ofereçam maior detalhamento no mapeamento e monitoramento dos atributos da floresta vão possibilitar o aumento em qualidade dos estudos de dinâmica e estimativas a partir do dossel, com efeitos sobre as decisões relacionadas a gestão e conservação do recurso florestal.

3.3. Sensoriamento Remoto

O Sensoriamento Remoto (SR) é a tecnologia que permite obter imagens e outros tipos de dados da superfície terrestre por meio da captação e registro da energia eletromagnética refletida ou emitida pela superfície dos objetos. A energia refletida ou emitida pela superfície é captada, transformada em sinais elétricos e convertida em dados na forma de gráficos, tabelas e imagens (Florenzano, 2011). Após serem interpretados, é possível obter informações sobre alvos específicos na superfície. Os produtos do sensoriamento remoto variam de acordo com a configuração do sistema (plataforma + sensor), portanto uma das características relevantes é a resolução espacial, ou seja, a capacidade que o sensor tem de discriminar objetos em função do tamanho destes.

Nesse sentido, as imagens óticas podem ser classificadas em diferentes resoluções espaciais, conseqüentemente na quantidade de informações que poderão ser extraídas (Tabela 1).

Tabela 1. Resolução Espacial de dados óticos.

Intervalo de resolução espacial	Nomenclatura	Sistemas sensores
<1m	<u>Resolução Espacial Muito Alta (VHSR)</u>	QuickBird, Planet, WorldView, Pleiades, ARP
1 m – 10 m	Alta resolução espacial (HSR)	IKONOS, SPOT, Rapid Eye
10 m - 100 m	Média resolução espacial (MSR)	Landsat, Sentinel, ASTER
100 m - 1000 m	Baixa resolução espacial (LSR)	MODIS, MERIS
> 1.000 m	Resolução espacial muito baixa (VLSR)	AVHRR, VAI

Fonte: Adaptado de White *et al.* 2016.

Entre as diversas resoluções, as que apresentam maior potencial para aquisição de informações do recurso florestal com alta precisão para gestão e conservação são as imagens HSR e VHRS, especialmente a última. Townshend (1980) avalia a resolução espacial a partir de critérios baseados nas propriedades geométricas do sistema de imageamento, como a habilidade para mensurar a periodicidade de alvos que se repetem e a habilidade para mensurar as propriedades espectrais de pequenos alvos. Na classificação de Strahler *et al.* (1989), a interpretação da imagem passa pela capacidade de discernir objetos de interesse: i) muitos pixels por objeto (identificação simplificada) ou ii) muitos objetos por pixel (características individuais perdidas). Portanto, quanto maior o detalhamento dos objetos de interesse mais informações poderão ser obtidas, porém o maior detalhamento pode também dificultar extraordinariamente a análise devido ao grande volume de dados a ser processado.

O uso de imagens de alta resolução em estudos da vegetação vem de longa data, especialmente a partir do lançamento do primeiro satélite comercial VHRS, o IKONOS em 1999 com resolução de 1 metro (White *et al.* 2016). Estudos como de Palace *et al.* (2007) utilizaram algoritmos em imagens IKONOS para estimar as dimensões das copas e outras propriedades estruturais da floresta, porém muitos erros estavam associados, como a incapacidade de detectar copas no sub-bosque e separar copas adjacentes ou entrelaçadas. Diversos trabalhos também foram realizados com dados Landsat e sensores de resolução similar, no entanto, a extração das propriedades estruturais das florestas tropicais foi um desafio ainda maior, visto que a resolução dessas imagens é comparável ao tamanho da copa das maiores árvores (Moran *et al.* 1994; Steininger, 1996).

Além dos diversos desafios apresentados, as imagens obtidas pelo sensoriamento remoto orbital também podem ser limitadas por outros fatores como efeitos da atmosfera, névoa, imagens em diferentes épocas do ano, efeito da topografia e do georreferenciamento das imagens (Negrón-Juárez *et al.* 2011; Florenzano, 2011). Nesse cenário, dois métodos de SR de baixa altitude se destacaram: (i) O ALS/LIDAR (*Airborne Laser Scanning / Light Detection And Ranging*) – scanners a laser aerotransportados e (ii) ARP-SfM – com uso de algoritmos de visão computacional e imagens capturadas por sensores RGB

aerotransportados. Ambos utilizados para criar nuvens de pontos 3D e derivar modelos digitais da superfície, mas com custos e capacitação técnica diferenciadas.

O ALS/LIDAR provou ser bastante eficiente, permitindo caracterização tridimensional precisa da estrutura vertical da floresta, produzindo modelos digitais altamente detalhados, bem como a estimativa de uma variedade de atributos tradicionalmente obtidos por inventário florestal (incluindo altura, volume e biomassa). Enquanto os produtos de ARP, também podem fornecer caracterização da estrutura de forma comparável, no entanto, os custos e extensão espacial alcançados são diferenciados, por outro lado, são melhor compreendidas pelos especialistas em IF (White *et al.*, 2013; White *et al.*, 2016).

3.3.1. Comportamento Espectral do Dossel

A aplicação das técnicas de SR no estudo da vegetação passa pelo entendimento da interação entre a radiação eletromagnética (REM) e a vegetação. A fotossíntese, processo intrínseco aos vegetais ajuda a compreender essa interação, visto que durante esse processo a folha absorve radiação eletromagnética por parte dos pigmentos fotossintetizantes como as clorofilas (65%), xantofilas (29%) e carotenos (6%) para transformação em elementos químicos vitais. Essa absorção ocorre principalmente na região do visível, que compreende o intervalo 0,4 μm a 0,72 μm do espectro eletromagnético (Ponzoni *et al.* 2012).

Quando tratamos da reflectância dos dosséis, precisamos considerar os tipos fisionômicos de dosséis, que devem orientar a aquisição e interpretação dos dados. O estudo do comportamento espectral do dossel passa, portanto, pelo fator de reflectância bidirecional para uma dada condição geométrica de iluminação (posição do sol) e de visada (posição do sensor). Esse fator refere-se à quantidade relativa de REM refletida por uma dada superfície, nesse caso influenciado pela fisionomia do dossel da floresta. (Ponzoni *et al.* 2012)

Nesse contexto, o fluxo solar incidente dentro do dossel em direção ao solo e o movimento consequente de reflexão em direção ao sensor não dependem somente dessas propriedades de espalhamento e de absorção dos

elementos da vegetação descritos. Dependem também das densidades e orientações da estrutura do dossel, ou seja, da arquitetura desse dossel (Ponzoni *et al.* 2012). Deste modo, esses elementos podem orientar a avaliação das propriedades de reflexão desse alvo, com efeitos sobre as características radiométricas e texturais da imagem produzida dessa superfície.

Conforme revisado por Leitão *et al.* 2002, o agrupamento do dossel, favorece picos e depressões nas superfícies dos dosséis, assim grande quantidade de radiação solar incidente penetra antes de ser refletida (Shuttleworth *et al.*, 1984). Para Eck & Deering (1992) isso pode resultar numa acentuada captura de radiação solar e, conseqüentemente, numa baixa reflexão. Nesse cenário, menos de 10% da radiação solar incidente atinge o piso da floresta (Pereira, 1997). Durante o dia, o coeficiente de reflexão (albedo), ou seja, a refletividade difusa decresce com a elevação do sol alcançando, em geral, valores máximos próximo ao nascer e pôr-do-sol, enquanto os valores mínimos são observados em torno do meio-dia (Rijks, 1967; Stewart, 1971; Viswanadham, 1972; Pinker, 1982; Leitão, 1989; Gash & Shuttleworth, 1991). Eck & Deering (1992) concluíram que o albedo menor para ângulos de elevação solar maiores se deve a maior penetração de radiação no dossel vegetativo, resultando no aumento da absorção e espalhamento da radiação. Quando o ângulo de elevação solar é pequeno, a radiação incidente não penetra no interior do dossel, ocorrendo redução da absorção por espalhamento múltiplo, o que concorre para uma reflexão maior da superfície e, em consequência, para um albedo maior.

3.3.2. Aeronaves Remotamente Pilotadas (ARP)

No Brasil, a Agência Nacional de Aviação Civil (ANAC) define, no Regulamento Brasileiro da Aviação Civil Especial (RBAC-E nº 94), as diretrizes e requisitos gerais para veículos aéreos não tripulados e aeromodelos, em que “[...] (1) *Aeromodelo significa toda aeronave não tripulada com finalidade de recreação;* (2) *Aeronave Remotamente Pilotada (Remotely-Piloted Aircraft – RPA), destinado à operação remotamente pilotada*”, (RBAC-E Nº 94, 2017). Do

mesmo modo, no contexto deste estudo adotaremos o termo Aeronave Remotamente Pilotada (ARP).

O uso de ARP para sensoriamento remoto aumentou rapidamente nos últimos anos, influenciado principalmente pela facilidade com que essa tecnologia pode ser implementada e com baixos custos em pesquisas e no setor privado. Com o passar dos anos as ARPs ganharam maturidade técnica, de modo que, quando equipadas com câmeras digitais ou outros sensores, permitem um sensoriamento remoto rápido e sob demanda em alta resolução espacial e temporal (Anderson & Gaston, 2013; Turner, Lucieer & Watson, 2012; Getzin, Wiegand & Schoning, 2012). O método por trás do desenvolvimento do sensoriamento remoto com ARP é a aerofotogrametria associada com algoritmos *Structure from Motion* (SfM), um método não seletivo, não dependente de grande rigor na aquisição por parte do usuário, como no caso da aerofotogrametria tradicional (White *et al.* 2016).

3.3.3. Aerofotogrametria *Structure from Motion*

A aerofotogrametria com algoritmos *Structure from Motion* (SfM) difere do SR tradicional sobretudo em relação ao custo da instrumentação e da plataforma, quando comparado com o SR orbital e à aerofotogrametria tradicional. A aerofotogrametria-SfM basicamente necessita da posição das câmeras, ou um conjunto de pontos em comum localizados na cena de interesse para reconstruir a geometria dos objetos na superfície (White *et al.* 2016). Portanto, informações tridimensionais podem ser mensuradas a partir de imagens sobrepostas, sem necessidade de informações pré-requisitos sobre localização e orientação da câmera, calibração da câmera ou pontos de referência identificados nas imagens (Iglhaut *et al.* 2019), como na fotogrametria tradicional. A vantagem disso é que plataformas baratas podem ser empregadas, associado a praticidade operacional proporcionada para a equipe de IF.

O método SfM têm sido adotado de forma abrangente em estudos da superfície terrestre. Utilizado por exemplo no monitoramento de geleiras (Ryan *et al.*, 2015), morfologia fluvial (Javernick *et al.*, 2014), erosão do solo (Frankl *et al.*, 2015) e também para uma diversidade de estudos florestais como

quantificação de biomassa florestal (Dandois & Ellis, 2013). Tais aplicações são possíveis especialmente por oferecer baixo custo, alta resolução espacial, rápida aquisição e possibilidade de oferecer precisão para uma diversidade de questões ambientais.

O SfM é uma técnica fundamentada basicamente em dois princípios: (i) a visão binocular e (ii) a mudança de visão de um objeto observado a partir de um ponto em movimento, neste caso a ARP. O princípio da visão binocular é fundamentado na estereoscopia, ou seja, a profundidade pode ser percebida a partir de dois pontos em posição conhecida, permitindo mensurar medidas. Por outro lado, o segundo princípio também permite perceber a profundidade e volumes, no entanto a partir de um único ponto de observação se este estiver em movimento (Bolles *et al.* 1987; Koenderink, 1991; Westoby, 2012; Iglhaut *et al.* 2019).

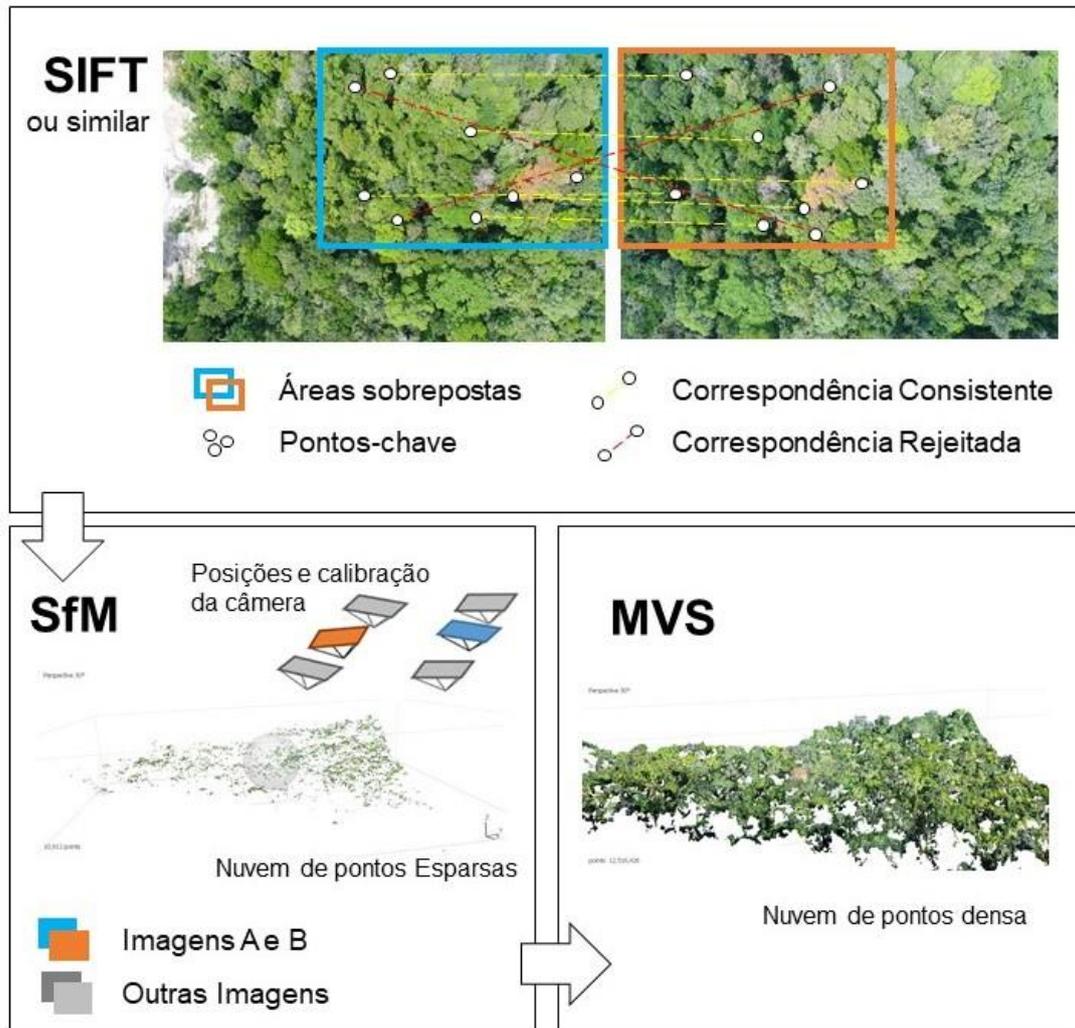
Ao compararmos o SfM com a fotogrametria tradicional podemos destacar três principais diferenças: i) os algoritmos SfM podem identificar e combinar imagens em diferentes escalas, ângulos de visão e orientações; ii) não há necessidade de informações de posição da câmera ou pontos de controle no solo, ainda que possam ser adicionados e iii) a calibração da câmera pode ser resolvida e refinada automaticamente durante o processo. Deste modo, o SfM pode entregar modelos fotogramétricos sem exigir homogeneidade rigorosa na sobreposição de imagens, posição da câmera e calibrações (Fonstad *et al.* 2013; Micheletti *et al.* 2015; Skarlatos *et al.* 2012). Embora o controle de fatores ambientais (iluminação), da plataforma (ARP rotativo ou ARP asa fixa) e da câmera/lente (ângulo de abertura, distância focal e tamanho do sensor) vão ser determinantes na qualidade do modelo final, uma vez que o SfM é um método passivo e não seletivo, logo a qualidade dos produtos é dependente da qualidade das imagens de entrada (White *et al.* 2016; Iglhaut *et al.* 2019).

Resumidamente, o SfM não é uma técnica ou ferramenta isolada, mas um fluxo de trabalho. Na literatura é comum encontrar apenas SfM, no entanto quando se refere a prática dos diferentes aspectos do fluxo de trabalho é encontrado o acrônimo SfM-MVS (Structure from Motion - Multi-view Stereo). Portanto, o fluxo de trabalho SfM-MVS necessita de múltiplas imagens (sobrepostas) de uma determinada superfície, adquiridas com uma câmera

fotográfica, a partir de vários pontos de vista de modo que capturem a tridimensionalidade completa superfície de interesse, para então reconstruir a geometria 3D desta superfície (Carravick *et al.*, 2016; Iglhaut *et al.* 2019).

O processo fundamental SfM-MVS (Figura 1) passa por:

- **Alinhamento (SIFT)** - Detecção e alinhamento a partir de características comuns (texturas) em imagens sobrepostas;
- **Nuvem de pontos esparsas (SfM)** – Recebem coordenadas X, Y, Z e o software constrói uma rede de pontos 3D correspondentes.
- **Nuvem de pontos densa (MVS)** - Após a criação da rede de pontos 3D, uma nuvem densa é gerada para preencher os espaços entre os pontos de ligação, portanto a partir do nível de detalhamento da nuvem os modelos serão diretamente derivados.
- **Geração dos modelos** – A partir da nuvem densa é obtido o Modelo Digital de Superfície (MDS) e o Ortomosaico. O MDS é um conjunto de dados geográficos digitais que representa elevações da superfície com coordenadas horizontais e verticais (x, y, z) e o ortomosaico é uma fotografia aérea não distorcida, com escala uniforme para todo o mosaico de imagens aéreas.



Adaptado de Iglhaut et al. (2019).

Figura 1. Os três processos principais de um fluxo de trabalho SfM-MVS.

Diante disso, a precisão das coordenadas estimadas para a nuvem de pontos derivados do SfM é determinada entre outros fatores por: (i) número de imagens sobrepostas nas quais o objeto de interesse aparece; (ii) distância média do sensor ao alvo; (iii) incidência de luz sobre os objetos de interesse. Portanto, são fatores que vão ser determinantes na qualidade da reconstrução dos objetos imageados (Iglhaut *et al.* 2019; Seifert *et al.* 2019).

Considerando isso, as características texturais, padrões de repetição e movimento potencial (por exemplo, por vento), as florestas provam ser desafiadoras para os algoritmos de correspondência com o SfM-MVS (Iglhaut *et al.* 2019; White *et al.*, 2016). Logo, para aplicar a fotogrametria SfM na silvicultura, alguns aspectos precisam ser considerados para alcançar bons resultados:

1. Altitude e escala – Escala é a razão entre uma distância medida em um mapa e a distância correspondente no terreno (Figura 2-A). Como a fotografia aérea é uma projeção perspectiva, as áreas que estiverem mais próximas da câmara, no momento da exposição, aparecerão maiores do que as correspondentes que estiverem mais distantes da câmara (Tommaselli, 2009). Portanto, a altitude de voo vai ser determinante na definição da escala, por outro lado, ao caracterizar a superfície de um dossel, a variação de atitude também pode obscurecer as clareiras e os detalhes do dossel (Baltsavias *et al.* 2008). Tal conceito é fundamental para a definição dos possíveis usos dos dados adquiridos com ARP, especialmente quando se trata de obter estimativas relacionadas a biomassa e de outras métricas da estrutura da floresta.
2. Sobreposição – Para Iglhaut *et al.* (2019) deve haver sobreposição alta para aumentar a redundância e vários ângulos de visão do mesmo objeto para reduzir oclusões e erros sistemáticos. É proposto cinco ou seis imagens para vegetação densa de uma mesma característica a ser reconstruída pelo algoritmo SfM para bons resultados. A maximização da sobreposição pode minimizar o erro da altura do dossel e da amostragem geral (Dandois, Olano e Ellis, 2015). Aqui adotamos um fator a mais a ser considerado, a distância da ARP ao alvo (o dossel da floresta), em muitos casos o planejamento é feito em função apenas da distância ao solo, subestimando a sobreposição efetiva (Figura 2-B).
3. Intensidade de iluminação efetiva - Para Iglhaut *et al.* (2019) a cena deve ser suficientemente iluminada, com iluminação homogênea, como em dias nublados ou sem nuvens. No entanto, se aplicarmos os conceitos do sensoriamento remoto orbital e as relações geométricas entre a direção da iluminação do alvo e a posição do sensor, estes vão influenciar nas condições de iluminação e na resposta espectral dos alvos, visto que as superfícies refletem diretamente de acordo com sua anisotropia (FILHO, 2000). Nesse caso, a variação do ângulo solar pode variar sazonalmente

e durante o dia, ângulos de elevação solar mais altos proporcionam condições de iluminação mais homogênea, enquanto ângulos de elevação solar mais baixos proporcionam o contrário, maior sombreamento (Figura 2-C). Portanto dependendo do propósito, essas diferenças devem ser consideradas, ou seja, a diferença angular entre o sol e a posição do sensor podem proporcionar resultados diferentes na geometria dos objetos (Hargitai *et al.*, 2019). Ângulos de fase maiores em tese vão causar maior quantidade de sombras, deste modo, o comportamento fotométrico da superfície poderá incluir mudanças substanciais de contraste com o angulo de fase maior, o que pode tornar a estereofotogrametria difícil, causando perda de dados (White *et al.*, 2014).

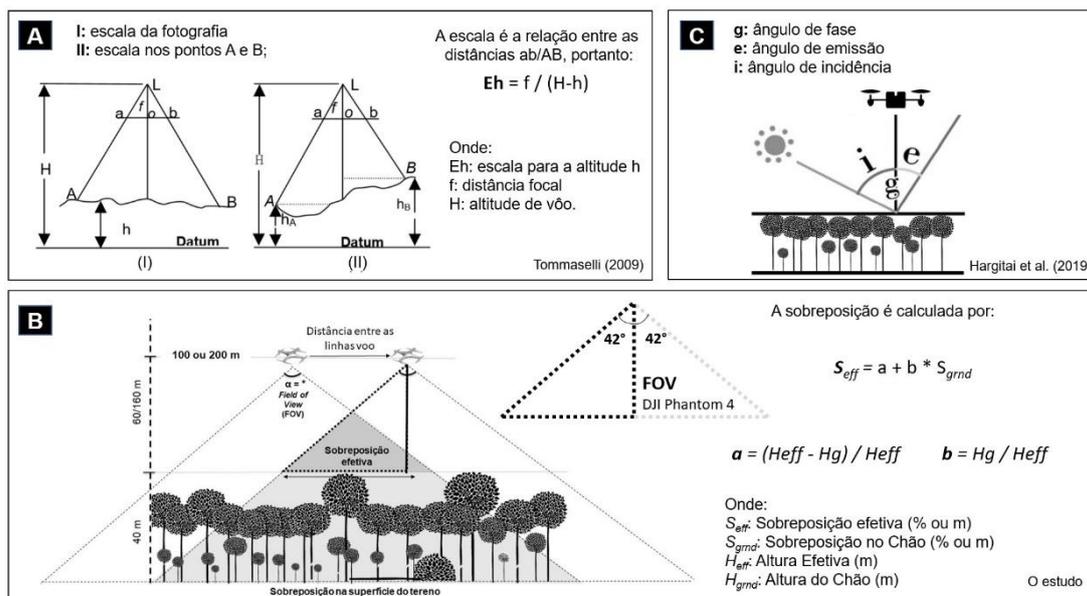


Figura 2. Ilustração dos fatores de maior influência na qualidade. A – Escala da imagem em função da altitude. B – Cálculo da sobreposição em relação ao chão, ao dossel (efetiva), lateral e frontal. C – Ângulo de fase.

3.3.4. ARP-SfM em inventários florestais

Conforme resumido na Tabela 2, diversas abordagens têm sido adotadas em estudos que utilizam dados de ARP para o mapeamento e caracterização da estrutura da floresta.

Tabela 2. Exemplos de estudos que aplicaram a abordagem baseada em imagens aéreas de Aeronaves Remotamente Pilotadas.

Estudo	Local	Tempo	Área	Condições Ambientais	Altitude (m)*	Sobreposição (%)	Plataforma	Objetivo	Resultados
Dandois e Ellis, 2013	Maryland – USA / Floresta decídua	16 meses	6,25 ha (250 m x 250 m)	Luz direta	130 m	>90	Mikrokopter Hexakopter	Monitorar a dinâmica estrutural e espectral da vegetação. Com ALS e SfM. Para biomassa e fenologia	Erros nas métricas da copa. Estimativa de AGB subestimada.
Getzin et al., 2014	Alemanha	Sem variação temporal	Parcelas de 1 ha	--	250 m	--	Carolo P200	Mapeamento de pequenas clareiras em florestas manejadas e não manejadas	A frequência do tamanho foi dominada por pequenas clareiras <5 m ²
Zahawi et al., 2015	Costa Rica / Floresta Tropical Pré-Montana	--	Parcelas de 0,25 ha (50X50 m)	--	Entre 30 – 40 metros, acima do dossel	90/70	Hexacóptero Hobbyist	Derivar medidas de altura, complexidade estrutural e abertura do dossel para uma área em restauração	Altamente correlacionados com dados de campo, altura do dossel (R2 ≥ 0,85), biomassa (R2 ≥ 0,81) e a % de abertura do dossel (R2= 0,82).
Wallace et al. 2016	Tasmânia, Austrália / Floresta esclerofila com eucalipto	Sem variação temporal	0,15 ha (30 x 50 m)	Luz direta (meio dia solar)	30 m	95/66	Droidworx Skyjib Oktokopter	Mensurar as propriedades estruturais das florestas (altura), comparando ALS e SfM	Diferença vertical de 0,92m (ALS) e 1,30m (SfM). E diferença horizontal de 0,42 (ALS) e 0,40 (SfM)
Figueiredo et al. 2018	Acre, Brasil / Floresta Tropical	Sem variação temporal	5,05 ha, 5,74 ha 6,48 ha	--	100 m, 110 m, 120 m, acima do dossel	87/80 88/81 89/83	DJI Phantom 3 Advanced	Mapeamento de degradação florestal causada por exploração ilegal	Erro médio da área degradada foi: 9,09 % 23,32 % 23,59 %
Figueiredo et al. 2018	Acre, Brasil / Floresta Tropical	Sem variação temporal	5 ha, 10 parcelas de 0,5 ha	--	120 m, acima do dossel	81.87	DJI Phantom 4 Pro	Georreferenciamento de palmeiras	Erro médio de posicionamento de 6,2 cm (X), 12,5 cm (Y) e 62,54 cm (Z)
Cunha, 2018	Acre, Brasil / Floresta Tropical	Sem variação temporal	10 parcelas de 1 ha	--	160 m, acima do solo	80	DJI Phantom 4 Pro	Mapeamento de degradação florestal causada por manejo florestal	Os percentuais de área e perda de biomassa em área de exploração foram semelhantes aos dados de LIDAR

Araújo, 2019	Amazonas, Brasil / Floresta Tropical madura	12 meses	2 ha (20 x 1000 m)	Luz difusa (~16h e 17h)	80 m	88/62	DJI Phantom 2	Mensurar estrutura, identificação de fenofases foliares e cálculo de índices espectrais, com SfM	Mensuração de tamanho de copa e identificação da estratégia das árvores para alcançar luz.
Park et al. 2019	Colorado, Panamá / Floresta Tropical Úmida	12 meses	50 ha (1000 x 500 m)	--	200 metros, acima do dossel	90/75	Mikropkopter	Quantificar padrões interanuais de variação na folha das copas de espécies individuais por algoritmos de aprendizagem de máquina	Previu com sucesso padrões em árvores individuais, com r^2 de 0.82 e erro absoluto médio de 8,1% e para análise ao nível de espécie obteve r^2 de 0.89 e erro absoluto médio 6 %
Huang et al 2019	Fuzhou, China / Médio-subtropical	3 meses	Árvores individuais	--	--	90/80	DJI Phantom 4 Pro	Verificar se fatores de estrutura do dossel das árvores, especialmente quantidade ou volume foliar, podem ter um grande efeito na estimativa da altura.	As condições foliares têm um efeito positivo nas medições da altura das árvores derivadas de ARP/SfM
Araújo et al. 2020	Amazonas, Brasil / Floresta Tropical madura	12 meses	2 ha (20 x 1000 m)	--	80 m	88/78	DJI Phantom 2	Mapeamento de copas para determinar o status do dossel associado com dados de inventário florestal	Quantificação da proporção de árvores no dossel e no sub-bosque em relação ao tamanho das árvores, as contribuições das árvores do dossel e do sub-bosque para os estoques de carbono e produtividade da madeira

Observa-se que dos estudos encontrados, havia grande divergência de valores de sobreposição, ficando em torno de 80-95 %. Não estava claro se a sobreposição adotada considerava o efeito da altura da floresta. Outro ponto observado, é que em alguns desses estudos não foi apresentado o horário da aquisição das imagens, conseqüentemente não sendo possível avaliar se a iluminação pode ter sido um fator determinante nos resultados obtidos.

Nesse contexto, estudos como de Park *et al.* (2019) destacam a aplicação da textura para análise de copas, onde as mudanças de iluminação podem diminuir a utilidade de índices de cores. Nesse estudo, o algoritmo de aprendizagem de máquina previu com sucesso padrões em árvores individuais, com r^2 de 0,82 e erro absoluto médio de 8,1% e para análise ao nível de espécie obteve r^2 de 0,89 e erro absoluto médio 6 %. Portanto, o controle dessa variável é fundamental para obter bons resultados com os dados obtidos por ARP. Em concordância com a necessidade de considerar a qualidade dos produtos de ARP antes da realização de uma determinada pesquisa, estudos como de Huang *et al.* 2019 constatam que a densidade do dossel pode influenciar nas estimativas tridimensionais, especialmente de altura, colaborando para ilustrar a importância desta temática qualitativa.

4. MATERIAL E MÉTODOS

4.1. Área de Estudo

O estudo foi realizado na Estação Experimental de Silvicultura Tropical (EEST/ZF2) do Instituto Nacional de Pesquisas da Amazônia (INPA), uma área com 21.000 ha de floresta madura no município de Manaus-AM. A área localiza-se entre os Km-20 e Km-35 da vicinal ZF-2, perpendicular à BR-174, próximo do Km-50 da referida estrada federal. Essa área representa um importante sítio de pesquisas com manejo florestal em florestas tropicais úmidas desde 1980 (Jardim e Hosokawa, 1986/87; Higuchi *et al.* 1997), com experimentos em áreas manejadas experimentalmente e dinâmica de florestas maduras.

A área de coleta de dados foi a base da EEST/ZF2 (Figura 3), em uma parcela retangular de 18 hectares, denominada “Quadrado”.

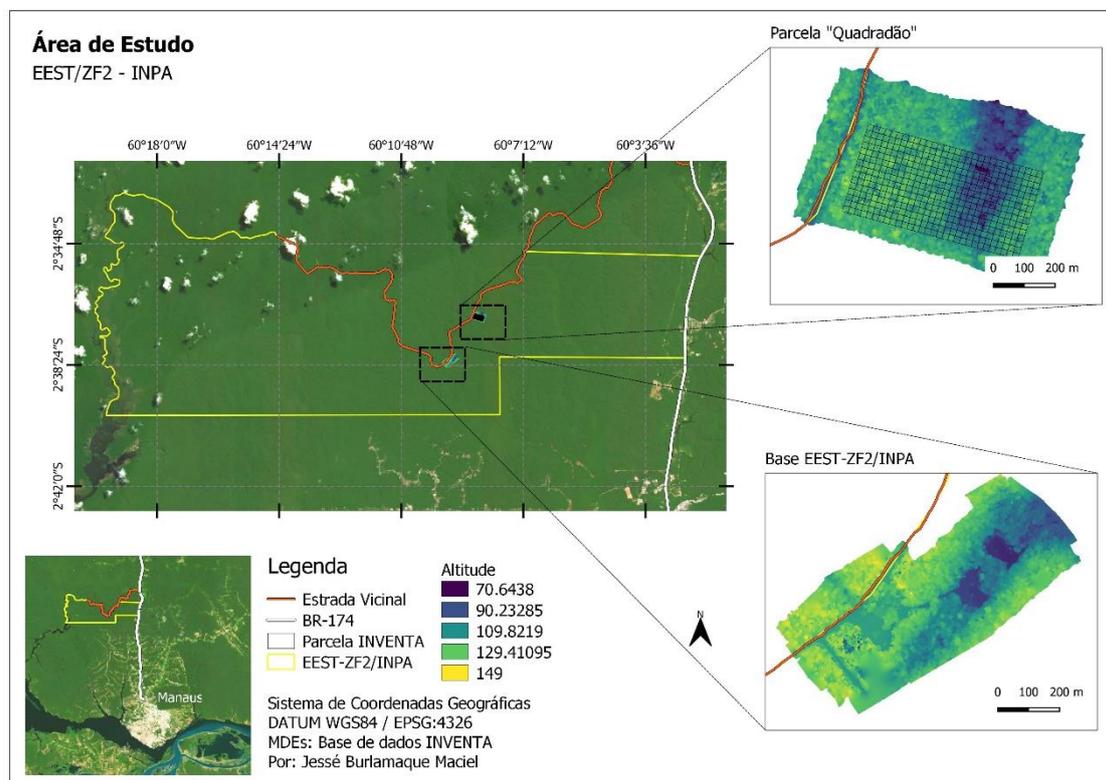


Figura 3. Localização da área do estudo – Parcela “Quadrado”

A vegetação da área do estudo é uma amostra dos 4 milhões de km² da floresta amazônica. Predominantemente caracterizada como floresta tropical

úmida densa em terra-firme (Higuchi *et al.*, 1997). A vegetação da área abriga as florestas mais heterogêneas da Amazônia e estrutura vertical variando entre 30 a 40 metros, (Huek, 1972; Higuchi *et al.*, 1997).

4.2. Coleta de Dados

4.2.1. Dados de campo

Pontos de controle no terreno

Para os pontos de controle (PC), as coordenadas geográficas foram coletadas com um aparelho receptor de sinais GNSS Diferencial (DGPS) modelo *Pathfinder 6 Pro* da Trimble®. As coordenadas registradas por meio do DGPS com pós processamento, geram resultados mais precisos que aparelhos de navegação, especialmente quando testado em áreas de florestas com dossel fechado (Hasegawa and Yoshimura, 2003; Sawaguchi *et al.* 2005; Wing *et al.* 2007). Os pontos de controle foram instalados em formato de “X” em tábuas de madeira pintadas de branco, com 2 por 0,20 metros (Figura 4). Inicialmente foram planejados para fazer a relação entre o sistema de coordenadas da imagem com o sistema de coordenadas do terreno.

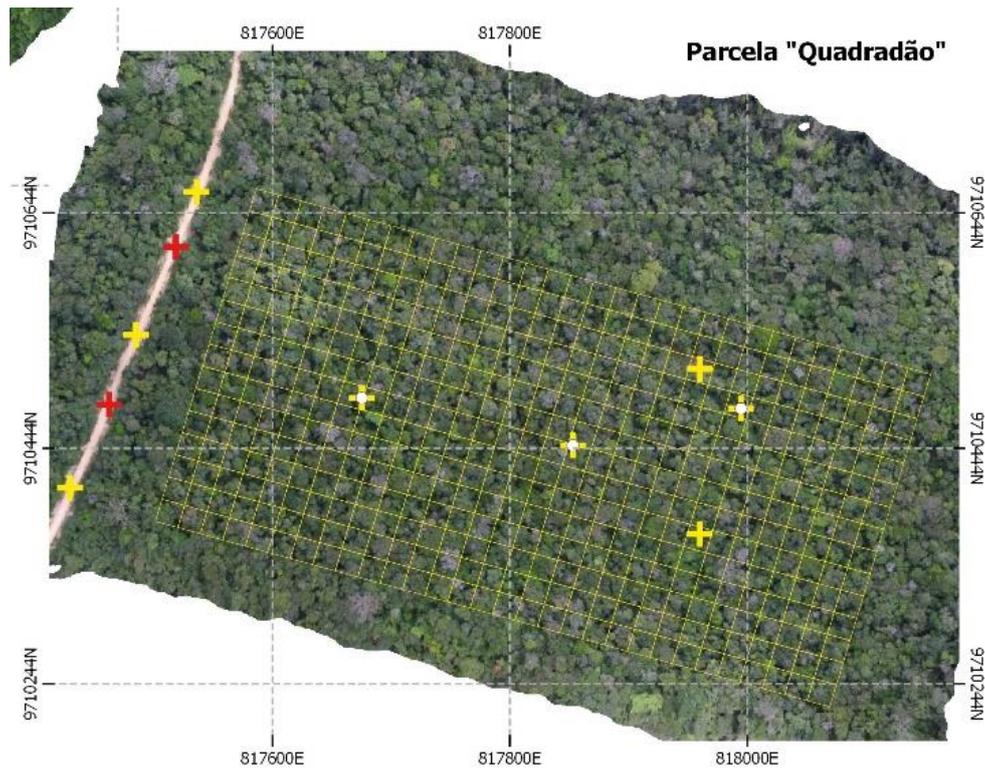


Figura 4. Pontos de Controle. Em amarelo – PC em clareiras e torres. Em vermelho – PC complementares.

Na parcela “Quadrado” – foram instalados 8 pontos de controle (PC) para o georreferenciamento do bloco fotogramétrico. Nesse processo foram instalados em 2 clareiras já existentes na área, 3 instalados na estrada e outros 3 em três torres existentes na área. No entanto, devido a não abertura de novas clareiras não foi possível instalar novos pontos de controle no terreno.

4.2.2. Dados remotos

i) Produtos ARP/SfM

Os dados da ARP consistem em imagens aéreas georreferenciadas, um modelo digital de superfície (MDS) e uma imagem ortorretificada. A plataforma utilizada foi um Phantom 4 Advanced desenvolvida pela SZ DJI Technology Corporation Limited (Shenzhen, China), classificado como quadricóptero e enquadrado na Classe 3 da Regulamentação (RBAC-E nº 94) da ANAC de 2017. A ARP leva a bordo um sensor CMOS de 1” com 20 megapixels (Tabela 3).

Possui precisão de foco vertical de $\pm 0,1$ m (com *Vision Positioning*) ou $\pm 0,5$ m (com posicionamento do GNSS), enquanto a precisão horizontal é de $\pm 0,3$ m (com *Vision Positioning*) ou $\pm 1,5$ m (com posicionamento do GNSS) (DJI, 2019). O receptor GNSS integrado recebe posições de duas constelações, da americana GPS e do russo GLONASS (DJI, 2019).

Tabela 3. Especificações do sensor RGB.

Sensor	CMOS
Tamanho do sensor de imagem	13,2 mm X 8,8 mm
Resolução de imagem	5472 x 3648 pixels
Fild of View (FOV)	84° (24 mm, equivalente 35 mm)
Tamanho do pixel	2,41 μ m
Groud Sample Distance (GSD)*	-
Bandas espectrais	R (490 – 600 nm)
	G (600 – 700 nm)
	B (700 – 1000 nm)

*Variável conforme altitude de vôo aplicada.

Fonte: DJI, 2019

Os conjuntos de dados de imagens foram coletados com base na combinação de **fatores de maior influência na qualidade**. Foram definidos os seguintes parâmetros de aquisição com o sistema (plataforma + sensor) descrito acima:

- Para **altitude**, serão testadas duas altitudes de voos:
 - i) 100 metros acima do solo;
 - ii) 200 metros acima do solo.

- Para **intensidade de iluminação**, serão testadas duas classes de incidência de luz:
 - i) Luz difusa – céu nublado;
 - ii) Luz direta – iluminação solar direta.

- Para **sobreposição frontal e lateral**:
 - i) Sobreposição alta - 90/80 %;

- ii) Sobreposição moderada - 80/70 %.
- iii) Sobreposição baixa – 60/30 %.

Uma vez que os parâmetros foram definidos, foi possível avaliar o efeito dessas características na qualidade dos produtos. Para a sobreposição, foi definido no software de planejamento considerando que o alvo a ser imageados está no nível do terreno, no entanto, no caso deste estudo o alvo (a floresta) está a aproximadamente 32 metros da superfície do terreno. Portanto, a sobreposição definida no software de gerenciamento de voo é diferente da sobreposição obtida em campo, denominado aqui de sobreposição efetiva. Diante disso, propomos uma equação para auxiliar no cálculo das sobreposições efetivas:

$$S_{eff} = a + b * S_{grnd}$$

Para calcular as variáveis:

$$a = (H_{eff} - H_{grnd})/H_{eff} \quad b = H_{grnd}/ H_{eff}$$

Onde:

S_{eff} = Sobreposição efetiva S_{grnd} = Sobreposição no Chão
 H_{eff} = Altura Efetiva H_{grnd} = Altura do Chão
 $grnd$ = chão/no solo

Assim, temos:

Tabela 4. Efeito da altura da floresta na sobreposição frontal e lateral comumente utilizados na literatura.

SOBREPOSIÇÃO PLANEJADA	SOBREPOSIÇÃO EFETIVA CALCULADA	SOBREPOSIÇÃO EFETIVA CALCULADA
	A 100 M	A 200 M
90/80	85/71	94/88
80/70	71/56	88/82
60/30	41/0	76/58

4.4. Análises

4.4.1 Processamento dos dados

4.4.1.1. Dados de campo

i) Pontos de controle no terreno

O processamento das coordenadas coletadas com o DGPS dos pontos de controle (PC), foram pós-processados e corrigidos no software Trimble GPS Pathfinder Office, utilizando informações fornecidas de uma estação coletora da Rede Brasileira de Monitoramento Contínuo (RBMC) do Instituto Brasileiro de Geografia e Estatística (IBGE) – Manaus-AM.

4.4.1.2. Dados Remotos

i) Imagens ARP

As imagens aéreas da ARP foram processadas no software Agisoft Metashape Professional versão 1.5.2 build 7838 (AGISTOF LLC., St. Petersburg, Rússia). O dispositivo utilizado foi um Windows 64 bits com 2 processadores Intel Xeon CPU E5-2650 0 a 2.00 GHz e 32 GB de RAM. Para tal procedimento, foi adotado o seguinte fluxo de processamento:

1) Filtro visual nas imagens, para remover fotos borradas ou de baixa qualidade – processo manual;

2) Alinhamento das imagens, os parâmetros utilizados foram:

- Acurácia Alta, para estimativas mais precisas da posição da câmera;

- Limite de pontos-chave 40.000, para encontrar pontos característicos confiáveis em cada imagem;
- Limite de pontos de amarração 4.000, para filtragem do limite superior de pontos de correspondência para cada imagem.
- Otimização da nuvem de pontos.

A configuração foi moderada para otimizar o desempenho (tempo x volume da dados) deste processo e para não afetar a qualidade do modelo a ser produzido, visto que esse processo pode desperdiçar alguns pedaços da nuvem de pontos quando não é possível encontrar o limite padrão de pontos por pares de fotos, conforme sugerido Agisoft LLC, (2018). O resultado desse processo foi a nuvem de pontos esparsas;

3) O terceiro processo, foi a produção da nuvem densa de pontos. Os parâmetros utilizados foram: (i) Qualidade Média, para otimizar o processamento e obter geometrias detalhadas e precisas; (ii) Filtro de profundidade agressivo, para que informações importantes não sejam perdidas, visto que o dossel da floresta apresenta textura rugosa e irregular, padrões de repetição e movimento potencial (vento) (Iglhaut *et al.*, 2019).

4) O quarto processo, foi o Modelo Digital de Superfície (MDS), ou seja, a geração de uma grade regular de valores de altura dos objetos imageados. O MDS foi gerado a partir da nuvem densa de pontos e a interpolação ativada por padrão, a fim de obter resultados confiáveis apenas das áreas correspondentes aos pontos de nuvens de pontos densos.

5) O quinto processo, foi o ortomosaico. Os parâmetros foram: (i) Superfície com base nos dados do MDS; (ii) Modo de mesclagem: mosaico padrão; (iii) Correção de cor desativado, visto que houve o controle do horário de coleta dos dados.

4.4.2. Análise estatística

i) Acuracidade do Posicionamento

Diante do cenário encontrado ao longo do desenvolvimento do estudo, a disposição não favorável para instalação de pontos de controle suficientes, optamos por analisar o posicionamento a partir dos dados espaciais (XYZ) do bloco fotogramétrico de cada método testado.

ii) Geometria dos objetos – Análise de variância (ANOVA) e Teste de Tukey

A geometria dos objetos foi comparada com a média do comportamento das variáveis resultado de cada método (Tabela 5). Inicialmente a análise foi descritiva, apresentando as características estatísticas de cada método, como as médias, as variâncias, desvio padrão, distribuição e o intervalo de confiança (IC, 95% probabilidade) para cada método. Foram testados 12 (doze) métodos com todos os parâmetros de aquisição combinados, ou seja, 12 voos com ARP e seus respectivos produtos. Os métodos foram:

Tabela 5. Métodos de aquisição com ARP.

MÉTODO	ALTURA	SOBREPOSIÇÃO	ILUMINAÇÃO
M1	100 m	90/80 %	Luz Difusa
M2	100 m	80/70 %	Luz Difusa
M3	100 m	60/30 %	Luz Difusa
M4	100 m	90/80 %	Luz Direta
M5	100 m	80/70 %	Luz Direta
M6	100 m	60/30 %	Luz Direta
M7	200 m	90/80 %	Luz Difusa
M8	200 m	80/70 %	Luz Difusa
M9	200 m	60/30 %	Luz Difusa
M10	200 m	90/80 %	Luz Direta
M11	200 m	80/70 %	Luz Direta
M12	200 m	60/30 %	Luz Direta

Onde: Os métodos ~~tachados~~ não processaram devido o seu conjunto de características.

As amostras das variáveis de cada método foram extraídas e comparadas a partir de dois pontos de vista: **Geométrico** - para verificar o efeito da sobreposição e altitude; e **Radiométrico** - para verificar o efeito da intensidade de iluminação efetiva.

As variáveis extraídas e comparadas foram:

- i) **Geométricas**: Perímetro (m) de copas e área (m²) de copas
- ii) **Radiométricas**: estatística do histograma do Modelo Digital de Elevação.

A avaliação dos produtos (imagem) destes métodos foi avaliada em copas aleatoriamente. Nesse processo, foi utilizada vetorização manual em software SIG para extrair as geometrias das imagens. Para verificar o efeito dos parâmetros de aquisição nas variáveis, foi extraído quarenta e oito (48) amostras geométricas de copas para os métodos testados.

Foi testada a seguinte hipótese: **H0**: A média das geometrias são iguais e **H1**: A média das geometrias são diferentes.

Foi aplicada uma Análise de Variância (ANOVA), com o resultado menor que 0.05 rejeitamos H0 e, portanto, um ou mais grupos diferem nas médias. Então foi feito o teste post-hoc de Tukey para identificar quais métodos foram estatisticamente diferentes.

5. RESULTADOS

Os dados descritivos de cada voo demonstram diferentes características e níveis de complexidade dos métodos (Tabela 6), onde métodos com maior sobreposição e menor altitude produziram maior quantidade de dados para serem processados, influenciando no tempo da aquisição dos dados e no processamento. Por outro lado, os métodos com menores sobreposições produziram menor número de dados, promovendo menor tempo de aquisição e de processamento.

Tabela 6. Resumo dos parâmetros obtidos com os 7 métodos.

MÉTODOS	COVERAGE AREA	GROUND RESOLUTION	TIE POINTS	NUMBER IMAGES	TOTAL ERROR (M)	POINT DENSITY DEM	PROCESSING TIME
M1	0.354 km ²	2.2 cm/pix	822,691	811	3,07	129 points/m ²	44 minutes 9 seconds
M2	0.318 km ²	2.29 cm/pix	122,749	277	4,92	478 points/m ²	18 minutes 41 seconds
M3	-	-	-	-	-	-	-
M4	0.204 km ²	2.25 cm/pix	490,142	419	3,41	123 points/m ²	21 minutes 9 seconds
M5	-	-	-	-	-	-	-
M6	-	-	-	-	-	-	-
M7	0.486 km ²	4.99 cm/pix	271,288	201	5	25.1 points/m ²	7 minutes 58 seconds
M8	0.421 km ²	4.99 cm/pix	88,579	69	7	25.1 points/m ²	3 minutes 56 seconds
M9	-	-	-	-	-	-	-
M10	0.487 km ²	4.94 cm/pix	276,355	203	4,01	102 points/m ²	10 minutes 21 seconds
M11	0.363 km ²	4.86 cm/pix	30,864	68	44	106 points/m ²	2 minutes 8 seconds
M12	-	-	-	-	-	-	-

Onde: **M1** - 100 m - 90/70 – Luz direta; **M2** - 100 m - 80/70 – Luz difusa; **M4** - 100 m - 90/80 – Luz direta; **M7** - 200 m - 90/80 – Luz difusa; **M8** - 200 m - 80/70 – Luz difusa; **M10** - 200 m - 90/80 – Luz direta; **M11** - 200 m - 80/70 – Luz direta.

Posicionamento dos objetos

Quanto ao **posicionamento dos objetos** imageados, avaliamos o posicionamento espacial das imagens a partir das estatísticas descritivas de cada bloco fotogramétrico. Os diferentes métodos produziram diferentes deslocamentos conforme mostra tabela 7 abaixo.

Tabela 7. Erros do georreferenciamento obtidos com os 7 métodos.

MÉTODOS	X ERROR (M)	Y ERROR (M)	Z ERROR (M)	XY ERROR (M)	TOTAL ERROR (M)
M1	2,87	2,87	0,79	2,97	3,07
M2	4,66	1,27	0,94	4,83	4,92
M3	-	-	-	-	-

M4	2,99	1,19	1,12	3,22	3,41
M5	-	-	-	-	-
M6	-	-	-	-	-
M7	4,27	1,18	1,02	4,43	4,43
M8	6,37	1,72	1,01	6,60	6,68
M9	-	-	-	-	-
M10	3,74	1,22	0,79	3,93	4,01
M11	30,66	31,96	1,65	44,29	44,32
M12	-	-	-	-	-

Destacamos o método M11 pela diferença em relação aos demais, com erro total de 44,32 metros, influenciado principalmente pela baixa sobreposição planejada e altitude elevada de 200 metros. De 68 imagens obtidas neste sobrevoo, apenas 55 imagens foram utilizadas no alinhamento e conseqüentemente na formação do mosaico, representando 80% de aproveitamento (Figura 5). Nestes casos, a sobreposição planejada (80/70%) é, na prática, representada por 76/58% de sobreposição no terreno (Tabela 8).

Tabela 8. Efeito da altura da floresta na sobreposição frontal e lateral comumente utilizados na literatura.

SOBREPOSIÇÃO		
PLANEJADA	EFETIVA CALCULADA	EFETIVA CALCULADA
	A 100 M	A 200 M
90/80	85/71	94/88
80/70	71/56	88/82
60/30	41/0	76/58

Fonte: Organizada por este estudo.

Por outro lado, o método M1 foi o que apresentou menor erro total, com 3,07 metros (Figura 5). Neste caso influenciado pela alta sobreposição e altitude de voo mais adequada, com 100 metros de altitude. Desse modo, observamos que de 811 imagens obtidas neste sobrevoo, 811 foram utilizadas no alinhamento e na construção do mosaico, representado 100% de aproveitamento das imagens.

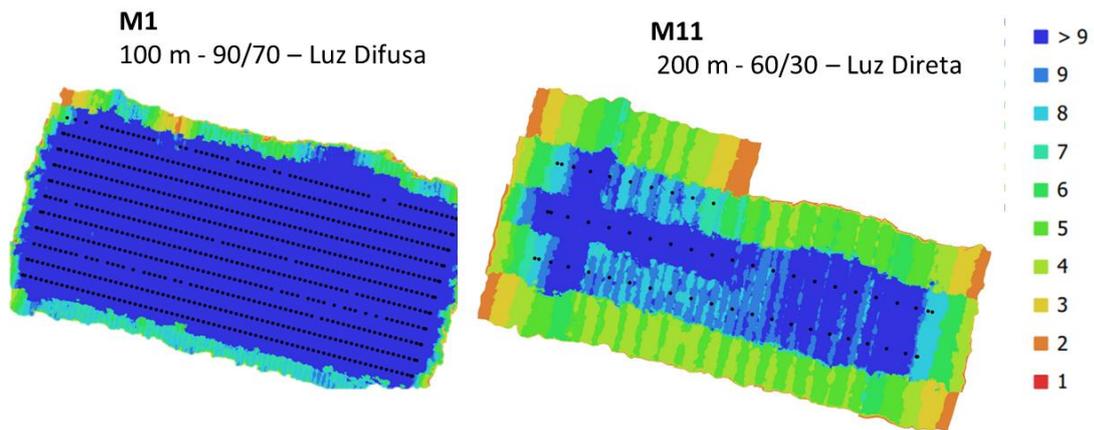


Figura 5. Localizações das imagens e número de imagens sobrepostas para os métodos M1 e M11.

Portanto, observamos que menores sobreposições e altitudes elevadas podem influenciar na qualidade dos produtos extraídos dessas imagens, visto que causam grandes deslocamentos em XYZ e erros na formação do mosaico de imagens, como podemos observar nas imagens das sobreposições. Estes resultados evidenciam o que foi discutido por Iglhaut *et al.* 2019 e Seifert *et al.* 2019, onde afirmam que a precisão das coordenadas para a nuvem de pontos derivados do SfM é determinada entre outros fatores por:

- (i) número de imagens sobrepostas nas quais o objeto de interesse aparece;
- (ii) distância média do sensor ao alvo;
- (iii) incidência de luz sobre os objetos de interesse.

Geometria dos objetos imageados

A **diferença geométrica dos objetos imageados** com as diferentes configurações de sobreposição, altitude da câmera e intensidade de incidência de luz produziram resultados diferenciados e desconformes em alguns casos. De 12 métodos planejados inicialmente, apenas 7 geraram dados suficientes para serem processados no software Agisoft Metashape. Destes 7, 3 produziram resultados desconformes dos demais, ou seja, com falhas no mosaico gerado, estes métodos são o M2, M4 e o M11 (Figura 6). Estas regiões estão destacadas

em vermelho hachurado na imagem abaixo, coincidindo em grande parte com regiões de borda onde a sobreposição entre as imagens é menor. Estas diferenças de sobreposição identificadas estão destacadas na figura 7.

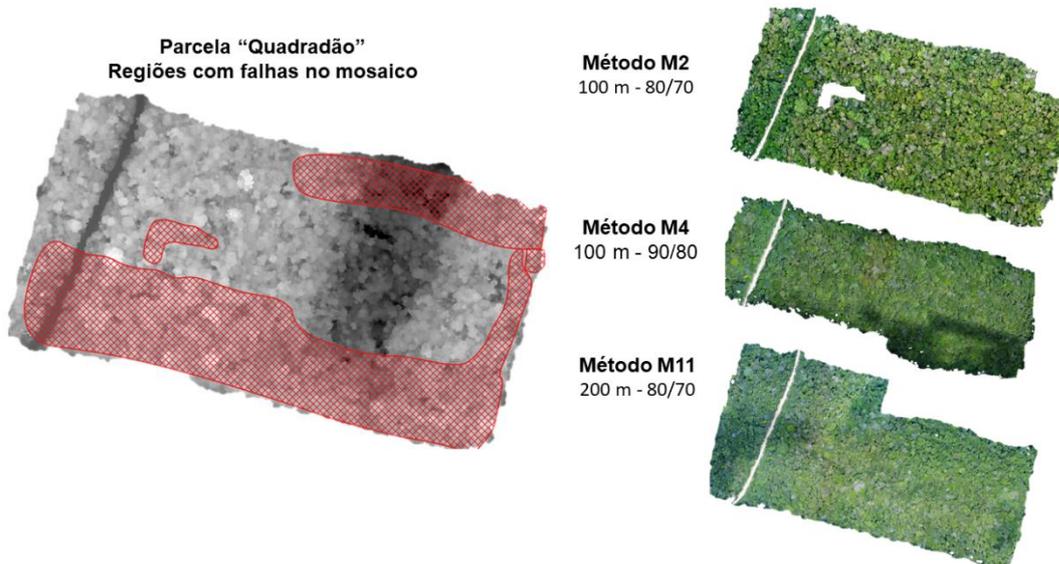


Figura 6. Falhas nos mosaicos M2, M4 e o M11.

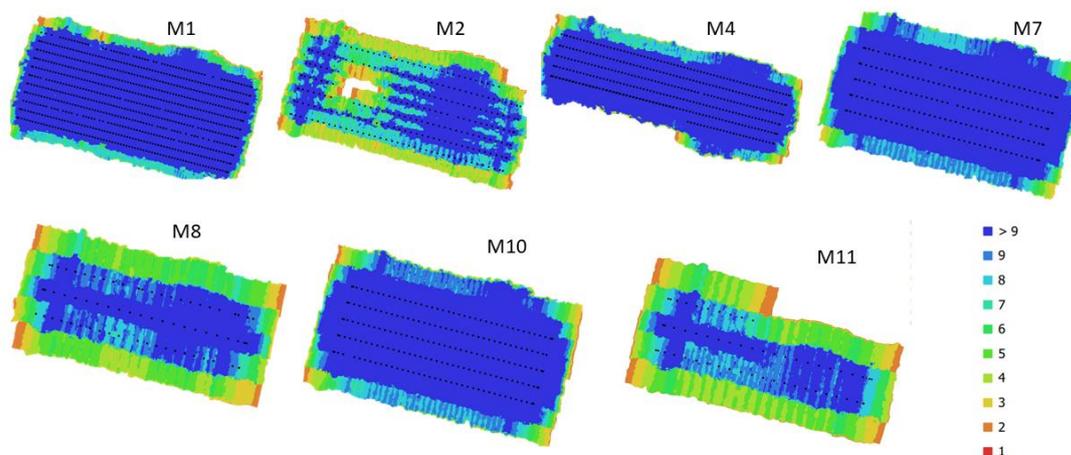


Figura 7. Localizações das imagens e sobreposição dos 7 métodos que geraram dados suficientes para processamento.

A partir destas imagens foi definido 49 (n) objetos (copas) para análise estatística de todos os 7 métodos dos quais obtivemos resultados (Figura 8). Do ponto de vista geométrico, utilizamos as variáveis área e perímetro para comparação de médias.

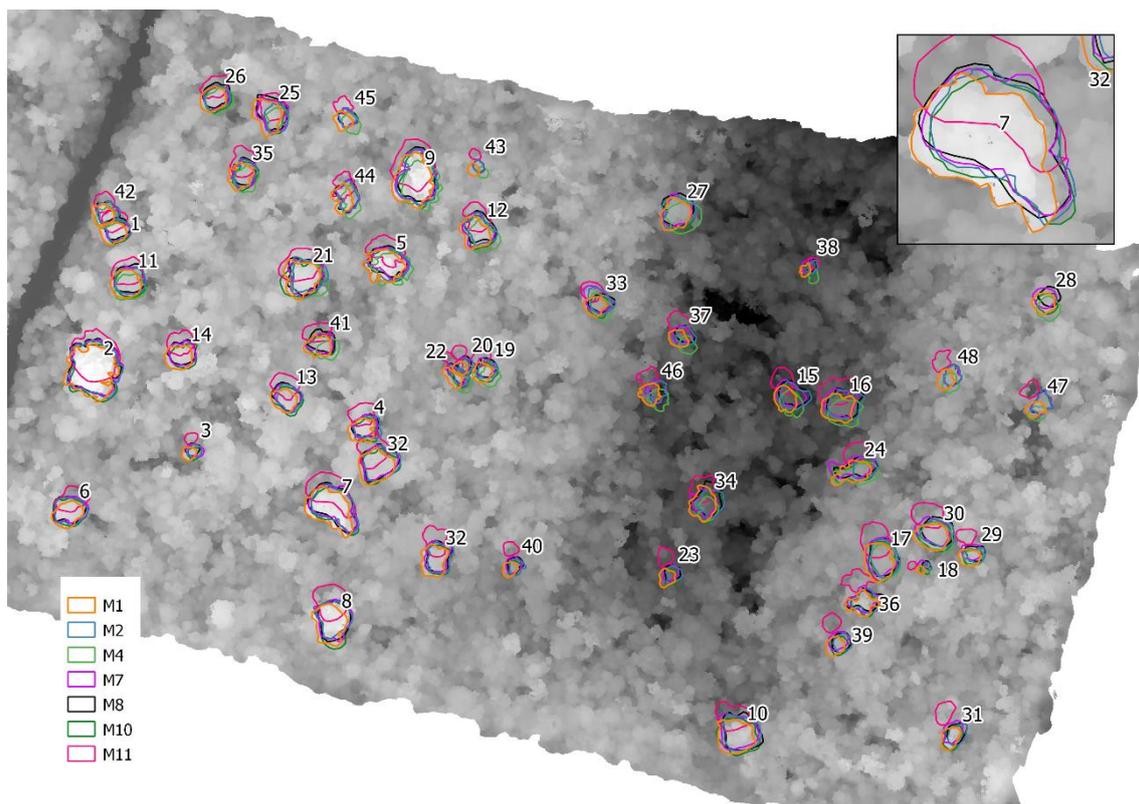


Figura 8. Polígonos vetorizados para o cálculo das variáveis.

Para a variável área (m²), a Análise de Variância (ANOVA) indicou valor $p < 0.0315$, na escala de verossimilitude do IPCC (2010) é extremamente improvável uma similaridade entre as médias conforme (Tabela 9).

Tabela 9. Estatísticas da comparação de médias entre os métodos testados para área de copas.

ANOVA	Diferenças em metros quadrados		
	Métodos	MD. ± I.C. (95%)	Mínimo
M1	248 ± 49.9	23.1	923.7
M2	240 ± 55.5	21.4	1034.4
M4	147 ± 43.7	17.6	666.3
M7	254 ± 50.8	22.4	979.1
M8	258 ± 52.9	20.1	1005.1
M10	258 ± 53.1	25.6	1025.4
M11	225 ± 48.4	24.8	863.9

p < 0.0315

Onde: ANOVA é a Análise de Variância; MD é a média da área de copas; I.C. é o intervalo de confiança, baseada no desvio padrão; Mínimo é o menor valor de área observado em cada método. Máximo é o maior valor de área observado em cada método.

Desse modo, foi aplicado o teste de *post-hoc* de Tukey. De acordo com os níveis de probabilidade estimados, o teste apresentou resultados que diferenciam o método M4. O teste de Tukey ainda apresentou fortes tendências de diferença estatística entre os métodos M8 e M10 em relação aos demais métodos (Figura 9).

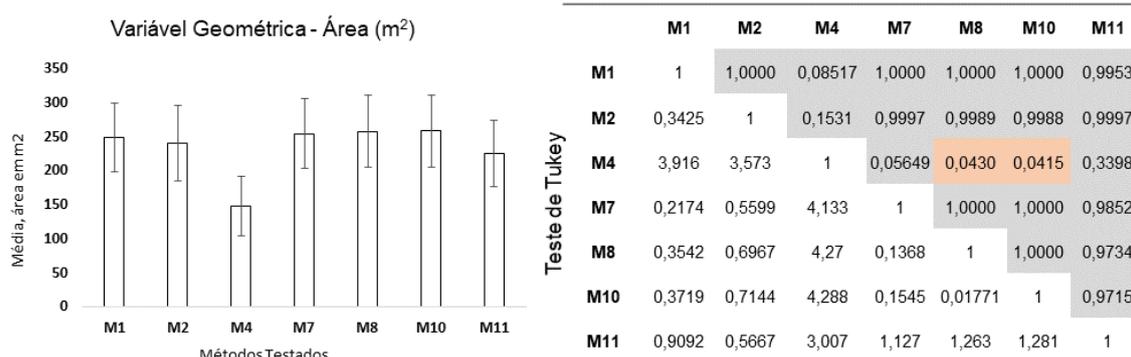


Figura 9. Teste de Tukey para Área (m²).

Para a variável perímetro (m), a Análise de Variância (ANOVA) indicou valor $p < 0,0000202$, na escala de verossimilitude do IPCC (2010) é excepcionalmente improvável uma similaridade entre as médias (Tabela 10).

Tabela 10. Estatísticas da comparação entre os métodos testados para a variável geométrica - perímetro (m).

ANOVA		Diferenças em metros	
Métodos	Média. ± I.C. (95%)	Mínimo	Máximo
M1	61.1 ± 7,3	19.6	165.4
M2	55.5 ± 7,4	17.5	130.2
M4	37.5 ± 8,8	16.1	114.7
M7	60.3 ± 6,3	17.8	114.8
M8	59.5 ± 6,2	16.6	118.7
M10	60.2 ± 6,3	20.9	114.3
M11	54.0 ± 6,3	18.3	111.2

p < 0,0000202

Onde: ANOVA é a Análise de Variância; MD é a média da área de copas; I.C. é o intervalo de confiança, baseada no desvio padrão; Mínimo é o menor valor de área observado em cada método. Máximo é o maior valor de área observado em cada método.

Desse modo, foi aplicado o teste de *post-hoc de Tukey*. De acordo com os níveis de probabilidade estimados, o teste apresentou resultados que diferenciam o método M4 dos demais métodos. (Figura 10).

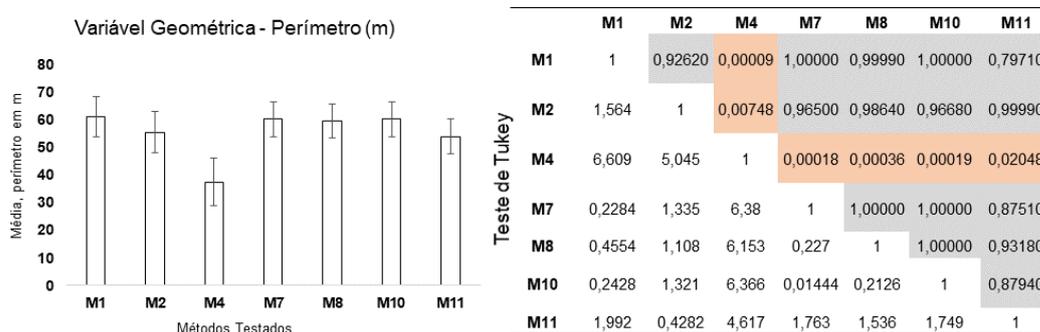


Figura 10. Teste de Tukey para Perímetro (m).

Desse modo, na maioria dos métodos não houve grandes diferenças em relação à área e perímetro médio da copa. Os diferentes métodos parecem ter algum tipo de variação espacial dentro do método. Sugerimos que as diferenças na altitude e na sobreposição das imagens podem distorcer, rotacionar ou gerar ruídos suficientes para dificultar a definição dos limites dessa geometria. Neste estudo foi testado a definição da geometria de forma manual, onde era conhecido o contexto da aquisição. Portanto, quando em altitudes elevadas, os ruídos vão dificultar a definição dos limites, mas em contrapartida, em altitudes menores o maior detalhamento facilita a definição dos limites. Em um estudo de maior escala, onde se faz necessário o uso de técnicas de segmentação orientada a objetos e onde a definição da geometria é definida via software SIG de modo automático, pode-se obter resultados indesejados - dependendo do método e característica da aquisição das imagens.

Do ponto de vista radiométrico, considerando os modelos digitais de elevação (m), observamos no histograma das copas vetorizadas que as médias em Z oscilam entre os métodos (Figura 11). Quando colocadas ao lado do erro XYZ do bloco fotogramétrico é possível identificar o efeito dos métodos na variação numérica dos valores de pixel (Z).

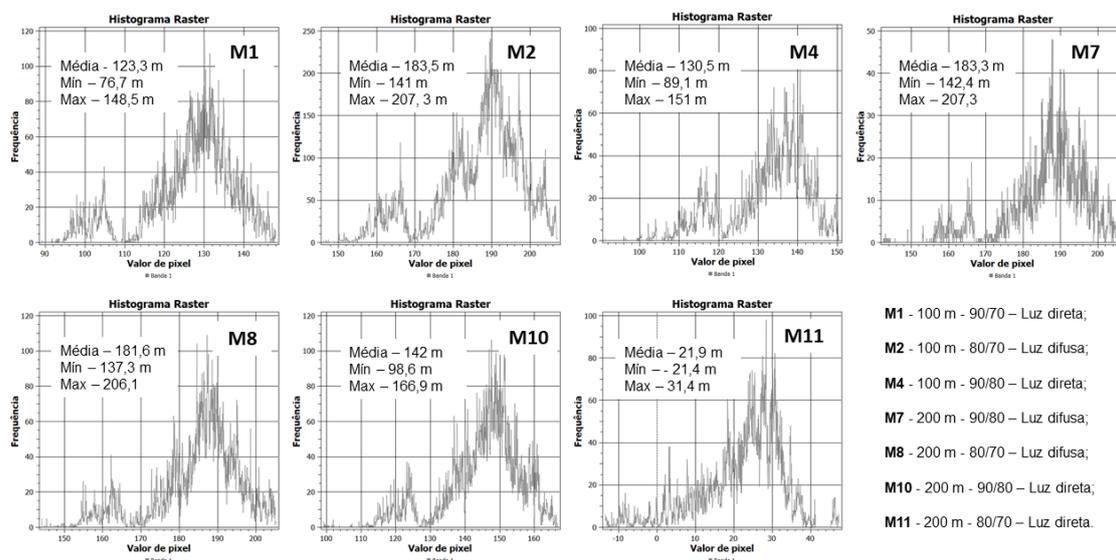


Figura 11. Histograma dos valores de Z das copas em cada método testado.

Tabela 11. Erros do georreferenciamento do bloco fotogramétrico para os 7 métodos.

MÉTODOS	X ERROR (M)	Y ERROR (M)	Z ERROR (M)	XY ERROR (M)	TOTAL ERROR (M)
M1	2,87	2,87	0,79	2,97	3,07
M2	4,66	1,27	0,94	4,83	4,92
M3	-	-	-	-	-
M4	2,99	1,19	1,12	3,22	3,41
M5	-	-	-	-	-
M6	-	-	-	-	-
M7	4,27	1,18	1,02	4,43	4,43
M8	6,37	1,72	1,01	6,60	6,68
M9	-	-	-	-	-
M10	3,74	1,22	0,79	3,93	4,01
M11	30,66	31,96	1,65	44,29	44,32
M12	-	-	-	-	-

Destaca-se os métodos M2, M7 e M8 como os que apresentaram maiores valores máximos de altitude nos histogramas. Estes também são os que

apresentam maiores erros espaciais no bloco fotogramétrico, com 4,92, 2,43 e 6,68 metros respectivamente. Por outro lado, o método M11 destoa dos demais de maneira oposta com valores extremamente baixos, possivelmente associado a baixa sobreposição de imagens e altitudes elevadas. Portanto, destacamos mais uma vez a importância de prezar pela alta sobreposição entre as imagens, que irá influenciar diretamente no número de imagens e coordenadas e conseqüentemente melhores erros em XYZ.

6. CONCLUSÃO

Os resultados seguem padrões específicos conforme o método de aquisição das imagens. Ainda que na média entre grupos os resultados possam ser bastante aproximados, é dentro dos grupos de dados de cada método onde podemos identificar as diferenças. Em condições de ótima iluminação com luz difusa, as copas serão mais bem definidas. Por outro lado, para clareiras isso pode não acontecer se o horário de aquisição e a condição de iluminação não for a ideal (em horários com alta inclinação solar), podendo torná-las “escuras” e pouco profundas.

Do ponto de vista técnico da aquisição de imagens, observamos que métodos mais robustos como o M1 podem gerar melhores resultados radiométricos e geométricos, no entanto, o grande volume de dados produzido por este método o torna dispendioso em tempo de aquisição, de processamento, geração de produtos e análise. De maneira oposta, métodos menos robustos como o M11 tornam praticamente impossível de se ter bons resultados, a exemplo dos métodos M3, M5, M6, M9 e M12, que devido à baixa robustez não foi possível sequer rodar o pré-processamento.

Do ponto de vista de georreferenciamento, quando possível recomendamos a instalação de pontos de controle em solo. Caso não seja possível, recomendamos a adoção de métodos que favoreçam alta sobreposição entre as imagens. Isso pode contribuir para melhorar o posicionamento do bloco fotogramétrico.

Portanto, quando houver disponibilidade apenas de sensor RGB, recomendamos os dados estruturais fornecidos pelo modelo digital de elevação como alternativa ao ortomosaico RGB com baixa qualidade radiométrica. Podemos alcançar boa qualidade com adoção do método M1 que proporciona melhores resultados geométricos e radiométricos para copas ou clareiras. Não havendo disponibilidade de tempo para aquisição e processamento com o método M1 recomendamos o método M7, que irá proporcionar resultados satisfatórios, com a possibilidade de cobrir uma área maior com menor números de sobrevoos.

Por fim, recomendamos sempre avaliar o custo operacional e de processamento bem como as relações entre área sobrevoada e qualidade das estimativas de estrutura. Isso pode ser alcançado combinando luz difusa, alta sobreposição e proximidade ao alvo.

7. APÊNDICE

Tabela 12. Estatística Descritiva da Variável Geométrica Área (m²)

	M1	M2	M4	M7	M8	M10	M11
<i>Tam (n)</i>	49,0	49,0	49,0	49,0	49,0	49,0	49,0
<i>Mínimo</i>	23,1	0,0	0,0	22,4	20,1	25,6	0,0
<i>Máximo</i>	923,7	1034,4	666,3	979,1	1005,1	1025,4	863,9
<i>Variância</i>	31797,0	39264,5	24347,8	32956,6	35659,5	35978,7	29856,6
<i>Amplitude</i>	900,6	1034,4	666,3	956,6	985,0	999,8	863,9
<i>Média</i>	248,9	240,0	147,5	254,5	258,0	258,5	225,3
<i>DesvPad</i>	178,3	198,2	156,0	181,5	188,8	189,7	172,8
<i>Nível Signif</i>	0,1	0,1	0,1	0,1	0,1	0,1	0,1
<i>IC</i>	49,9	55,5	43,7	50,8	52,9	53,1	48,4
<i>Limite Sup</i>	298,8	295,5	191,2	305,3	310,9	311,6	273,7
<i>Limite Inf</i>	199,0	184,5	103,8	203,7	205,2	205,4	177,0

Tabela 13. ANOVA da Variável Geométrica Área (m²)

<i>Fonte da variação</i>	SQ	gl	MQ	F	valor-P	F crítico
<i>Entre grupos</i>	460993,02	6	76832,17	2,3397	0,03	2,1255
<i>Dentro dos grupos</i>	11033315,34	336	32837,24			
<i>Total</i>	11494308,37	342				

Tabela 14. Estatística Descritiva da Variável Geométrica Perímetro (m).

	M1	M2	M4	M7	M8	M10	M11
<i>Tam (n)</i>	49,0	49,0	49,0	49,0	49,0	49,0	49,0
<i>Mínimo</i>	19,6	0,0	0,0	17,8	16,6	20,9	0,0
<i>Máximo</i>	165,4	130,2	114,7	132,7	135,4	135,2	111,2
<i>Variância</i>	680,8	702,3	979,7	507,5	495,0	508,2	508,9
<i>Amplitude</i>	145,8	130,2	114,7	114,8	118,7	114,3	111,2
<i>Média</i>	61,1	55,6	37,5	60,3	59,5	60,3	54,0
<i>DesvPad</i>	26,1	26,5	31,3	22,5	22,2	22,5	22,6
<i>Nível Signif</i>	0,1	0,1	0,1	0,1	0,1	0,1	0,1
<i>IC</i>	7,3	7,4	8,8	6,3	6,2	6,3	6,3
<i>Limite Sup</i>	68,5	63,0	46,3	66,6	65,7	66,6	60,3
<i>Limite Inf</i>	53,8	48,1	28,8	54,0	53,3	54,0	47,7

Tabela 15. ANOVA da Variável Geométrica Perímetro (m).

Fonte da variação	SQ	gl	MQ	F	valor-P	F crítico
<i>Entre grupos</i>	20554,73	6	3425,78	5,472	0,0000203	2,125
<i>Dentro dos grupos</i>	210355,39	336	626,057			
<i>Total</i>	230910,12	342				

8. REFERÊNCIAS BIBLIOGRÁFICAS

AGUILAR, F. J., RIVAS, J. R., NEMMAOUI, A., PEÑALVER, A., & AGUILAR, M. A. (2019). **UAV-Based Digital Terrain Model Generation under Leaf-Off Conditions to Support Teak Plantations Inventories in Tropical Dry Forests.** A Case of the Coastal Region of Ecuador. *Sensors*, 19(8), 1934.

ANDERSON, K., & GASTON, K. J. (2013). **Lightweight unmanned aerial vehicles will revolutionize spatial ecology.** *Frontiers in Ecology and the Environment*, 11(3), 138-146.

BALSAVIAS, E., GRUEN, A., EISENBEISS, H., and ZHANG, L. (2008). **Highquality image matching and automated generation of 3D tree models.** *International Journal of Remote Sensing*, Vol. 29: pp. 1243–1259.

BOLLES, RC; BAKER, HH; MARIMONT, DH. **Epipolar-plane image analysis: an approach to determining structure from motion.** *Int J Comput Vis.* 1987;1:7–55.

BOURGOIN, C., BLANC, L., BAILLY, J. S., CORNU, G., BERENQUER, E., OSZWALD, J., ... & GOND, V. (2018). **The potential of multisource remote sensing for mapping the biomass of a degraded Amazonian forest.** *Forests*, 9(6), 303.

BROWN, S., GILLESPIE, A. J., & LUGO, A. E. (1989). **Biomass estimation methods for tropical forests with applications to forest inventory data.** *Forest science*, 35(4), 881-902.

BUMA, B.; BARRETT, T. M. **Spatial and topographic trends in forest expansion and biomass change, from regional to local scales.** *Global Change Biology*, v. 21, n. 9, p. 3445-3454, Sep 2015. ISSN 1354-1013. Disponível em: < <Go to ISI>://WOS:000360998400023 >.

CHAMBERS, J. Q., ASNER, G. P., MORTON, D. C., ANDERSON, L. O., SAATCHI, S. S., ESPÍRITO-SANTO, F. D., ... & SOUZA Jr, C. (2007). **Regional ecosystem structure and function: ecological insights from remote sensing of tropical forests.** *Trends in Ecology & Evolution*, 22(8), 414-423.

CHAMBERS, J. Q., HIGUCHI, N., SCHIMEL, J. P., FERREIRA, L. V., & MELACK, J. M. (2000). **Decomposition and carbon cycling of dead trees in tropical forests of the central Amazon.** *Oecologia*, 122(3), 380-388.

CHAMBERS, J. Q., ROBERTSON, A., CARNEIRO, V. M. C., Lima, A. J., Smith, M. L., PLOURDE, L. C., *et al.* (2009). **Hyperspectral remote detection of niche partitioning among canopy trees drives by blowdowns gap disturbances in the Central Amazon.** *Oecologia*, 160, 107–117.

- COSTA, D.H.M. 2000. **Dinâmica da composição florística e crescimento de uma área de floresta de terra firme na flona do tapajós após a colheita de madeira.** Dissertação de Mestrado. Faculdade de Ciências Agrárias do Pará, Belém. 81pp.
- CUMMINGS, D. L., KAUFFMAN, J. B., PERRY, D. A., & HUGHES, R. F. (2002). **Aboveground biomass and structure of rainforests in the southwestern Brazilian Amazon.** *Forest Ecology and Management*, 163(1-3), 293-307.
- DA JIANG INNOVATIONS (DJI). DJI Phantom 4. Disponível Online: <https://www.dji.com/phantom-4/info> (acessado em 09 de outubro de 2019).
- DANDOIS, JP and ELLIS, EC. (2013). **High spatial resolution three-dimensional mapping of vegetation spectral dynamics using computer vision.** *Remote Sensing of Environment* 136: 259-276.
- DE AVIAÇÃO CIVIL, ANAC, **Regulamento Brasileiro. Especial–RBAC–E nº 94. Requisitos Gerais para Aeronaves Não Tripuladas de Uso Civil.** Resolução, n. 419, 2018.
- DOMINY, N. J., DUNCAN, B. (2011). **GPS and GIS Methods in an African Rain Forest: Applications to Tropical Ecology and Conservation.** *Ecology and Society*, Vol. 5, No. 2 > Art. 6
- ESPÍRITO-SANTO, F. D., GLOOR, M., KELLER, M., MALHI, Y., SAATCHI, S., NELSON, B., ... & PALACE, M. (2014). **Size and frequency of natural forest disturbances and the Amazon forest carbon balance.** *Nature communications*, 5, 3434.
- FIGUEIREDO, E. O., BRAZ, E. M., & d'OLIVEIRA, M. V. N. (2007). **Manejo de precisão em florestas tropicais: modelo digital de exploração florestal.** Rio Branco: Embrapa Acre.
- FILHO, B. S. (2000). **Interpretação de imagens da Terra. Apostila do Curso de Especialização em Geoprocessamento.** Belo Horizonte: UFMG.
- FONSTAD, M. A., DIETRICH, J. T., COURVILLE, B. C., JENSEN, J. L., & CARBONNEAU, P. E. (2013). **Topographic structure from motion: a new development in photogrammetric measurement.** *Earth Surface Processes and Landforms*, 38(4), 421-430.
- FONTES, C. G., CHAMBERS, J. Q., & HIGUCHI, N. (2018). **Revealing the causes and temporal distribution of tree mortality in Central Amazonia.** *Forest ecology and management*, 424, 177-183.
- FRANKL, A., STAL, C., ABRAHA, A., NYSSSEN, J., RIEKE-ZAPP, D., DE WULF, A., & POESEN, J. (2015). **Detailed recording of gully morphology in 3D through image-based modelling.** *Catena*, 127, 92-101.
- FURLEY, A. (2007) **Tropical forests of the Lowlands.** In: Veblen T; Kenneth RY, Antony RO (eds) *The physical geography of South America.* Oxford University Press, pp 135–157.
- GAMA, J.R.V.; BENTES-GAMA, M.M.; SCOLFORO, J.R.S. 2005. **Manejo sustentado para floresta de várzea na Amazônia oriental.** *Revista Árvore, Viçosa – MG*, 29(5): 719-729.
- GETZIN, S., WIEGAND, K., & SCHÖNING, I. (2012). **Assessing biodiversity in forests using very high-resolution images and unmanned aerial vehicles.** *Methods in ecology and evolution*, 3(2), 397-404.

- HARGITAI, H., WILLNER, K., & BUCHROITHNER, M. (2019). **Methods in planetary topographic mapping: a Review**. In *Planetary Cartography and GIS* (pp. 147-174). Springer, Cham.
- HASEGAWA, H., & YOSHIMURA, T. (2003). **Application of dual-frequency GPS receivers for static surveying under tree canopies**. *Journal of Forest Research*, 8(2), 0103-0110.
- HIGUCHI, N. 1994. **Utilização de Manejo dos Recursos Madeireiros das Florestas Tropicais Úmidas**. *Acta Amazônica*, 24(3-4): 275-288.
- HIGUCHI, N., SANTOS, J. D., RIBEIRO, R. J., FREITAS, J. D., VIEIRA, G., COIC, A., & MINETTE, L. J. (1997). **Crescimento e incremento de uma floresta amazônica de terra-firme manejada experimentalmente. MCT-INPA**. *Biomassa e nutrientes florestais—Relatório Final do Projeto Bionte*. Manaus, 89-131.
- HOPKINSON, C., CHASMER, L., BARR, A. G., KLJUN, N., BLACK, T. A., & MCCAUGHEY, J. H. M. (2016). **Monitoring boreal forest biomass and carbon storage change by integrating airborne laser scanning, biometry and eddy covariance data**. *Remote Sensing of Environment*, 181, 82–95. <https://doi.org/10.1016/j.rse.2016.04.010>.
- HOUGHTON, R.A.; HALL, F.; GOETZ, S.J. **Importance of biomass in the global carbon cycle**. *J Geophys. Res.* 2009, 114, 1–13.
- HUBBELL, S. P., FOSTER, R. B., O'BRIEN, S. T., HARMS, K., CONDIT, R., WECHSLER, B., WRIGHT, S. J., and DE LAO, S. L.: (1999) **Light-gap disturbances, recruitment limitation, and tree diversity in a neotropical forest**. *Science*, 283, 554–557.
- IGLHAUT, J., CABO, C., PULITI, S., PIERMATTEI, L., O'CONNOR, J., & ROSETTE, J. (2019). **Structure from motion photogrammetry in forestry: a review**. *Current Forestry Reports*, 5(3), 155-168.
- JARDIM, F. C. D. S., & HOSOKAWA, R. T. (1986/1987). **Estrutura da floresta equatorial úmida da estação experimental de silvicultura tropical do INPA**. *Acta Amazonica*, 17, 411-534.
- JAVERNICK L, BRASINGTON J and CARUSO B. (2014). **Modelling the topography of shallow braided rivers using Structure-from-Motion photogrammetry**. *Geomorphology* doi:10.1016/j.geomorph.2014.01.006
- KANGAS, A., & MALTAMO, M. (Eds.). (2006). **Forest inventory: methodology and applications** (Vol. 10). Springer Science & Business Media.
- KOENDERINK, JJ; VAN DOORN, AJ. **Affine structure from motion**. *J Opt Soc Am A*. 1991;8:377–85.
- LAURANCE, W. F., & CURRANT, T. J. (2008). **Impacts of wind disturbance on fragmented tropical forest: A review and synthesis**. *Australian Ecology*, 33, 399–408.
- LAURANCE, W. F., FERREIRA, L. V., MERONA, J. M., LAURANCE, S. G., HUTCHING, R., & LOVEJOY, J. E. (1998). **Effects of forest fragmentation on recruitment patterns in Amazonian tree communities**. *Conservation Biology*, 12, 460–464.
- LAWLEY, V., LEWIS, M., CLARKE, K., & OSTENDORF, B. (2016). **Site-based and remote sensing methods for monitoring indicators of vegetation condition: An Australian review**. *Ecological Indicators*, 60, 1273-1283.
- LEITÃO, M. D. M., SANTOS, J. M. D., & OLIVEIRA, G. M. D. (2002). **Estimativas do albedo em três ecossistemas da floresta amazônica**. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 6(2), 256-261.

LEBERL, F., IRSCHARA, A., POCK, T., MEIXNER, P., GRUBER, M., SCHOLZ, S., & WIECHERT, A. (2010). **Point clouds**. *Photogrammetric Engineering & Remote Sensing*, 76(10), 1123-1134.

LIEBERMANN, H., SCHULER, J., STRAGER, M. P., HENTZ, A. K., & MAXWELL, A. (2018). **Using Unmanned Aerial Systems for Deriving Forest Stand Characteristics in Mixed Hardwoods of West Virginia**. *Journal of Geospatial Applications in Natural Resources*, 2(1), 2.

LIMA, Adriano José Nogueira. **Avaliação de um sistema de inventário florestal contínuo em áreas manejadas e não manejadas do Estado do Amazonas (AM)**. (2010). 183 f. Tese (Doutorado em Manejo florestal, Silvicultura) - Instituto Nacional de Pesquisas da Amazônia, Manaus, 2010.

LLOYD, J., GLOOR, E. U., and LEWIS, S. L.: (2009) **Are the dynamics of tropical forests dominated by large and rare disturbance events?**. *Ecol. Lett.*, 12, E19–E21, doi:10.1111/j.14610248.2009.01326.

MALHI, Y., WOOD, D., BAKER, T. R., WRIGHT, J., PHILLIPS, O. L., COCHRANE, T., ... & HIGUCHI, N. (2006). **The regional variation of aboveground live biomass in old-growth Amazonian forests**. *Global Change Biology*, 12(7), 1107-1138.

MARRA, D. M., CHAMBERS, J. Q., HIGUCHI, N., TRUMBORE, S. E., RIBEIRO, G. H., DOS SANTOS, J., ... & WIRTH, C. (2014). **Large-scale wind disturbances promote tree diversity in a Central Amazon forest**. *PLoS One*, 9(8), e103711.

MCMAHON, S.M.; ARELLANO, G.; DAVIES, S.J. **The importance and challenges of detecting changes in forest mortality rates**. *Ecosphere*. 2019, Volume 10(2), Article e02615.

MICHELETTI, N., CHANDLER, J. H., & LANE, S. N. (2015). **Structure from motion (SfM) photogrammetry**. IN: Clarke, L.E. and Nield, J.M. (Eds.) *Geomorphological Techniques (Online Edition)*. London: British Society for Geomorphology. ISSN: 2047-0371, Chap. 2, Sec. 2.2.

MORAN, E. F., E. BRONDIZIO, P. MAUSEL, AND Y. WU. 1994. **Integrating Amazonian vegetation, land-use, and satellite data**. *Bioscience* 44: 329–338.

NEGRÓN-JUÁREZ, R. I.; CHAMBERS, J. Q.; MARRA, D. M.; RIBEIRO, G.H.P.M.; RIFAI, S. W.; HIGUCHI, N; ROBERTS, D. **Detection of subpixel treefall gaps with Landsat imagery in Central Amazon forests**. *Remote Sensing of Environment* 115 (2011) 3322–3328.

PACHAURI, R. K., ALLEN, M. R., BARROS, V. R., BROOME, J., CRAMER, W., CHRIST, R., ... & DUBASH, N. K. (2014). **Climate change 2014: synthesis report**. Contribution of Working Groups I, II and III to the fifth assessment report of the Intergovernmental Panel on Climate Change (p. 151). IPCC.

PALACE, M., KELLER, M., ASNER, G. P., HAGEN, S., & BRASWELL, B. (2007). **Amazon forest structure from IKONOS satellite data and the automated characterization of forest canopy properties**. *Biotropica*, 40(2), 141-150.

PÉLLICO NETTO, S., & BRENA, D. (1997). **Inventário Florestal**. v 1. Curitiba: editorado.

PHILLIPS, O. L., ARAGÃO, L. E., LEWIS, S. L., FISHER, J. B., LLOYD, J., LÓPEZ-GONZÁLEZ, G., ... & VAN DER HEIJDEN, G. (2009). **Drought sensitivity of the Amazon rainforest**. *Science*, 323(5919), 1344-1347.

PHILLIPS, O. L., LEWIS, S. L., BAKER, T. R., CHAO, K. J., & HIGUCHI, N. (2008). **The changing Amazon forest**. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 363(1498), 1819-1827.

PINTO, A. C. M.; HIGUCHI, N.; IIDA, S.; SANTOS, J.; RIBEIRO, R. J.; ROCHA, R. M.; SILVA, R. P. em HIGUCHI, N. *et al.* (2003). **Projeto Jacaranda, fase II: pesquisas florestais na Amazônia Central**. Coordenação de Pesquisas em Silvicultura Tropical, Instituto Nacional de Pesquisas da Amazônia.

PULITI, S., ØRKA, H., GOBAKKEN, T., & NÆSSET, E. (2015). **Inventory of small forest areas using an unmanned aerial system**. *Remote Sensing*, 7(8), 9632-9654.

RÉJOU-MÉCHAIN, M., BARBIER, N., COUTERON, P., PLOTON, P., VINCENT, G., HEROLD, M., ... & FÉRET, J. B. (2019). **Upscaling Forest biomass from field to satellite measurements: sources of errors and ways to reduce them**. *Surveys in Geophysics*, 1-31.

RIZZINI, C.T. (1997) **Tratado de Fitogeografia do Brasil - Aspectos sociológicos e florísticos**. 2nd edn. HUCITEC/EDUSP, São Paulo, 374 pp

RÖDIG, E., CUNTZ, M., HEINKE, J., RAMMIG, A., & HUTH, A. (2017). **Spatial heterogeneity of biomass and forest structure of the Amazon rain forest: Linking remote sensing, forest modelling and field inventory**. *Global ecology and biogeography*, 26(11), 1292-1302.

RUNNING, S. W. (2009). **Ecosystem disturbance, carbon, and climate**. *Science*, 321, 652–653.

RYAN JC, HUBBARD AL, BOX JE, TODD J, CHRISTOFFERSEN P, CARR JR, HOLT TO and SNOOKE N. (2015). **UAV photogrammetry and structure from motion to assess calving dynamics at Store Glacier, a large outlet draining the Greenland ice sheet**. *The Cryosphere* 9(1): 111.

SAATCHI, S. S., HOUGHTON, R. A., DOS SANTOS ALVALA, R. C., SOARES, J. V., & Yu, Y. (2007). **Distribution of aboveground live biomass in the Amazon basin**. *Global change biology*, 13(4), 816-837.

SANTOS, M. F., COSTA, D. L., MELO, L. O., & GAMA, J. R. V. (2018). **Estrutura, distribuição espacial e dinâmica florestal de duas espécies nativas após extração manejada de madeira na Flona do Tapajós**. *Advances in Forestry Science*, 5(2), 351-356.

SAWAGUCHI, I., SAITOH, Y., & TATSUKAWA, S. (2005). **A study of the effects of stems and canopies on the signal to noise ratio of GPS signals**. *Journal of Forest Research*, 10(5), 395-401.

SHANG, W., GAO, Z., JIANG, X., & CHEN, M. (2017, September). **The extraction of coastal windbreak forest information based on UAV remote sensing images**. In *Remote Sensing and Modeling of Ecosystems for Sustainability XIV* (Vol. 10405, p. 104050Q). International Society for Optics and Photonics.

SIZER, N. C., TANNER, E. V. J., & FERRAZ, K. I. D. (2000). **Edge effects on litterfall mass and nutrients concentrations in forest fragments in central Amazonia**. *Journal of Tropical Ecology*, 16, 853–863.

SILVA, R. P. D. (2007). **Alometria, estoque e dinâmica da biomassa de florestas primárias e secundárias na região de Manaus (AM)**. Tese (Doutorado em Manejo florestal, Silvicultura) - Instituto Nacional de Pesquisas da Amazônia, Manaus.

SKARLATOS, D., & KIPARISSIDES, A. (2012). **Comparison of laser scanning, photogrammetry and SFM-MVS pipeline applied in structures and artificial surfaces**. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume I-3.

SMITH, M. W., CARRIVICK, J. L., & QUINCEY, D. J. (2016). **Structure from motion photogrammetry in physical geography**. *Progress in Physical Geography*, 40(2), 247-275.

- STARK, S. C., ENQUIST, B. J., SALESKA, S. R., LEITOLD, V., SCHIETTI, J., LONGO, M., ... & OLIVEIRA, R. C. (2015). **Linking canopy leaf area and light environments with tree size distributions to explain Amazon forest demography**. *Ecology letters*, 18(7), 636-645.
- STARK, S. C., LEITOLD, V., Wu, J. L., HUNTER, M. O., de CASTILHO, C. V., COSTA, F. R., ... & KELLER, M. (2012). **Amazon forest carbon dynamics predicted by profiles of canopy leaf area and light environment**. *Ecology letters*, 15(12), 1406-1414.
- STEININGER, M. 1996. **Tropical secondary forest regrowth in the Amazon: Age, area, and change estimation with Thematic Mapper**. *Int. J. Remote Sens.* 17(1): 9–2.
- TANG, L. N.; SHAO, G. F. (2015). **Drone remote sensing for forestry research and practices**. *Journal of Forestry Research*, v. 26, n. 4, p. 791-797. ISSN 1007-662X. Disponível em: < <Go to ISI>://WOS:000363255100001 >.
- TOWNSHEND, J. R. G., (1980), *The spatial resolving power of earth resources satellites: a review*, NASA Goodard Space Flight Center TM 82020, Greenbelt, MD.
- TOMMASELLI, A. M. (2009). **Fotogrametria básica**. *Presidente Prudente: UNESP*.
- TURNER, D., LUCIEER, A., & WATSON, C. (2012). **An automated technique for generating georectified mosaics from ultra-high resolution unmanned aerial vehicle (UAV) imagery, based on structure from motion (SfM) point clouds**. *Remote sensing*, 4(5), 1392-1410.
- VIDAL, C.; LANZ, A.; TOMPPPO, E.; SCHADAUER, K.; GSCHWANTNER, T.; Di COSMO, L.; ROBERT, N. (2008). **Establishing forest inventory reference definitions for forest and growing stock: a study towards common reporting**. *Silva Fennica* 42: 247–266.
- WESTOBY, MJ; BRASINGTON, J; GLASSER, NF; HAMBREY, MJ. Reynolds JM. **“Structure-from-motion” photogrammetry: a low-cost, effective tool for geoscience applications**. *Geomorphology*. 2012;179: 300–14.
- WHITE O.L., SCHENK P.M., NIMMO F. et al (2014) **A new stereo topographic map of Io: implications 950 for geology from global to local scales**. *J Geophys Res Planets* 119:1276–1301. <https://doi.org/10.1002/2013JE004591>.
- WHITE, J. C., COOPS, N. C., WULDER, M. A., VASTARANTA, M., HILKER, T., & TOMPALSKI, P. (2016). **Remote sensing technologies for enhancing forest inventories: A review**. *Canadian Journal of Remote Sensing*, 42(5), 619-641.
- WHITE, J. C., WULDER, M. A., VASTARANTA, M., COOPS, N. C., PITT, D., & WOODS, M. (2013). **The utility of image-based point clouds for forest inventory: A comparison with airborne laser scanning**. *Forests*, 4(3), 518-536.
- WHITMORE, T. (1989) **Canopy gaps and the two major groups of forest trees**, *Ecology*, 70, 536–538.
- WING, M. G., & EKLUND, A. (2007). **Performance comparison of a low-cost mapping grade global positioning systems (GPS) receiver and consumer grade GPS receiver under dense forest canopy**. *Journal of Forestry*, 105(1), 9-14.