

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS E TECNOLOGIA PARA A SUSTENTABILIDADE
PROGRAMA DE PÓS-GRADUAÇÃO EM PLANEJAMENTO E USO DOS RECURSOS
RENOVÁVEIS

Melodie Kern Sarubo Dorth

**USO DE RPAS NO MONITORAMENTO DE RESTAURAÇÃO FLORESTAL:
ACURÁCIA POSICIONAL DE PRODUTOS RGB E LIDAR**

Sorocaba

2025

Melodie Kern Sarubo Dorth

**USO DE RPAS NO MONITORAMENTO DE RESTAURAÇÃO FLORESTAL:
ACURÁCIA POSICIONAL DE PRODUTOS RGB E LIDAR**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Planejamento e Uso de Recursos Renováveis para obtenção do título de Doutor em Planejamento e Uso de Recursos Renováveis.

Orientação: Prof. Dr. Paulo Guilherme Molin

Sorocaba

2025

Dorth, Melodie Kern Sarubo

Uso de RPAS no monitoramento de restauração florestal:
acurácia posicional de produtos RGB e LiDAR / Melodie
Kern Sarubo Dorth -- 2025.
165f.

Tese de Doutorado - Universidade Federal de São Carlos,
campus Sorocaba, Sorocaba

Orientador (a): Paulo Guilherme Molin

Banca Examinadora: Ana Claudia dos Santos Luciano,
Angelica Faria de Resende, Catherine Torres de Almeida,
Vinicius Rodrigues Tonetti

Bibliografia

1. Acurácia. 2. GNSS. 3. RPAS e sensores RGB e LiDAR.
I. Dorth, Melodie Kern Sarubo. II. Título.

Ficha catalográfica desenvolvida pela Secretaria Geral de Informática
(SIn)

DADOS FORNECIDOS PELO AUTOR

Bibliotecário responsável: Maria Aparecida de Lourdes Mariano -
CRB/8 6979



UNIVERSIDADE FEDERAL DE SÃO CARLOS

Centro de Ciências e Tecnologias Para a Sustentabilidade
Programa de Pós-Graduação em Planejamento e Uso de Recursos Renováveis

Folha de Aprovação

Defesa de Tese de Doutorado da candidata Melodie Kern Sarubo Dorth Sinegalia, realizada em 10/03/2025.

Comissão Julgadora:

Prof. Dr. Paulo Guilherme Molin (UFSCar)

Profa. Dra. Catherine Torres de Almeida (UFPR)

Profa. Dra. Angélica Faria de Resende (USP)

Prof. Dr. Vinicius Rodrigues Tonetti (UFSCar)

Profa. Dra. Ana Cláudia dos Santos Luciano (USP)

O Relatório de Defesa assinado pelos membros da Comissão Julgadora encontra-se arquivado junto ao Programa de Pós-Graduação em Planejamento e Uso de Recursos Renováveis.

AGRADECIMENTOS

Sem dúvida, este doutorado foi uma das escolhas mais loucas (e incríveis) da minha vida... Uma Melodie começou, e outra, mais forte (também mais abatida), o está finalizando.

Passei por transformações boas e ruins, tive que me reinventar de muitas maneiras, em muitas formas... Tive que me descobrir, redescobrir, perdoar, aceitar... Mas que bom que o dinamismo da vida, Deus, minha família e amigos estiveram comigo.

Meus filhos, tudo que faço, tudo que vivo, é por vocês e para vocês... “Ano passado eu morri, esse ano, não morro mais”... e não morro, a não ser por vocês.

Meus pais e irmãos: não sei mesmo se teria conseguido chegar até aqui sem vocês... na verdade, eu sei, e não, não teria... Assim como minhas avós, cunhada, primas, tias e tios... sem vocês, essa caminhada não teria sido possível.

E tem as pessoas especiais, que não são “família”, se avaliarmos árvore genealógica, mas que seguraram minha mão, estiveram na trincheira ao meu lado, sem nunca me abandonar: Mayla, Carol, Paloma, Fer, Pablo, Marlene, Chiari, Marcela, Camila, Kris, Miriam, Vitor, Elaine e Thiago, entre tantos outros (perdoem se esqueci alguém, tô emocionada, rss).

Não deixaria jamais de mencionar as pessoas que vieram “em demandas acadêmicas”, mas que viraram “minhas crianças”, e que, definitivamente, sem a raça, ajuda, comprometimento, empatia, amizade e amor, eu JAMAIS estaria no final dessa jornada: Péti, Vininho, Zéh, Gih, Bia, Kill, Furbyinha, Vini, Giulinho (e Mari) e Felipe.

Há também os amigos e pesquisadores que conheci ao longo deste trajeto, e que me ajudaram, elucidaram e até acalmaram, e que, direta ou indiretamente, contribuíram pra este trabalho: Cathe e Zé, Gel, Danilo, Papa, Sílvia, Brancalion, Toledo, Viani e Adriana.

Agradeço imensamente aos meus professores e a todos do meu departamento PPGPUR na UFSCAR Sorocaba por toda ajuda e aprendizado... Principalmente agradeço à Luciana por SEMPRE nos ajudar em tudo... Lu, você é daquelas pessoas que faz seu trabalho tão bem, e vai tão além, que admiramos como profissional, e, sobretudo, como SER humano. Você é incrível! Há ainda a Re.Green que propiciou que os campos do estudo de caso fossem possíveis. Obrigada por acreditarem na pesquisa!

E, por último, mas de importância ÍMPAR, agradeço meu orientador. Guilherme, obrigada por acreditar em mim, por me cobrar (às vezes podia ser menos), por me incentivar (também podia ser menos, porque fui acreditando em você e fui indo, hahaha) e pela tua amizade. Foi/é um prazer ser tua orientada, amiga e pesquisadora do teu círculo.

E viva a acurácia!

RESUMO

Devido às mudanças globais impulsionadas por emissões de gases de efeito estufa e alterações no uso da terra, é crucial conservar e restaurar ecossistemas florestais para mitigar esses impactos por meio do sequestro de carbono, proteção da biodiversidade e oferta de serviços ambientais. Nesse cenário, tecnologias acessíveis e econômicas de monitoramento, como o uso de drones e sensores, surgem como alternativas promissoras para complementar a coleta de dados em campo e reduzir custos. Contudo, desafios permanecem, especialmente relacionados à qualidade posicional das coordenadas, o que demanda estratégias como otimização do tempo de coleta, escolha adequada de técnicas, sensores e parâmetros de voo, além da implantação de pontos de controle para corrigir distorções geométricas e melhorar a precisão espacial. Adicionalmente, limitações do sistema GNSS (Sistema de Navegação Global por Satélites, do inglês, “*Global Navigation Satellite System*”) e a ausência de informações sobre a acurácia dos dados ressaltam a necessidade de medidas complementares para aprimorar a confiabilidade dos levantamentos. Esta tese teve como objetivo avaliar a acurácia posicional de produtos RGB (Vermelho-Verde-Azul, do inglês “*Red-Green-Blue*”) e LiDAR (Detecção e Medição por pulsos de Luz, do inglês, “*Light Detection And Ranging*”), considerando a inserção de pontos de controle no processamento. Visando atender os objetivos, na etapa 1 foi implantada a Rede Cepegeo, composta por quinze vértices em ambientes variados, com levantamentos realizados por técnicas convencionais de topografia e geodésia. Os dados obtidos foram ajustados e organizados em memoriais descritivos. Em seguida, na 2 etapa, foi realizada uma avaliação das metodologias GNSS, considerando tempos de rastreamento e diferentes cenários, incluindo áreas adjacentes a florestas e ambientes mais desafiadores como próximos à corpos d’água ou edificações. A análise das metodologias GNSS mostrou que as técnicas relativo estático e PPP (mínimo de 30 minutos) alcançaram acurácia de 10,1 a 30 cm em áreas abertas e florestas de baixa densidade. Em florestas densas, a acurácia variou entre 50,1 e 80 cm, evidenciando o impacto do dossel na qualidade do sinal. No componente altimétrico, nenhuma metodologia GNSS obteve acurácia compatível com os ajustes. A metodologia relativo estático apresentou os melhores resultados em precisão e qualidade posicional, destacando-se como a mais eficiente para levantamentos em diferentes cenários. Na 3 etapa, visando avaliar a acurácia dos produtos gerados por RPAS equipados com sensores RGB e LiDAR em uma área de restauração florestal, foram implantados 90 pontos de controle, tanto horizontais quanto verticais, cujas coordenadas foram obtidas por GNSS de dupla frequência, estação total e nível geométrico. Em seguida, foram realizados voos com drones equipados com sensores RGB e LiDAR, e os dados foram processados em softwares comerciais, utilizando as ferramentas de livre acesso

disponibilizadas pelos mesmos. No que diz respeito aos dados oriundos do sensor RGB, foram gerados ortomosaicos e modelos digitais de elevação considerando diferentes números de pontos de controle no processamento. Os resultados mostraram que a precisão dos produtos RGB apresentou qualidade “ótima” com 4 pontos de controle, enquanto a inclusão de mais de 50 pontos ocasionou overfitting, reduzindo a acurácia em algumas áreas. No caso dos produtos LiDAR, foi efetuada a classificação das nuvens de pontos LiDAR bem como a geração de modelos de altura do dossel. A análise planimétrica evidenciou um deslocamento médio de 1,2 m quando os dados foram processados sem correção por base RTK, além de pequenas deformações na região central do modelo. Já a avaliação do componente altimétrico indicou que a qualidade posicional dos dados LiDAR não pode ser considerada de forma absoluta, devido às variações introduzidas pela combinação de sensor e software, especialmente nas correções das geotags. Este trabalho apresenta uma abordagem inovadora ao avaliar a acurácia dos produtos gerados por sensores RGB e LiDAR, além de analisar a acurácia dos próprios pontos de controle empregados para aprimorar a qualidade posicional dos produtos. A integração de RPAS equipados com esses sensores, combinada ao uso de pontos de controle geodésicos e técnicas avançadas de processamento, revelou-se uma estratégia eficaz para o mapeamento e a análise de áreas em restauração florestal. A escolha criteriosa e o equilíbrio na distribuição dos GCPs, aliados às correções via RTK, são fundamentais para garantir a alta qualidade posicional dos produtos. Embora desafios como o excesso de pontos e a necessidade de ajustes nos dados LiDAR exijam um planejamento meticuloso, a combinação dessas tecnologias potencializa a eficiência e a robustez dos levantamentos ambientais. Recomenda-se a realização de novos estudos com variações nas alturas de voo e a utilização de sensores mais avançados, especialmente no que diz respeito ao LiDAR, bem como a adoção de versões premium dos softwares de processamento para aprimorar ainda mais os resultados.

Palavras-chave: Aerofotogrametria; Drone; Restauração Ecológica; Qualidade Posicional; Sensoriamento remoto; UAS; UAV; Pontos de controle

ABSTRACT

Due to global changes driven by greenhouse gas emissions and land use alterations, the conservation and restoration of forest ecosystems are essential to mitigate these impacts through carbon sequestration, biodiversity protection, and the provision of ecosystem services. In this context, accessible and cost-effective monitoring technologies—such as the use of drones and sensors—emerge as promising alternatives to complement field data collection and reduce associated costs. However, several challenges remain, particularly regarding the positional quality of geospatial data, which necessitates strategies such as optimizing data acquisition timing, selecting appropriate techniques, sensors, and flight parameters, as well as implementing control points to correct geometric distortions and enhance spatial accuracy. Additionally, limitations of the GNSS (Global Navigation Satellite System) and the lack of accuracy information underscore the need for complementary measures to improve the reliability of geospatial surveys. This thesis aimed to evaluate the positional accuracy of RGB (Red-Green-Blue) and LiDAR (Light Detection and Ranging) products, considering the integration of ground control points (GCPs) during data processing. To meet this objective, the first stage involved the establishment of the Cepegeo Network, comprising fifteen geodetic control points across diverse environments, surveyed using conventional topographic and geodetic methods. The collected data were adjusted and compiled into descriptive reports. In the second stage, GNSS methodologies were evaluated based on tracking duration and environmental scenarios, including areas adjacent to forests and more challenging environments, such as near water bodies or buildings. The analysis revealed that the relative static and Precise Point Positioning (PPP) techniques (with a minimum tracking time of 30 minutes) achieved accuracies ranging from 10.1 to 30 cm in open areas and low-density forests. In dense forests, accuracy decreased, ranging from 50.1 to 80 cm, highlighting the canopy's impact on signal quality. Regarding vertical accuracy, none of the GNSS methodologies achieved results compatible with geodetic adjustments. Among them, the relative static technique delivered the best performance in terms of positional precision and reliability, establishing itself as the most effective for surveys under varied conditions. The third stage focused on assessing the accuracy of products generated by RPAS (Remotely Piloted Aircraft Systems) equipped with RGB and LiDAR sensors over a forest restoration site. A total of 90 control points, both horizontal and vertical, were established using dual-frequency GNSS receivers, total stations, and differential leveling. Subsequent drone flights were conducted using RGB and LiDAR-equipped systems, and the data were processed in commercial software platforms utilizing their open-access tools. For the RGB-derived data, orthomosaics and digital

elevation models were generated with varying numbers of GCPs. Results indicated that RGB product accuracy was rated as “optimal” when four GCPs were used, while the inclusion of more than 50 GCPs led to overfitting, resulting in reduced accuracy in certain areas. Regarding the LiDAR products, point cloud classification and canopy height model generation were performed. Planimetric analysis revealed an average horizontal displacement of 1.2 meters when data were processed without RTK base station corrections, along with minor deformations in the central area of the model. The evaluation of vertical accuracy suggested that the positional quality of LiDAR data cannot be considered absolute, given the variations introduced by sensor-software interactions, particularly in geotag correction processes. This research presents an innovative approach by evaluating the accuracy of products generated by RGB and LiDAR sensors, as well as analyzing the accuracy of the control points themselves used to enhance product precision. The integration of RPAS with these sensors, in conjunction with geodetic GCPs and advanced processing techniques, proved to be an effective strategy for mapping and analyzing forest restoration areas. The careful selection and balanced distribution of GCPs, along with RTK-based corrections, are critical to ensuring high positional quality. Although challenges such as GCP oversaturation and LiDAR data adjustments require meticulous planning, the combined use of these technologies enhances the efficiency and robustness of environmental surveys. Further research is recommended, including varying flight altitudes and the deployment of more advanced sensors—particularly for LiDAR—as well as the use of premium software versions to further improve the outcomes.

Keywords: Aerial Photogrammetry; Drone; Ecological Restoration; Photogrammetry; Positional Quality; Remote Sensing; UAS; UAV; Control Points.

LISTA DE FIGURAS

Figure 1: Workflow of the selection of articles that compose this SRL.....	32
Figure 2: Authors with the highest number of publications using the chosen terms.	35
Figura 3: Metodologia – Visão Geral.	59
Figura 4: Planta de situação da Rede Cepegeo.	68
Figura 5: Delineamento geral da metodologia.	70
Figura 6: Vértice CP01 da Rede Cepegeo.	74
Figura 7: Localização dos vértices da Rede Cepegeo.	74
Figura 8: Memorial Descritivo CP01.	76
Figura 9: General outline.	93
Figura 10: Study Area.	94
Figura 11: Precision vs. Accuracy of CP01 Coordinates.	100
Figura 12: Scatter Plot of Planimetric Coordinates for CP01.	101
Figura 13: Scatter Plot of Planimetric Coordinates for CP02.	101
Figura 14: Scatter Plot of Planimetric Coordinates for CP09.	102
Figura 15: Área de estudo localizada na UFSCAR – campus Araras.	121
Figura 16: GCP materializado na área de estudo.	123
Figura 17: Projeto técnico de concepção dos VCPs.	123
Figura 18: VCP materializado na área de estudo.	123
Figura 19: Pontos de controle espacialmente distribuídos na área de estudo.	126
Figura 20: Pontos de referência no CHM gerado utilizando RTK com pós-processamento.	128
Figura 21: RPs distribuídos espacialmente na área de estudo.	129
Figura 22: Ortomosaico para o cenário com 4 GCPs.	133
Figura 23: DTM para o cenário com 4 GCPs.	133
Figura 24: Comparativo polígono coordenadas homologadas x cenário sem GCPs.	138
Figura 25: Comparativo polígono coordenadas homologadas x cenário com 4 GCPs.	138
Figura 26: Nuvem de pontos obtida à partir de dados LiDAR com pós-processamento.	140
Figura 27: CHM de 20 cm obtido à partir de dados LiDAR.	140
Figura 28: Comparativo entre o polígono obtido à partir das coordenadas planimétricas advindas do produto com correção da base RTK e sem a correção da base.	144

LISTA DE TABELAS

Table 1: Categories used for article classification.....	34
Table 2: Absolute and relative frequencies of assessed forest attributes.	36
Table 3: Absolute frequencies of the considered indicator.	37
Table 4: Absolute and relative frequencies of Sensors used.	38
Table 5: Articles that composed this review and used RPAs and sensors in restoration monitoring.	39
Table 6: Results found in articles focusing on restoration monitoring.	40
Tabela 7: Vértices da Rede Cepegeo e as condições físicas dos mesmos, bem como principal fator que pode ocasionar erros quando efetua-se levantamentos utilizando GNSS.	71
Tabela 8: Coordenadas oriundas do posicionamento relativo com GNSS para o CP01.	75
Tabela 9: Coordenadas UTM CP01 e CP20 homologadas.	75
Tabela 10: Coordenadas obtidas através por poligonação, com cálculo manual e via Topcon Link.....	77
Tabela 11: Coordenadas UTM homologadas Rede Cepegeo.....	78
Table 12: Vertices of the Cepegeo Network adopted and the influencing factor considered. .	95
Table 13: oordinates, Precisions, and Techniques - Vertex CP01.....	97
Table 14: Classes and Considered Dispersion.....	98
Table 15: Accuracy Table – Planimetry.	98
Table 16: Accuracy Table – Altimetry.	99
Tabela 17: Coordenadas homologadas dos pontos de controle.	130
Tabela 18: Coordenadas homologadas, e nos cenários sem GCPs e com 4 GCPs, além do ME e RMSE dos mesmos.....	134
Tabela 19: ME e RMSE obtidos em cada um dos cenários deste estudo para as coordenadas E.	136
Tabela 20: ME e RMSE obtidos em cada um dos cenários deste estudo para as coordenadas N.	137
Tabela 21: ME e RMSE obtidos em cada um dos cenários deste estudo para as coordenadas Z.	137
Tabela 22: Tabela de Acurácia RGB, componente planimétrico.	139
Tabela 23: Tabela de Acurácia RGB, componente altimétrico.	139

Tabela 24: Métricas estatísticas obtidas em cada um dos cenários deste estudo para as coordenadas E..... 141

Tabela 25: Métricas estatísticas obtidas em cada um dos cenários deste estudo para as coordenadas E..... 141

Tabela 26: Distâncias geométricas entre os RPs para ambos os cenários. 142

Tabela 27: Alturas dos VCPs de 1 m medidas geometricamente e através dos CHM. 142

Tabela 28: Alturas dos VCPs de 2 m medidas geometricamente e através dos CHM. 143

Tabela 29: Alturas dos VCPs de 3 m medidas geometricamente e através dos CHM. 143

Tabela 30: Alturas dos TCPs obtidas geometricamente, por clinômetro, vertéx e pelos CHM. 143

LISTA DE SIGLAS

AGB - Biomassa acima do solo (do inglês *aboveground biomass*)

CePE-Geo - Centro de Pesquisa e Extensão em Geotecnologias

CHM - Modelo de altura do dossel (do inglês, *Canopy Height Model*)

CONCAR - Conselho Nacional de Cartografia

DSM - Modelo digital de superfície (do inglês, *Digital Surface Model*)

DTM - Modelo digital de terreno (do inglês, *Digital Terrain Model*)

EP - Erro-Padrão

ET-ADGV - Especificações Técnicas para Aquisição de Dados Geoespaciais Vetoriais

GCP – pontos de controle em terra (do inglês, *Ground Control Points*)

GNSS - Sistemas Globais de Navegação por Satélite (do inglês, *Global Navigation Satellite System*)

GSD - distância de amostragem do solo (do inglês, *Ground Sampling Distance*)

IBGE - Instituto Brasileiro de Geografia e Estatística

IMU - Unidade de Medição Inercial (do inglês *Inertial Measurement Unit*)

INCRA - Instituto nacional de Colonização e reforma agrária

ITC - Delineamento individual da copa das árvores (do inglês *Individual Tree Crown*)

LiDAR (do inglês, *Light Detection And Ranging*)

MMQ – Método dos Mínimos Quadrados

NBR – Norma Brasileira

ONU – Organização das Nações Unidas

PEC - Padrão de Exatidão Cartográfica

PEC-PCD - Padrão de Exatidão Cartográfica para Produtos Cartográficos Digitais

PPP – Posicionamento por ponto preciso

PPS – Posicionamento por ponto simples

RBMC - Rede Brasileira de Monitoramento Contínuo

RGB (do inglês, *Red-Green-Blue*)

RPAS - Sistemas de Aeronaves Pilotadas Remotamente (do inglês, *Remotely Piloted Aircraft Systems*)

RTK – Cinemático em tempo real (do inglês, *Real Time Kinematic*)

SAG – Relativo Estático-Rápido, também denominado *Stop-and-go*

SER - Sociedade da Restauração Ecológica (do inglês *Society for Ecological Restoration*)

SfM - Estrutura do Movimento (do inglês *Structure from Motion*)

SIGEF - Sistema de Gestão Fundiária

UAS - Sistema de aeronave não tripulada (do inglês, *Unmanned Aircraft System*)

UAV – Veículo aéreo não tripulado (do inglês, *Unmanned Aerial Vehicle*)

UFSCAR - Universidade Federal de São Carlos

SUMÁRIO

1. INTRODUÇÃO	14
1.1 Contextualização	14
1.2 Questão Norteadora	18
1.3 Hipótese.....	18
1.4 Objetivos	18
1.4.1 <i>Objetivo Geral</i>	18
1.4.2 <i>Objetivos Específicos</i>	18
1.5 Estrutura da tese	19
Literatura Citada	20
 2. SYSTEMATIC LITERATURE REVIEW: HOW HAVE RPAS HELPED MONITOR FORESTS AND WHAT CAN WE APPLY IN FOREST RESTORATION MONITORING?.....	 27
ABSTRACT	27
Implications for Practice.....	27
2.1 Introduction.....	28
2.2 Methodology.....	30
2.2.1 Mapping the information landscape through scientific evidence.....	32
2.2.2 Current state of the art.....	33
2.3 Results	34
2.4 Discussion	41
2.4.1 Mapping the information landscape through scientific evidence.....	41
2.4.2 Current state of the art.....	42
2.5 Final Considerations	48
Literature Cited	49
 3. DELINEAMENTO DA PESQUISA: VISÃO GERAL.....	 57
 4. CONECTANDO PAISAGENS: IMPLANTAÇÃO DE UMA REDE GEODÉSICA MATERIALIZADA EM AMBIENTES IDEAIS, FLORESTAIS E DIVERSOS.....	 60
RESUMO.....	60
4.1 Introdução	61
4.2 Materiais e Métodos	68
4.2.1 Área de estudo	68
4.2.2 Materiais	69

4.2.3 Metodologia – delineamento geral	69
4.3 Resultados	73
4.3.1 Materialização da Rede	73
4.3.2 Coordenadas dos vértices de referência	74
4.4 Discussão	78
4.5 Conclusão	81
Literatura Citada	82

5. LOOK DOWN: TO WHAT EXTENT DOES THE PRECISION OF GROUND CONTROL POINTS REFLECT THEIR ACCURACY?89

ABSTRACT	89
5.1 Introduction	89
5.2 Methods	93
5.2.1 Design: Overview	93
5.2.2 Study Area	93
5.2.3 Methodology	94
5.2.4 Accuracy Table	97
5.2.5 Precision x Accuracy	97
5.3 Results	97
5.3.1 Coordinates and Precisions Obtained in the Surveys	97
5.3.2 Accuracy Table	98
5.3.3 Precision x Accuracy	100
5.4 Discussion of results	102
5.4.1 Coordinates from the surveys and Accuracy Table	102
5.4.2 Precision x Accuracy	103
5.4.3 Implications in the Context of Forest Restoration Monitoring	104
5.5 Recommendations for Future Work	108
5.6 Final Considerations	108
Literature Cited	109

6. ACURÁCIA POSICIONAL DE PRODUTOS RGB E LIDAR: UM ESTUDO DE CASO EM ARARAS-SP116

RESUMO	116
ABSTRACT	117
6.1 Introdução	118
6.2 Metodologia	120
6.2.1 Área de estudo	120
6.2.2 Metodologia	122

6.3 Resultados	130
6.3.1 Pontos de Controle.....	130
6.3.2 RGB.....	132
6.3.3 LiDAR.....	139
6.4 Discussão.....	144
6.4.1 Coordenadas homologadas dos GCPs, VCPs e TCPs	145
6.4.2 RGB	145
6.4.3 LiDAR.....	148
6.5 Considerações finais	153
Literatura Citada	154
 7. CONSIDERAÇÕES FINAIS.....	 162
 ANEXO 1.....	 165

1. INTRODUÇÃO

1.1 Contextualização

Enquanto mudanças climáticas sem precedentes estão ocorrendo em escala global, principalmente devido às emissões de carbono causadas pelo ser humano, e enquanto a grande maioria dos indicadores de ecossistemas e biodiversidade está apresentando um rápido declínio, torna-se primordial restaurar e preservar as florestas, com o intuito de mitigar as alterações climáticas e a perda de biodiversidade (Dupuis et al. 2020). Recentemente, a Organização das Nações Unidas (ONU) apelaram a todos os setores da sociedade para que se mobilizassem para uma década de ação, designando o período de 2021 a 2030 como a Década da Restauração onde mais de 60 nações, em consonância com o Desafio de Bonn, assumiram o compromisso de restaurar mais de 200 milhões de hectares de paisagens florestais até 2030 (Brancalion et al. 2019; Tedesco et al. 2023).

O reconhecimento do potencial da restauração de ecossistemas para enfrentar desafios urgentes envolve tanto ações ativas, como o plantio de mudas, quanto estratégias passivas (Rodrigues et al. 2009). Por isso, é fundamental a avaliação contínua dos métodos empregados, permitindo monitorar a recuperação da área, identificar perturbações e implementar medidas corretivas de manejo ou replantio, o que contribui para aprimorar técnicas existentes e orientar novos estudos (Brancalion et al. 2015; Evans 2018; Almeida et al. 2019).

Em um cenário de crescentes demandas sobre os recursos florestais, o monitoramento dos estoques de carbono e da biodiversidade exige ferramentas precisas e com frequência temporal adequada (Patias et al. 2017). Além disso, compreender a dinâmica de longo prazo das florestas é essencial para o planejamento e a gestão sustentável desses ecossistemas, e o sensoriamento remoto se destaca como um meio poderoso para análise, síntese e geração de relatórios que embasam decisões importantes (Gómez et al. 2019).

Dessa forma, o monitoramento de áreas em processo de restauração permite obter dados confiáveis sobre a evolução da vegetação, identificar falhas no reflorestamento e avaliar a eficácia das técnicas empregadas, sendo crucial também para prognósticos de produção florestal a longo prazo e para a compreensão dos ecossistemas florestais tropicais, por meio de técnicas de amostragem que revelam indicadores-chave da ecologia (Tao et al. 2014; d'Oliveira et al. 2021; Valbuena et al. 2017).

O "Guia Inicial para Introdução à Sociedade da Restauração Ecológica" (SER) apresenta orientações essenciais para o planejamento de projetos de restauração, fornecendo uma lista de atributos críticos que englobam a estrutura da vegetação, a composição e os processos ecológicos. Esses atributos auxiliam na identificação de indicadores de êxito (Wortley et al.

2013; Ruiz-Jaen & Aide 2005; Noss 1990; Franklin et al. 1981). Por exemplo, no monitoramento do estoque de carbono, a obtenção de estimativas precisas da biomassa acima do solo (AGB) e a avaliação da diversidade de espécies são fundamentais (d'Oliveira et al. 2021; Sinegalia et al. 2023).

Entretanto, um desafio crítico é o desenvolvimento de protocolos de monitoramento replicáveis e economicamente viáveis em escalas de milhões de hectares, visto que as avaliações tradicionais dependem de coletas de dados em parcelas de campo, métodos que ainda implicam custos significativos (Holl & Aide 2011). Nesse contexto, o advento dos Sistemas de Aeronaves Pilotadas Remotamente (RPAS, do inglês, *Remotely Piloted Aircraft System*), e de uma ampla gama de sensores capazes de gerar imagens de alta resolução, possibilitou o desenvolvimento de novas abordagens provenientes de sensoriamento remoto e aerofotogrametria (Berra & Peppia 2020), permitindo complementar a coleta de dados em campo, proporcionando redução de custos e fornecendo informações precisas das extensões espaciais das florestas, composição de espécies, características fisiológicas, bem como mudanças na cobertura florestal, e conteúdo de carbono. Além disso, possibilita um aumento significativo na avaliação do desempenho das técnicas e produtos em várias escalas, (Gyamfi-Ampadu et al. 2021; White et al. 2017).

Apesar da alta confiabilidade do LiDAR para estimativas precisas, seus custos elevados limitam sua aplicação em grandes áreas. seus altos custos de aquisição dificultam o monitoramento de grandes áreas (Ota et al. 2015; Corte et al. 2020). Em contrapartida RPAS com sensores RGB embarcados são caracterizadas pelo baixo custo e um excelente compromisso entre resolução e escala, permitindo gerar produtos de alta precisão, como mapas, ortoimagens, nuvens de pontos e modelos digitais de superfície ou terreno (Ota et al. 2015; Ocalan et al. 2022). A precisão desses produtos depende das especificações técnicas dos sensores—tais como câmeras digitais, receptores GNSS e componentes da Unidade de Medição Inercial (IMU)—além da técnica de processamento adotada (Maesano et al. 2022; Ocalan et al. 2022).

A qualidade dos produtos finais—como DTMs, DSMs e ortomosaicos—está diretamente relacionada à abordagem adotada na aquisição das imagens, tendo a resolução espacial (GSD, do inglês *Ground Sampling Distance*) como fator crucial para o sucesso do processamento (Szypuła 2023; Singh et al. 2023). A GSD é influenciada por diversos fatores, incluindo a altura e trajetória do voo, o sensor utilizado, as condições de iluminação e a cobertura da superfície do terreno. Além disso, a precisão do modelo resultante depende da

inclinação da câmera, da sobreposição de imagens, do método de calibração e do software empregado no processamento (Szypuła 2023).

O avanço na ciência da computação, especialmente com a abordagem *Structure from Motion* (SfM), tem permitido a produção de DSMs de alta qualidade a partir de fotografias sobrepostas. Essa técnica, que utiliza métodos automatizados de visão computacional para gerar modelos 3D, demonstrou ser satisfatória para o mapeamento topográfico (Fonstad et al. 2013; Turner et al. 2015; Lucieer et al. 2014; Niethammer et al. 2011; Ota et al. 2015). Contudo, em áreas com alta variação topográfica, a obtenção de DTMs precisos continua sendo essencial para a produção de modelos precisos de AGB e para análises 3D, podendo requerer medidas adicionais para melhorar a qualidade dos dados (Singh et al. 2023).

Os dados derivados da aerofotogrametria apresentam diversas vantagens em termos de escala e eficiência, entretanto, a detecção precisa do solo em florestas tropicais densas, necessária para a estimativa da altura do dossel, continua sendo um desafio significativo (Zhang 2021), onde a falta de precisão pode ocasionar problemas sérios, como a subestimação ou superestimação da cobertura vegetal, o que dificulta a análise real do progresso da restauração. Essa imprecisão pode levar a decisões equivocadas na alocação de recursos, no planejamento de novas intervenções e na escolha de metodologias adequadas, além de comprometer a comparação entre diferentes períodos de monitoramento e a identificação de tendências essenciais para a recuperação da área degradada (Patias et al. 2017; Evans 2018; Almeida et al. 2019; Gómez et al. 2019).

Para aumentar a precisão dos produtos, é comum utilizar pontos de controle, pontos-chave estrategicamente distribuídos na área mapeada, que podem ser características terrestres permanentes ou alvos de referência posicionados no solo antes do voo (Singh et al. 2023; Ocalan et al. 2022). Esses pontos permitem a orientação absoluta do produto cartográfico, orientando, nivelando e escalando os modelos. Em voos fotogramétricos, recomenda-se que os pontos de controle sejam posicionados estrategicamente na periferia ou nos cantos do bloco para reduzir erros planimétricos e distribuídos pelo interior do bloco para minimizar erros altimétricos (Arévalo-Verjel et al. 2022). A quantidade desses pontos também influencia diretamente a precisão do modelo, sendo essencial em levantamentos destinados a intervenções de restauração em pequena escala ou no acompanhamento de mudanças ao longo do tempo (Cisneros et al. 2019; Casella et al. 2020; Swinfield et al. 2019).

O GNSS revolucionou os levantamentos geodésicos ao proporcionar posicionamento rápido, preciso e econômico (Paula et al. 2023; Dorth & Segantine 2008; Peng et al. 2021). No entanto, os sinais dos satélites podem sofrer interferências ao atravessar a atmosfera terrestre,

o que pode afetar a propagação das ondas eletromagnéticas e gerar desafios, especialmente no componente altimétrico (Mendonça 2013; Pourreza et al. 2022; Swinfield et al. 2019). As altitudes elipsoidais, medidas em relação a uma figura geométrica da Terra, são inerentemente menos precisas e, para aplicações práticas, precisam ser convertidas em altitudes relacionadas ao campo gravitacional terrestre, o que pode introduzir incertezas devido a erros em modelos gravimétricos (Featherstone 2008). Ademais, a precisão dos levantamentos GNSS é inferior em áreas sob dossel fechado em comparação com áreas abertas (Štroner et al. 2023).

Outro aspecto importante refere-se à distinção entre acurácia e precisão. Enquanto a acurácia indica a proximidade de uma estimativa em relação ao valor verdadeiro, a precisão reflete a consistência das medições em torno de sua média (Monico 2008; Antunes & Lingnau 2007). Assim, um levantamento GNSS pode apresentar uma variação milimétrica em relação à média das observações, mas ainda assim ter uma discrepância de 50 centímetros a 1 metro quanto à exatidão.

Esta tese apresenta uma abordagem inovadora ao propor a análise da acurácia posicional dos produtos gerados por sensores RGB e LiDAR, considerando a inserção de pontos de controle durante o processamento, além da acurácia dos próprios pontos de controle. Além disso, visando abordar a questão central acerca da acurácia dos pontos de controle, foi implantada uma rede geodésica de precisão, denominada Rede Cepegeo, onde diferentes metodologias de posicionamento GNSS foram testadas em cenários diversos. Em seguida, um estudo de caso em uma área de restauração florestal, com a implementação de pontos de controle horizontais e verticais, possibilitou a análise comparativa dos produtos obtidos por drones equipados com sensores RGB e LiDAR, processados com softwares comerciais. Os resultados permitiram identificar o melhor custo-benefício na obtenção da acurácia posicional dos produtos e indicaram a quantidade ideal de pontos de controle para otimização dos dados RGB, além de apontar a necessidade de investigações adicionais para aprimorar a acurácia dos produtos LiDAR.

Esperamos que nossas descobertas incentivem estudos futuros que preencham as lacunas identificadas, considerando que o uso de técnicas que possibilitam o monitoramento em larga escala, como a aerofotogrametria e o sensoriamento remoto, está alinhado com as tendências atuais. Dessa forma, contribuímos para o aprimoramento de ferramentas voltadas à formulação de estratégias relacionadas aos compromissos globais com a restauração e conservação ambiental.

Indica-se, ainda, que a presente tese está inserida no contexto do projeto temático FAPESP intitulado “Compreendendo florestas restauradas para o benefício das pessoas e da

natureza – NewFor” (nº do processo: 2018/18416-2), cujo pesquisador coordenador é o Prof. Dr. Pedro Henrique Santin Brancalion (ESALQ/USP) e um dos pesquisadores principais, responsável pelas atividades que envolvem geotecnologias, é o Prof. Dr. Paulo Guilherme Molin (UFSCAR/CCN). Este projeto também se insere no contexto do projeto Centro de Ciências para o Desenvolvimento FAPESP denominado “Restauração de vegetação nativa na Mata Atlântica pela combinação estratégica de medidas obrigatórias e compromissos voluntários - CCD-EMA” (nº do processo 2021/11940-0), com coordenação do Prof. Dr. Paulo Guilherme Molin (UFSCAR/CCN).

1.2 Questão Norteadora

De que forma a inserção de pontos de controle, obtidos por receptores GNSS, influencia a acurácia posicional dos produtos gerados por RPAS com sensores RGB e LiDAR? Além disso, como diferentes metodologias e cenários afetam a acurácia dos próprios pontos de controle?

1.3 Hipótese

A acurácia posicional de pontos de controle obtidos com GNSS e de produtos gerados por RPAS com sensores RGB e LiDAR varia significativamente de acordo com a técnica utilizada, o número de pontos de controle inseridos no processamento e as condições ambientais, sendo possível estabelecer diretrizes metodológicas que maximizem a acurácia dos levantamentos em diferentes cenários.

1.4 Objetivos

1.4.1 Objetivo Geral

Identificar como os RPAS com sensores embarcados vêm sendo utilizado num contexto de monitoramento florestal remoto, e a acurácia posicional dos produtos obtidos por RPAS dotados de sensores RGB e LiDAR em áreas em restauração florestal, além da acurácia dos pontos de controle obtidos com GNSS.

1.4.2 Objetivos Específicos

- i. Identificar como os RPAs com sensores embarcados vêm sendo utilizados num contexto de monitoramento florestal;
- ii. Estimar e comparar a qualidade posicional tridimensional de pontos obtidos com GNSS pelas técnicas mais comumente aplicadas em áreas florestais.
- iii. Estimar e comparar a

qualidade posicional tridimensional de produtos obtidos por RPAs com sensores RGB embarcados, considerando a inserção de até 60 pontos de controle no processamento.

iv. Estimar e comprar a qualidade posicional tridimensional de produtos obtidos por RPAs com LiDAR, além de avaliar os ajustes técnicos que possibilitam melhoria da qualidade posicional

1.5 Estrutura da tese

Visando atender o objetivo geral mencionado anteriormente, esta tese foi dividida em etapas, tais como os objetivos específicos foram apresentados. Assim, será dividida em 7 capítulos principais, onde, no capítulo 1 é apresentada a introdução e contextualização do tema, a questão norteadora, hipótese, os objetivos e a justificativa para todas as temáticas abordadas na tese, além da estrutura da mesma.

No capítulo 2, com o intuito de contextualizar tais temáticas e validar a importância da tese, empreendemos a realização de uma revisão sistemática de literatura (RSL). Tal revisão, intitulada “*How have RPAS helped monitor forests and what can we apply in forest restoration monitoring?*”, foi publicada na revista *Restoration Ecology* em 13/12/2023 (<https://doi.org/10.1111/rec.14061>).

No capítulo 3 abordamos um delineamento geral, apresentando a metodologia da pesquisa em linhas gerais, e no capítulo 4 apresentamos a metodologia executada para a implantação da rede planialtimétrica Cepegeo, onde a implantação de tal rede se fez necessária, posto que para avaliarmos a acurácia dos levantamentos e técnicas GNSS mais comumente utilizadas na obtenção das coordenadas dos pontos de controle, os vértices levantados têm que ser previamente conhecidos para que a dispersão em torno deste também possa ser determinada. Tal capítulo foi reestruturado e aceito para publicação na Revista Brasileira de Geografia Física (RBBF) na data de 29/01/2025, estando atualmente *no prelo*.

O capítulo 5 também foi elaborado em formato de artigo, e foi submetido para publicação na revista *Remote Sensing of Environment* na data de 03/02/2025. Na data de 05/02/2025 recebemos o e-mail que o mesmo está sendo considerado para publicação, e, sendo considerado para tal, passará por revisão. Tal capítulo trata da análise das diferentes metodologias GNSS e determinação da acurácia pertinente a cada técnica, avaliando, inclusive, diferentes tempos de rastreamento. Neste trabalho, além das metodologias e resultados encontrados, foi elaborada uma Tabela de Acurácia de Pontos de Controle obtidos por posicionamento GNSS visando nortear estudos e práticas futuras

O capítulo 6 também foi elaborado em formato de artigo, e após as considerações da banca, o mesmo será considerado para publicação. Neste capítulo apresentamos a metodologia executada no campo e a análise dos dados, para a determinação da qualidade posicional de produtos RGB e LiDAR, considerando a inserção e quantidade de pontos de controle. Também foi analisado se há melhoria nas coordenadas advindas deste produto se efetuarmos pós-processamento GNSS. Este capítulo foi intitulado “Acurácia Posicional De Produtos RGB E LiDAR: Um Estudo De Caso Em Araras-SP”.

No capítulo 7 procederemos às considerações finais proporcionadas por esta tese.

Observação: As referências bibliográficas constam nos finais de cada capítulo.

Literatura Citada

Almeida, D.R.A. de, Stark, S.C., Chazdon, R., Nelson, B.W., Cesar, R.G., Meli, P., Gorgens, E.B., Duarte, M.M., Valbuena, R., Moreno, V.S., Mendes, A.F., Amazonas, N., Gonçalves, N.B., Silva, C.A., Schietti, J., Brancalion, P.H.S., 2019. The effectiveness of lidar remote sensing for monitoring forest cover attributes and landscape restoration. *For. Ecol. Manag.*, 438, pp. 34-43. <https://doi.org/10.1016/j.foreco.2019.02.002>.

Antunes AFB, Lingnau C (1997) Uso de índices de acurácia para avaliação de mapas temáticos obtidos por meio de classificação digital. In: III Congresso e Feira para Usuários de Geoprocessamento da América Latina. 1997. Curitiba. www.geomatica.ufpr.br

Arévalo-Verjel, A. N., Lerma J. L., Prieto, J. F., Carbonell-Rivera, J. P., Fernández, J., 2022. Estimation of the Block Adjustment Error in UAV Photogrammetric Flights in Flat Areas. *Remote Sensing*. 14(12):2877. <https://doi.org/10.3390/rs14122877>.

Berra EF, Peppas MV (2020) Advances and Challenges of UAV SFM MVS Photogrammetry and Remote Sensing: Short Review. *IEEE Latin American GRSS & ISPRS Remote Sensing Conference (LAGIRS)*, pp. 533-538

Brancalion PHS, Viani RAG, Rodrigues RR, Gandolfi S (2015) *Restauração Florestal*. Oficina de Textos. São Paulo

Brancalion PHS, Goetz S, Reid JL, Strassburg BBN, Wilson S, Chazdon RL, Niamir A, Broadbent E, Crouzeilles R, Barros FSM, Zambrano AMA, Baccini A, Aronson J (2019) Global restoration opportunities in tropical rainforest landscapes. *Science Advances* 5:1–12

Casella V, Chiabrando F, Franzini M, Manzino AM (2020) Accuracy Assessment of a UAV Block by Different Software Packages, Processing Schemes and Validation Strategies. *ISPRS Int. J. Geo-Inf.* 9:164.

Cisneros S, García É, Montoya K, Sinde I (2019) Study of the Configurations of Ground Control Points for Photogrammetry with Drone. *Rev. Geospac*, 16, 43–57.

Corte APD, Souza DV, Rex FE, Sanquetta CR, Mohan M, Silva CA, Zambrano AMA, Prata G, de Almeida DRA, Trautenmüller JW, Klauberg C, de Moraes A, Sanquetta MN, Wilkinson B, Broadbent EN (2020) Forest inventory with high-density UAV-Lidar: Machine learning approaches for predicting individual tree attributes. *Computers and Electronics in Agriculture* 179:105815, ISSN 0168-1699, <https://doi.org/10.1016/j.compag.2020.105815>.

d'Oliveira MVN, Figueiredo EO, de Almeida DRA, Oliveira LC, Silva CA, Nelson BW, da Cunha RM, Papa DA, Stark SC, Valbuena R (2021) Impacts of selective logging on Amazon forest canopy structure and biomass with a LiDAR and photogrammetric survey sequence, *Forest Ecology and Management*. Volume 500. 119648. ISSN 0378-1127. <https://doi.org/10.1016/j.foreco.2021.119648>.

Dorth MKS (2010) PROPOSTA DE CLASSIFICAÇÃO DE LINHAS DE BASE OBTIDAS COM DADOS GPS, A LUZ DE ÁRVORE DE DECISÃO. Dissertação de mestrado. EESC-USP. São Carlos.

Dupuis C, Lejeune P, Michez A, Fayolle A (2020) How Can Remote Sensing Help Monitor Tropical Moist Forest Degradation?—A Systematic Review. *Remote Sensing*. 12(7):1087. <https://doi.org/10.3390/rs12071087>

Evans K, Guariguata MR, Brancalion PHS (2018) Participatory monitoring to connect local and global priorities for forest restoration. *Conservation Biology*, 32: 525-534

Franklin JF, Denison W, Mckee A, Maser C, Sedell J, Swanson F, Juday G (1981) Ecological characteristics of old-growth Douglas-fir forests. General technical report. PNW-GTR-118. U.S. Department of Agriculture, Forest Service, Pacific Northwest Research Station, Portland, Oregon, <https://doi.org/10.1073/pnas.78.12.7458>

Featherstone WE (2008) GNSS-based heighting in Australia: Current, emerging and future issues, *Journal of Spatial Science*, 53:2, 115-133. <https://doi.org/10.1080/14498596.2008.9635153>

Fonstad, MA, Dietrich JT, Courville BC, Jensen JL, Carbonneau, PE (2013) Topographic Structure from Motion: A New Development in Photogrammetric Measurement. *Earth Surf. Process. Landforms*. 38, 421–430.

Garcia M, Saatchi S, Ferraz A *et al* (2017) Impact of data model and point density on aboveground forest biomass estimation from airborne LiDAR. *Carbon Balance Manage* 12, 4 <https://doi-org.ez31.periodicos.capes.gov.br/10.1186/s13021-017-0073-1>

Gómez C, Alejandro P, Hermosilla T, Montes F, Pascual C, Ruiz LA, Álvarez-Taboada F, Tanase M, Valbuena R (2019). Remote sensing for the Spanish forests in the 21st century: a review of advances, needs, and opportunities. *Forest Systems*. 28(1):eR001. <https://doi.org/10.5424/fs/2019281-14221>

Gyamfi-Ampadu E, Gebreslasie M (2021) Two Decades Progress on the Application of Remote Sensing for Monitoring Tropical and Sub-Tropical Natural Forests: A Review. *Forests*. 12(6):739. <https://doi.org/10.3390/f12060739>

Holl KD, Aide TM (2011) When and where to actively restore ecosystems? *Forest Ecology and Management*, 261(10):1558-1563

Jaafar WM, Woodhouse IH, Silva CA, Omar H, Abdul Maulud KN, Hudak AT, Klauberg C, Cardil A, Mohan M (2018) Improving Individual Tree Crown Delineation and Attributes Estimation of Tropical Forests Using Airborne LiDAR Data. *Forests*. 2018; 9(12):759. <https://doi.org/10.3390/f9120759>

Lucieer A, Jong SM, Turner D (2014) Mapping Landslide Displacements using Structure from Motion (SfM) and Image Correlation of Multi-Temporal UAV Photography. *Prog. Phys. Geogr.* 2014, 38, 97–116

Maesano M, Santopuoli G, Moresi FV, Matteucci G, Lasserre B, Scarascia Mugnozza G (2022). Above ground biomass estimation from UAV high resolution RGB images and LiDAR data in a pine forest in Southern Italy. *iForest* 15: 451-457. - doi: 10.3832/ifor3781-015

Mendonça MAM de. (2013) Investigação da cintilação ionosférica no Brasil e seus efeitos no posicionamento por GNSS. Dissertação (Mestrado) – Programa de Pós Graduação em Ciências Cartográficas, Faculdade de Ciências e Tecnologia da UNESP, Presidente Prudente.

Monico, JFG. Posicionamento pelo GNSS: descrição, fundamentos e aplicações. São Paulo: Ed. da Unesp, 2 ed., 2008. 476p.

Niethammer U, Rothmund S, Schwaderer U, Zeman J, Joswig M (2011) Open Source Image-Processing Tools for Low-Cost UAV-Based Landslide Investigations. In *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences—ISPRS Archives*; ISPRS: Zurich, Switzerland, pp. 161–166.

Noss RF (1990) Indicators for monitoring biodiversity: a hierarchical approach. *Conservation Biology* 4: 355–364

Ocalan, T., Turk, T., Tunalioglu, N. *et al.* Investigation of accuracy of PPP and PPP-AR methods for direct georeferencing in UAV photogrammetry. *Earth Sci Inform* 15, 2231–2238 (2022). <https://doi-org.ez31.periodicos.capes.gov.br/10.1007/s12145-022-00868-7>

Ota T, Ogawa M, Shimizu K, Kajisa T, Mizoue N, Yoshida S, Takao G, Hirata Y, Furuya N, Sano T, et al. (2015) Aboveground Biomass Estimation Using Structure from Motion Approach with Aerial Photographs in a Seasonal Tropical Forest. *Forests* 6(11):3882-3898. <https://doi.org/10.3390/f6113882>

Patias P, Giagkas F, Georgiadis C, Mallinis G, Kaimaris D, Tsioukas V. (2017) Evaluating horizontal positional accuracy of low-cost UAV orthomosaics over forest terrain using ground

control points extracted from different sources. Fifth International Conference on Remote Sensing and Geoinformation of the Environment (RSCy2017). <https://doi.org/10.1117/12.2278008>

Paula ER, Monico JFG, Tsuchiya IH, Valladares CE, Costa SMA, Marini-Pereira L, Vani BC, Moraes AO (2023) A Retrospective of Global Navigation Satellite System Ionospheric Irregularities Monitoring Networks in Brazil, *Journal of Aerospace Technology and Management*, v15.1288. <https://doi.org/10.1590/jatm.v15.1288>

Peng, Y, Scales, WA, Hartinger, M. et al. (2021). Characterization of multi-scale ionospheric irregularities using ground-based and space-based GNSS observations. *Satell Navig* 2, 14. <https://doi.org/10.1186/s43020-021-00047-x>

Pourreza M, Moradi F, Khosravi M, Deljouei A, Vanderhoof MK (2022) GCPs-Free Photogrammetry for Estimating Tree Height and Crown Diameter in Arizona Cypress Plantation Using UAV-Mounted GNSS RTK. *Forests*. 13(11):1905. <https://doi.org/10.3390/f13111905>

Rodrigues Rr, Lima Raf, Gandolfi S, Nave Ag (2009) On the restoration of high diversity forests: 30 years of experiences in the Brazilian Atlantic Forest. *Biological Conservation* 142(6):1242-1251

Ruiz-Jaen MC, Aide TM (2005a). Restoration success: how is it being measured? *Restoration Ecology* 13: 569–577

SER (Society for Ecological Restoration). 2004. Society for ecological restoration international's primer of ecological restoration. Available from: <http://www.ser.org/resources/resources-detail-view/ser-international-primer-on-ecological-restoration>).

Sinegalia MKSD, Santoro GB, Molin PG (2023) How have RPAS helped monitor forests and what can we apply in forest restoration monitoring? *Restoration ecology* 32:1:e14061 <https://doi.10.1111/rec.14061>

Singh CH, Rai A, Harshit, Mishra V, Kushwaha SKP, Jain K (2023) Quality Assessment of UAV Data using Multiple RTK Reference Stations. International Conference on Machine Intelligence for GeoAnalytics and Remote Sensing (MIGARS), Hyderabad, India. 1-4.

<https://doi.org/10.1109/MIGARS57353.2023.10064555>

Štroner, M., Urban, R., Křemen, T., & Braun, J. (2023). UAV DTM acquisition in a forested area – comparison of low-cost photogrammetry (DJI Zenmuse P1) and LiDAR solutions (DJI Zenmuse L1). *European Journal of Remote Sensing*, 56(1). <https://doi-org.ez257.periodicos.capes.gov.br/10.1080/22797254.2023.2179942>

Swinfield T, Lindsell JA, Williams JV, Harrison RD, Agustiono, Habibi, Gemita E, Schönlieb CB, Coomes DA. (2019) Accurate Measurement of Tropical Forest Canopy Heights and Aboveground Carbon Using Structure From Motion. *Remote Sensing*. 11(8):928. <https://doi.org/10.3390/rs11080928>

Szypuła B (2023) Accuracy of UAV-based DEMs without ground control points. *GeoInformatica*. <https://doi-org.ez31.periodicos.capes.gov.br/10.1007/s10707-023-00498-1>

Tao S, Guo Q, Li L, Xue B, Kelly M, Li W, Xu G, Su Y (2014) Airborne Lidar-derived volume metrics for aboveground biomass estimation: A comparative assessment for conifer stands, *Agricultural and Forest Meteorology*, Volumes 198–199, Pages 24-32, ISSN 0168-1923, <https://doi.org/10.1016/j.agrformet.2014.07.008>.

Tedesco AM, López-Cubillos S, Chazon R, Rhodes JL, Archibald CL, Pérez-Hämmerle KV, Brancalion PHS, Wilson KA, Oliveira M, Correa DF, Ota L, Morrison TH, Possingham HP, Mills M, Santos FC, Dean AJ (2023) Beyond ecology: ecosystem restoration as a process for social-ecological transformation. *Trends in Ecology & Evolution* 38(7):643-653

Turner D, Lucieer A, de Jong SM (2015) Time Series Analysis of Landslide Dynamics using an Unmanned Aerial Vehicle (UAV). *Remote Sens.* 7:1736–1757.

Valbuena R, Hernando A, Manzanera JS, Görgens EB, Almeida DRA, Mauro F, García-Abril A, Coomes DA (2017) Enhancing of accuracy assessment for forest above-ground biomass

estimates obtained from remote sensing via hypothesis testing and overfitting evaluation. *Ecological Modelling* 366:15-26

White JC, Wulder MA, Hermosilla T, Coops NC, Hobart GW (2017) A nationwide annual characterization of 25years of forest disturbance and recovery for Canada using Landsat time series. *Remote Sensing of Environment* 194:303-321

Wortley L, Hero JM and Howes M (2013), Evaluating Ecological Restoration Success: A Review of the Literature. *Restor Ecol*, 21: 537-543. <https://doi.org/10.1111/rec.12028>

2. SYSTEMATIC LITERATURE REVIEW: HOW HAVE RPAS HELPED MONITOR FORESTS AND WHAT CAN WE APPLY IN FOREST RESTORATION MONITORING?

RUNNING HEAD: RPAS IN FOREST MONITORING AND RESTORATION

ABSTRACT

We are currently experiencing an unprecedented moment in forest restoration, where monitoring activities in recovery areas play a vital role in problem identification and method adaptation. However, it is crucial to shift away from expensive traditional methodologies and develop technologies that enable large-scale monitoring using more accessible and cost-effective tools. In an effort to provide an evidence-based perspective, we conducted a systematic review of how remotely piloted aircraft systems (RPAS) equipped with various sensors have been employed for forest monitoring. We consulted three databases and included 53 articles in our review. The results revealed a trend towards research in tropical ecosystems, with forest structure being the most frequently assessed attribute, and canopy height being the most widely measured structural indicator. RGB sensors were commonly used, both individually and in combination with others, and there was a noticeable shift towards the use of LiDAR. Data validation primarily relied on forest inventory methods, often involving comparisons of outputs from different sensors and the use of artificial intelligence algorithms. Despite the wide range of studies utilizing sensor-equipped drones to analyze forest attributes, there is a notable scarcity of research specifically addressing the application of these technologies in forest restoration monitoring. Filling this research gap is essential, as employing techniques that enable large-scale monitoring, such as aerial photogrammetry and remote sensing, aligns with current trends and contributes to global commitments to environmental restoration and conservation.

Keywords: Aerophotogrammetry; Drone; Ecological Restoration; UAS; UAV.

Implications for Practice

- The monitoring of forest restoration through the combination of RPAS with integrated sensors enables large-scale resurgence, saving time and resources compared to forest inventory monitoring

- The precision of the products obtained through the combination of RPAS and sensors enables the identification of important details in restoration, such as the number of planted trees and forest coverage.
- The information obtained through these technologies enhances decision-making efficiency, allowing the identification and correction of issues, as well as the adaptation of methods whenever necessary, aiming for the success of the restoration.

2.1 Introduction

Ecosystem restoration has been rapidly expanding worldwide, particularly following the global call by the UN that declared the period from 2021 to 2030 as the Decade of Restoration (Brancalion et al. 2019), with over 60 nations committing to restore more than 200 million hectares of forest landscapes by 2030 as part of the Bonn Challenge (Tedesco et al. 2023).

With the recognition of the significant potential of ecosystem restoration to address the most pressing challenges of our time, encompassing not only active restoration through planting seedlings but also passive restoration strategies (Rodrigues et al. 2009), continuous evaluation of the methods employed becomes essential. This evaluation allows for an analysis of how the recovering area is responding to the utilized methods (Brancalion et al. 2015), identification of potential disturbances, and implementation of corrective management measures, guiding practices such as replanting or adjustment. This contributes to enhancing existing restoration techniques and guiding the direction of new studies (Evans, 2018), making monitoring an indispensable step throughout the entire process of ecological restoration (Almeida et al. 2019).

The monitoring of an area undergoing forest restoration is founded on sampling techniques aimed at obtaining key indicators of an ecosystem's ecology (Valbuena et al. 2017). The Society for Ecological Restoration (SER) Primer provides foundational guidance for restoration planning, along with a list of essential attributes for its success, assisting professionals in identifying indicators of achievement (Wortley et al. 2013).

These attributes encompass three general ecological outcomes: vegetation structure, composition and ecological processes, often used to classify ecosystem state indicators in literature (Ruiz-Jaen & Aide 2005b; Noss 1990; Franklin et al. 1981). Composition refers to the identity and variety of elements in a collection and includes species diversity and abundance (Noss 1990). Structure pertains to the physical organization or patterns of a system and determines habitat suitability (Franklin et al. 1981). Ecological Processes relate to the ecologically and evolutionarily driven processes that provide insights into the restored ecosystem's resilience (Franklin et al. 1981), and can be subdivided into Function and

Ecosystem Services, where Function pertains to various activities and processes occurring within the ecosystem, such as nutrient cycling, organic matter decomposition, and local climate regulation (Gatica-Saavedra et al. 2017). Ecosystem Services refer to the benefits arising from ecosystems, including provisioning services like food and water; regulating services like flood and disease control; cultural services encompassing spiritual, recreational, and cultural benefits; and supporting services like nutrient cycling that maintain conditions for life on Earth (MEA 2005).

A critical step in obtaining these indicators is to develop replicable monitoring protocols on a scale of millions of hectares that are cost-effective, as assessments of restoration outcomes traditionally heavily rely on field-based data collection methods, which, even with recent advancements, incur significant costs (Holl & Aide 2011).

The advent of RPAS, commonly known as drones, and a wide range of sensors capable of generating high-resolution images has enabled the development of new approaches in remote sensing and aerial photogrammetry (Berra & Peppia 2020). The most frequently used sensors for forest monitoring purposes include RGB (Red-Green-Blue), LiDAR (Light Detection And Ranging), multispectral, and hyperspectral sensors (Kahraman & Bacher 2021). The combination of sensors and RPAS, in the context of restoration monitoring, emerges as a promising alternative, allowing for complementing field data collection, reducing costs, and providing precise information about forest ecosystems. Furthermore, it enables a significant improvement in the assessment of the performance of techniques and products at various scales (White et al. 2017).

According to the International Society for Photogrammetry and Remote Sensing (ISPRS), Photogrammetry and Remote Sensing are the science, technology, and art that allow for the reliable inference of information about objects on the Earth's surface without direct physical contact. These two techniques are fundamental in the field of geoinformation and Earth observation. However, while Photogrammetry emphasizes extracting geometric information from objects and scenes of interest using photographs or digital images (Castanheiro et al. 2021; Nedelcu et al. 2019), Remote Sensing deals with the acquisition, processing, and interpretation of images and multi-channel spectral data acquired from sensors onboard aircraft and satellite platforms. These sensors record the interaction between investigated objects and electromagnetic energy, enabling the acquisition of information beyond the visible spectrum, such as infrared, thermal, and microwave images (Torres et al. 2023; Sothe et al. 2019; Borisova et al. 2017). Digital aerial photogrammetry, or aerophotogrammetry, is a subdivision of

photogrammetry that deals with aerial photographs. It is widely used in creating digital elevation models and orthophotos through the principles of geometry and optics (Wolf 2004).

In order to systematically synthesize and analyze the available scientific evidence in a methodical, replicable, and comprehensive manner, as well as to gain insights into the current landscape, the "state of the art," and the key gaps and trends (Siddaway et al. 2019) regarding the use of drones with onboard remote sensors in monitoring forest restoration, we embarked on conducting a systematic and bibliometric literature review. This review was carried out across three distinct research databases: Web of Science (WOS), Scopus, and Scielo. These databases were selected due to their encompassment of the majority of peer-reviewed literature abstracts and citations, as well as their bibliometric tools that facilitate the tracking, analysis, and visualization of results (Deo 2022).

However, despite the exponential increase in studies utilizing drones and onboard remote sensors for forest monitoring (Buters et al. 2019), we immediately identified a gap concerning the use of these technologies in monitoring areas undergoing forest restoration. Upon using a combination of keywords that we deemed suitable for this inquiry, we retrieved a mere 5 articles.

Filling this gap is essential, as the adoption of techniques that enable restoration monitoring on a larger scale aligns with the current landscape. This prompted us to pursue a new guiding question: 'Do the results from studies using drones with embedded sensors for forest monitoring provide sufficient parameters for replication in the monitoring of areas undergoing forest restoration?' This also led to the reformulation of keywords.

We obtained a total of 999 articles published between 1983 and 2021. After the screening process, in accordance with the predetermined eligibility criteria, we included 53 articles in this portfolio. These articles were analyzed to provide a comprehensive overview of the use of these technologies in forest monitoring, as well as to assess whether the results can be replicated in the monitoring of areas undergoing forest restoration. Additionally, we aimed to identify trends, patterns, and/or knowledge gaps in the existing studies.

2.2 Methodology

The primary objective of a systematic literature review is to synthesize knowledge and analyze scientific evidence, enabling an understanding of the current landscape of publications related to the proposed topic. It also facilitates the identification of trends, patterns, and/or knowledge gaps, providing a solid foundation for decision-making, the formulation of new

research, and the development of evidence-based policies or practices (Caldwell & Bennett 2020; Siddaway et al. 2019).

Therefore, aiming to answer the question, "How have RPAS, along with sensors, been used to monitor forest restoration worldwide, and what indicators have been analyzed?", we selected the keywords Monitoring, Restoration, Forest, and RPAS, along with their respective synonyms and plurals, as follows: drone OR RPAS OR UAV OR UAS OR RPA OR "remotely piloted aircraft" OR "unmanned aerial vehicle" OR "unmanned aerial system" AND forest\$ OR afforestation AND monitor\$ AND restor\$. These terms were combined in various ways using titles, abstracts, and keywords from the publications. The words "AND" and "OR" are boolean operators used in various combinations where the use of "AND" indicates that both terms must appear in the publications, and "OR" indicates that at least one of the terms should appear. The symbol "\$" is an operator that truncates the end of a word, which is useful for searching for different suffixes.

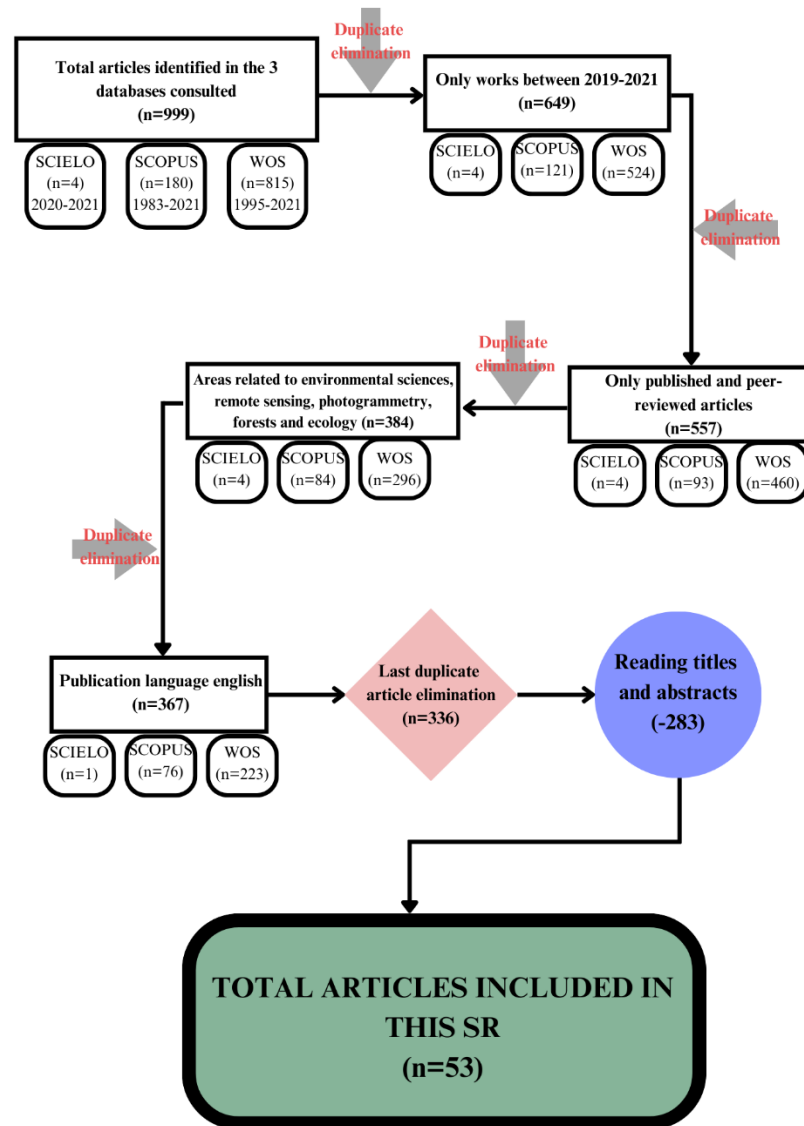
However, for this combination of words, the return of articles that would constitute this portfolio was very limited, resulting in a total of 0 articles in the Scielo and Scopus databases, and 5 in the WOS database. Due to the identified gap, it was decided to expand the search by using the terms Monitoring, Forest, and RPAS (and their respective synonyms and plurals), resulting in a total of 999 articles in the three mentioned databases, published between 1983 and December 2021 (including articles with early access).

With the aim of analyzing the combination of the most current methodology, technology, and techniques, the search was refined to articles published between 2019 and 2021 in areas related to remote sensing, photogrammetry, and environmental analysis. Subsequently, a final check for duplicate and redundant articles in the mentioned databases was conducted.

Armed with these studies, we proceeded with a qualitative analysis of titles and abstracts, followed by a thorough examination of complete studies. The objective was to select works that employed RPAS with imaging sensors and provided relevant information for monitoring areas undergoing forest restoration. Our focus was on the type of forest, sensors used, assessed indicators and attributes, and result validation. This process led to the exclusion of articles not directly related to the topic, such as studies employing remote sensing for agricultural improvements (which appeared due to the keyword "forest") and those related to wildlife monitoring or forests subject to recurrent fires.

Figure 1 depicts the workflow with the stages of identification and text selection.

Figure 1: Workflow of the selection of articles that compose this SRL.



Once the relevant articles for this review were identified (Articles accepted in this review, Table S1), two distinct analyses were conducted on these results. The first analysis aimed to map the current landscape of studies that utilized drones with onboard sensors for forest monitoring. The second analysis sought to comprehend the current state of the art by evaluating whether the results derived from these studies provide sufficient parameters for replication in the monitoring of areas undergoing forest restoration. Additionally, this analysis aimed to identify trends, patterns, and/or gaps in this thematic area.

2.2.1 Mapping the information landscape through scientific evidence

The analysis of the evolution of scientific production, authors, and key research areas plays a crucial role in understanding the current landscape and trends within a specific field of

knowledge. This allows for the identification of patterns, gaps, research opportunities, challenges, and strategic directions (Deo 2022).

For this mapping, the data from this review were organized into figures and tables showcasing the evolution of scientific production over the years, prominent authors, journals, and research areas with the most published articles.

2.2.2 Current state of the art

Restoration efforts are poised to take place in the coming decade(s) at a greater scope and capacity than ever before, and evidence-based research represents a significant tool to support broad generalizations across a variety of shared conditions to advance ecological restoration on a global scale (Ladouceur & Shackelford 2020).

In this study, with the aim of understanding the current state of the art and identifying trends, patterns, and/or gaps in the use of drones equipped with sensors for monitoring areas undergoing forest restoration, an analysis and categorization of the articles were conducted. This analysis paid close attention to the types of forests, ecological indicators and attributes, as well as the types of sensors and validation processes used in the results. The study sought to address questions related to the ecosystem, technology, and validation employed in result analysis, as well as whether the study's objective was to monitor an area in the process of forest restoration or if the obtained results could be replicated for such scenarios.

Regarding the ecosystem, the study aimed to address the following questions: What types of forests have the highest number of case studies? What indicator(s) were most commonly analyzed? Which of these attributes had the highest incidence? Did the results obtained allow for the assessment of the structure, composition, and/or ecological functions and ecosystem services of the studied ecosystems?

Concerning the technology and validation of the obtained results, the study aimed to comprehend: Which sensors were most frequently used, and what methodology was employed to validate these results? Was there a combination with statistical techniques and/or artificial intelligence (AI)?

Table 1 displays the categories that were considered for the classification of the included articles, where, in order to provide an accurate perspective on the studies comprising this portfolio, we retained the terms and definitions used by the authors of the articles.

Table 1: Categories used for article classification.

Category	Subdivisions
Forest Types	Tropical; Boreal; Temperate; Subtropical
Indicators	Phenology; Vital Status; Tree Individual Height; Canopy Height; Canopy Crown; Tree Canopy volume; Canopy Cover; Leaf Area Index; Understory; Diameter at Breast Height (DBH); Spatial Distribution; Species Classification; Species Richness; Species Diversity; Biodiversity; Biomass
Attribute	Structure; Composition; Ecological Processes
Types of Sensors	RGB; LiDAR; Multispectral; Hyperspectral
Data Validation	Inventory; Technique Comparison; Statistical Test; AI

With the answers to these inquiries, we were able to identify the main gaps, patterns, and trends in the use of drones with onboard sensors in the context of forest restoration monitoring.

2.3 Results

Figure 1, presented earlier, illustrates the outcomes achieved in each stage.

Evolution of scientific production over the years

Between the years 2002 to 2004, the annual publication rate was 0.11% of the total, and until 2015, it accumulated only 10.39% of the publications. In 2017, there was a slight increase, with an annual publication rate of 7.85%, raising the cumulative percentage to 12.16% in 2018 and further to 18.56% in 2019. In 2020, this value increased to 24.53%, making it the year with the highest number of published articles.

A figure was produced (after applying the filters described in the methodology to ensure the absence of duplicates) presenting the temporal evolution of scientific production in terms of the number and percentage of publications per year from 1983 to 2021 (Temporal evolution of publications between 1983 and 2021, Figure S1).

It is important to highlight that the search in the mentioned databases was completed in November 2021 and represented 22.21% of the total.

Authors

According to the data obtained from this review, researchers Almeida DRA, Brancalion PHS, Broadbent EM, Coops NC, Papa DA, Silva CA, and Zambrano AMA are the main authors of publications related to RPAS platforms and forest monitoring, with 4 publications (8.511%) each. The leading authors in this field, according to this review, are presented in Figure 2.

Figure 2: Authors with the highest number of publications using the chosen terms.



Research Topics and Journals

The publications that make up this portfolio were predominantly developed in themes related to remote sensing (about 77%) and environmental sciences (72%). The journal with the highest number of publications for the chosen terms was Remote Sensing (ISSN: 2072-4292).

The absolute frequencies (AF) and relative frequencies (RF) of the Research Topics are presented in the supplementary information (Main research topics of the analyzed publications, Table S2).

Forest Types

Out of the 53 analyzed articles, 17 (32.08%) were conducted in tropical forests, followed by 12 (22.64%) in mixed temperate forests, 4 articles (7.55%) in boreal forests, and 2 (3.77%) in subtropical forests. It is worth noting that 34% of the analyzed studies did not mention the forest typology.

Forest Ecological Attributes and Indicators

Among the articles included in this review, the ecological attribute most frequently evaluated was Forest Structure, with 62% of the studies (n=33) exclusively focused on this aspect. 13% (n=7) aimed to assess both Structure and Ecological Processes, and studies targeting Structure and Composition or all three attributes each had an occurrence of 3 articles (5%), totaling 85% of the studies with an interest in evaluating Forest Structure.

Regarding studies that aimed to assess Forest Composition, 5 of them evaluated it individually, and 3 in combination with forest structure. Concerning Ecological Processes, 7 assessed this attribute alongside structure, and only 2 evaluated it independently.

It's worth noting that only 3 studies evaluated all 3 ecological attributes, and the results are presented in Table 2.

Table 2: Absolute and relative frequencies of assessed forest attributes.

Attribute	AF	RF
Only Forest Structure	33	62,26%
Only Forest Composition	5	9,44%
Only Ecological Processes	2	3,77%
Structure, Composition and Ecological Processes	3	5,66%
Structure and Composition	3	5,66%
Structure and Ecological Processes	7	13,21%
Composition and Ecological Processes	0	0

Regarding the indicators, canopy height (n=27) showed the highest frequency, followed by spatial distribution (n=17), and this result aligns with the previous findings, given the correlation between these indicators and forest structure. Table 3 provides the absolute frequencies for the indicators included in this portfolio.

Table 3: Absolute frequencies of the considered indicator.

Indicator	FA
Phenology	6
Vital Status	3
Tree Individual Height	1
Canopy Height	27
Canopy Crown	9
Tree Canopy Volume	1
Canopy Cover	10
Leaf Area Index	5
Understory	1
Diameter at Breast Height (DBH)	7
Spatial Distribution	17
Species Classification	5
Species Richness	1
Species Diversity	4
Biodiversity	10
Biomass	8

Sensors

In the articles included in this review, 56.6% used RGB sensors either individually or in combination with other sensors, with 34% using only RGB and 22.6% using combinations of RGB with other sensors. Among these, 50% used a combination of RGB and LiDAR sensors.

Table 4 presents the frequencies of sensors, both individually and in combination, and a figure with the absolute frequency of sensor usage has been included in the supplementary information (Absolute frequencies with which the sensors were used, Figure S2).

Table 4: Absolute and relative frequencies of Sensors used.

SENSOR	Relative Frequency	Absolute Frequency
LiDAR only	11,32%	6
Hyperspectral only	1,89%	1
Multispectral only	13,21%	7
RGB only	33,96%	18
LiDAR + Hyperspectral	5,66%	3
LiDAR + Multispectral	7,55%	4
LiDAR + RGB	11,32%	6
Hyperspectral + Multispectral	3,77%	2
Hyperspectral + RGB	1,89%	1
Multispectral + RGB	9,43%	5

It's worth mentioning that LiDAR was the second most frequently used sensor (35.9%).

Data validation

Of the 53 articles analyzed, 40 of them (75.47%) mentioned using forest inventory for result validation, and the works that did not use this method employed a combination of statistical techniques, algorithms, and/or artificial intelligence for this purpose. Regarding the results, 28 articles mentioned that, according to the adopted validation, the technique allowed for successful identification or use of the indicator/attribute for forest monitoring, 20 mentioned that the technique should be performed again, considering improvements, and 5 did not mention whether they were successful.

100% of the analyzed articles discussed image processing parameters and used statistical inference techniques to validate and classify the obtained results.

Articles focused on monitoring areas undergoing restoration

Of the 53 papers, only 17% (n=9) aimed to evaluate the success of the indicators and attributes collected by the sensor and RPAS set for forest restoration monitoring. These articles can be viewed in Table 5.

Table 5: Articles that composed this review and used RPAs and sensors in restoration monitoring.

Titles
Monitoring restored tropical forest diversity and structure through UAV-borne hyperspectral and lidar fusion
Monitoring the Structure of Regenerating Vegetation Using Drone-Based Digital Aerial Photogrammetry
Remotely piloted aircraft imagery for automatic tree counting in forest restoration areas: a case study in the Amazon
UAV-derived estimates of forest structure to inform ponderosa pine forest restoration
Automated Detection of Conifer Seedlings in Drone Imagery Using Convolutional Neural Networks
Monitoring the structure of forest restoration plantations with a drone-lidar system
Management Recommendation Generation for Areas Under Forest Restoration Process through Images Obtained by UAV and LiDAR
Accurate Measurement of Tropical Forest Canopy Heights and Aboveground Carbon Using Structure from Motion
Forest restoration monitoring through digital processing of high-resolution images

The most common ecological attribute was Forest Structure, with 100% of these studies evaluating this attribute. Only two articles evaluated Ecological Processes in addition to Forest Structure, and none aimed to assess Forest Composition. Regarding the indicators, only 3 out of the 9 articles used a single indicator, with canopy height being the most common (67%), followed by canopy cover (33%).

Regarding the sensors, 4 studies used LiDAR individually, followed by 3 that used RGB individually, and 1 for hyperspectral and multispectral sensors. Despite the individual use of these sensors, 2 studies used a combination of multispectral and LiDAR, and 1 combined RGB and LiDAR to compare results.

The main results found for these articles are presented in Table 6.

Table 6: Results found in articles focusing on restoration monitoring.

Category	Subdivisions
Forest Types (%)	Tropical 56% Boreal (11%) Temperate (11%) Unspecified typology (22%)
Indicators (FA)	Canopy height (6) Canopy Crown (1) Canopy Cover (3) Leaf Area Index (1) Spatial Distribution (2) Species Richness (1) Species Diversity (1) Biodiversity (1) Biomass (3)
Attributes (FA)	Only Forest Structure (6) Structure and Composition (1) Structure and Ecological Processes (2)
Types of sensors	Only RGB (n=3); Only LiDAR (n=4); Only Multispectral (n=1); Only Hyperspectral (n=1); Combination Multi + LiDAR (n=2); Combination RGB + LiDAR (n=1)
Data Validation (RF)	Inventory (55,56%) Inventory = Technique Comparison = Statistical Test (100%) AI (66,67%)

2 studies mentioned that, despite being successful, there are relevant considerations regarding cost and the high level of knowledge required. 56% mentioned using forest inventory for validation.

2.4 Discussion

2.4.1 Mapping the information landscape through scientific evidence

Evolution of Scientific Production, Research Topics, Authors, and Journals

By analyzing the evolution of scientific production, it is possible to understand the most significant milestones and advances, as well as changes in research trends, enabling the identification of emerging and/or underrepresented topics in scientific literature. This helps direct researchers' focus towards existing gaps. Additionally, analyzing the most prolific and influential authors in a systematic review provides insights into collaboration networks, aiding in the understanding of individual and collective contributions in the field (Deo 2022).

Our review demonstrates a significant increase in publications from 2019 onwards, with 65.3% of the papers falling between 2019 and 2021. This increase can be attributed to the global trend, driven by the United Nations' call to support the restoration of degraded ecosystems (Almeida et al. 2019b).

There was also a significant overlap of studies between research topics related to remote sensing and environmental sciences. Out of the 53 articles included in this portfolio, 52 are in at least one of these two areas (98%), with 60% belonging to both (n=32).

Supporting this trend, the authors with the highest number of papers included in this review have multiple studies in both areas. They employed remote sensing and/or photogrammetry techniques for monitoring forest indicators while also collaborating on joint research, alternating authorship order among the selected papers in this review.

Almeida DRA, Brancalion PHS, Broadbent EM, Papa DA, Silva CA, and Zambrano AMA have conducted studies on forest structure monitoring using LiDAR (Almeida DRA 2019; d'Oliveira 2021¹; Almeida DRA 2020; Almeida DRA 2021), as well as studies on indicators of ecosystem services such as biodiversity and biomass (d'Oliveira 2020). Coops NC (Shen 2020; Fu 2021; Nuljten 2021; Nuljten 2021) has used photogrammetry and/or remote sensing to analyze forest structure and/or composition.

2.4.2 Current state of the art

Forest Types

The United Nations classifies forests according to their climatic domain as tropical, boreal, temperate, and subtropical forests, covering approximately 45%, 27%, 16%, and 11% of the total area, respectively (FAO 2020). Each type of forest has unique levels of biodiversity, vegetation structures, and ecological processes that need to be considered in the restoration process (de Souza 2022).

In this study, we observed a trend towards monitoring tropical, subtropical, or mixed forests, with 55% of the studies taking place in these forest types. Tropical forests play a crucial role in sustaining life on the planet, harboring a vast number of individuals and species belonging to different ecological groups. They also play a pivotal role in global carbon dynamics, accounting for a third of terrestrial gross primary production and half of the carbon stored in land (Hubbell et al. 1999). However, they are also the most deforested forest landscapes (de Souza 2022; FAO 2020).

Therefore, the concentration of studies in this ecosystem type was not surprising, given that the restoration of tropical forests is essential. This consideration arises not only from the factors previously mentioned but also from the need to address global climate change and to preserve and conserve biodiversity and ecosystem services (Parron et al. 2019).

However, the small number of studies in boreal forests (7.55%) was surprising, considering that boreal forests cover nearly 30% of the total land area (de Souza 2022). This scarcity of studies in boreal forests may be related to the fact that they are the least deforested areas and, therefore, require fewer restoration actions (FAO 2020).

Another point is that in addition to 34% of the authors not mentioning the type of forest, there was also a lack of information about the conservation status of the forests. In other words, it was unclear whether the analyzed forest was in a conserved, degraded, or restoration process state (and at which successional stage in the case of restoration).

Forest Ecological Attributes and Indicators

Given the substantial investment of time, effort, and resources in forest restoration initiatives, it is crucial to establish standards of practice for evaluating the effectiveness of these actions. Without proper assessment of restoration outcomes, managers would be unable to determine whether the established objectives have been achieved (Gatica-Saavedra et al. 2017). In this context, the SER Primer plays a crucial role in promoting integration and providing

guidance for restoration planning, assisting professionals in identifying success indicators (Wortley et al. 2013; SER 2004).

In this review, 62% of the articles assessed the Forest Structure attribute, and among those, 51% used canopy height. The importance of monitoring canopy height is justified as this indicator plays a critical and multifaceted role in forest restoration monitoring, reflecting the health and structure of an ecosystem (Xiaoyan et al. 2023). It also helps understand the three-dimensional structure of the ecosystem (Dickinson et al. 2016). A well-developed canopy indicates an environment conducive to tree growth and natural regeneration, promoting effective restoration, and positively correlating with species richness (Almeida et al. 2021).

A concerning gap was observed regarding ecosystem services, where only 2 studies mentioned this attribute. Ecosystem services can be minimally defined as the benefits to human well-being derived from the functioning of ecosystems, and although no one disagrees that nature provides benefits to people, the use of ecosystem services as a motivation for restoration has been controversial, with both methodological and philosophical objections (Matzek 2018). Methodological concerns primarily involve the structuring of payment for ecosystem services (PES) programs (Boyd & Banzhaf, 2007), and philosophically, the most salient objection is the assertion that this can undermine ethical foundations, where the biggest point of concern relates to monetization, which may weaken motivations based on the intrinsic value of ecosystems and species (Rohr et al. 2018).

A related concern is that if restoration is carried out with the explicit goal of providing ecosystem services to people, this can compromise ecological and biodiversity objectives (for example, monocultures of non-native species planted for carbon sequestration (Lindenmayer et al. 2012).

Sensors

Remote sensing allows us to map and monitor vegetation more efficiently compared to using only traditional field-based methods (White et al. 2016). However, different types of sensors provide unique information about ecosystems that can be more useful when combined (Almeida et al. 2019b)

Sensors that remotely capture data (such as LiDAR or multispectral sensors) stand out as agile and autonomous methods for monitoring forest restoration projects, especially in conditions where information updates are frequently required or when the use of aerial photogrammetry by planes is not financially viable, justifying research trends in remote sensing (Almeida et al. 2019).

The most commonly used onboard sensors for forest monitoring are RGB, LiDAR, multispectral, and hyperspectral sensors. RGB sensors operate in the visible range and measure variations in the radiance intensity of light reflected from a colored surface, allowing for the collection of quantitative terrain data. LiDAR sensors work by emitting pulses of light and measuring the time it takes for them to reflect off the ground, along with the intensity with which they do so, thereby providing a three-dimensional point cloud of the forest (Kahraman & Bacher 2021). Multispectral and hyperspectral sensors consist of multiple sensors that capture images of the same object in different spectral bands, with the main difference between them being the number of bands and how narrow they are (Poley & McDermid 2020).

In the papers comprising this portfolio, the most frequently used sensor on its own was RGB (34%), and among the combinations of RGB with others, the one with the highest occurrence was with LiDAR (11%). None of these results are surprising, as RGB sensors have the lowest acquisition cost and are the easiest to operate (Peng et al. 2023), while LiDAR sensors are particularly effective in generating accurate three-dimensional models, including distances and heights. The synergy between the data from these sensors aids in the more effective identification and understanding of objects in the environment (Zang et al. 2022). Recent developments in drones suggest that the combination of these products has great potential in estimating tree composition and functional diversity (Sankey et al. 2017).

However, driven by the pursuit of a more comprehensive and accurate understanding of recovering ecosystems, a trend towards the use of LiDAR and/or its combination with other sensors has been observed, totaling around 36% of the studies. The high-quality point clouds generated by LiDAR sensors for spatial metrics can be employed to develop predictive equations for forest inventory attributes such as trunk volume, basal area, and height (Almeida et al. 2019). LiDAR has also proven to be the best option for measuring canopy structural parameters (which can be associated with traditional indicators like biomass, widely used for monitoring restoration projects) as well as structural parameters more directly related to ecological processes (Almeida et al. 2019b).

Regarding the use of multispectral and hyperspectral sensors in forest monitoring, both have been relatively limited, showing the lowest frequencies of use in this review. Although multispectral sensors had an occurrence of 13% when used alone (higher than LiDAR sensors which had only 11% occurrence when used alone), their incidence in combination with other sensors was the second lowest (around 31%), higher only than that of hyperspectral sensors. This can be attributed to a combination of factors, as although these sensor types offer valuable insights into forest health, composition, and dynamics, several challenges and considerations

have influenced their broader adoption. One of the main limiting factors for their use is the high cost. Multispectral and hyperspectral sensors are typically more expensive, and the acquisition and processing of multispectral and hyperspectral data require investments in specialized equipment and specific technical skills (Sankey et al. 2017; Hänsch & Hellwich 2021).

Despite these challenges, it's important to acknowledge the intrinsic advantages of multispectral and hyperspectral sensors. They can provide detailed information about different types of vegetation cover, plant health, environmental stress, and other crucial aspects of forests (Ecke et al. 2022; Hänsch & Hellwich 2021; Li et al. 2021).

Data validation

Forest monitoring through techniques using remote sensors will play a crucial role in tracking the success of ambitious goals to increase forest coverage in deforested and degraded landscapes. However, this implies ensuring that the outcomes provided by these products offer reliable data to assess different aspects of forest diversity, such as tree richness, functional diversity, and composition (Almeida et al. 2021).

In this context, in projects aiming to establish suitable parameters for replication in forest restoration monitoring, forest inventories emerge as invaluable tools. They enable the assessment of accuracy and reliability of information collected by remote sensors and provide a standardized source of training data for models. This increases the likelihood that estimates based on remote techniques align with inventory-based estimates, offering valuable validation data for users interested in conducting accuracy assessments at larger scales. This empowers researchers to make science-based decisions (Lister et al. 2020).

In this review, we were able to observe that 75% of the analyzed studies conducted validation of their results by comparing them with data provided by forest inventories. Subsequently, they assessed the quality of these results using statistical techniques.

Among the 25% (n=13) of the studies that did not utilize forest inventory, a similar trend to the overall analysis was observed, with a preference for the use of RGB or its combinations. Among these, 9 studies employed RGB products. Among these, 3 studies used only RGB images to train software and assess its quality for artificial intelligence (AI) purposes. Additionally, 3 studies combined RGB and multispectral products, followed by 2 studies that combined RGB and hyperspectral data, and 1 study that utilized a combination of RGB and LiDAR data. Among the studies that did not use forest inventory, none solely employed LiDAR or hyperspectral sensors. However, those that combined results from these sensors with RGB considered the data from LiDAR and hyperspectral sensors as "ground truth" and assessed the

quality of the RGB-generated products based on the responses obtained from the former sensors.

It was also observed that the studies which did not utilize forest inventory employed techniques of remote sensing and/or high-resolution digital image processing. Additionally, they involved the development of algorithms for classification through artificial intelligence (AI), followed by statistical tests to measure the quality of the indicators of interest. Examples of these indicators include tree canopy, canopy gaps (Hoi & Dung 2021), and crown delineation (Safonova et al. 2021).

Contributions to the monitoring of forests undergoing restoration

Although sensors mounted on UAVs are increasingly being used in new ways to monitor a wide range of ecosystem health indicators, and based on previous studies that have demonstrated the importance of reducing monitoring costs without losing precision (Almeida et al. 2021; Buters et al. 2019; Dainelli et al. 2019; Dupuis et al. 2020; Robinson et al. 2022), there remains a gap in articles specifically focused on this purpose. Even after the adoption of new keywords, only 9 out of the 53 articles that comprised this portfolio were obtained for the purpose of monitoring forest restoration effectively. This low representation may reflect the technological advancement of UAVs and their current use in forest restoration monitoring only starting from 2019, as previously mentioned, where 65.3% of the studies that composed this portfolio were published between 2019 and 2021.

It is worth noting the existence of 7 studies that, despite being aimed at forest monitoring, mention that their results could be replicated in the monitoring of restored areas and/or emphasize the importance of the findings for the current scenario of forest monitoring in the restoration process (mentioning alignment with the Decade).

Regarding sensors, the most used sensor in this category was Lidar (33%), or a combination of Lidar with other sensors (25%), which can also be considered a limiting factor contributing to this gap due to the high cost associated with this sensor, as well as the high level of technical knowledge required for data analysis (Almeida et al. 2019). However, the trends observed in a general context differ and suggest growth in studies focused on assessing the potential use of RGB products in the analysis of forest indicators. Among these 9 studies, 33% used only RGB or a combination of RGB with others, while among the 53 articles considered, the use of RGB or a combination of RGB with other sensors occurred in 56% of cases, compared to 36% for Lidar and/or a combination of Lidar with other sensors.

Gobbi et al. (2020) aimed to identify and characterize structural, functional, and compositional attributes of the forest using point clouds obtained through the combination of UAVs and Structure from Motion (SfM) technique—a widely used method in photogrammetry to create three-dimensional models of objects or scenes from a set of two-dimensional images. Additionally, (Zhang et al. 2021) demonstrated that digital terrain models and canopy height models, even under dense forest cover, can be derived from point clouds generated by UAVs and aerial photogrammetry.

Regarding forest typology, the same trend of studies in tropical, subtropical, or mixed ecosystems was observed, with 67% of studies occurring in these ecosystems.

A pattern identified relates to the ecological attribute Forest Structure, which showed a higher incidence among these studies, exhibiting the same behavior as found when considering the 53 articles comprising this portfolio. However, it is worth noting that of the 9 studies with the specific purpose of monitoring areas in the process of forest restoration that composed this portfolio, all of them assessed this same attribute, with 6 evaluating it individually, 2 in conjunction with the Ecological Processes attribute, and 1 in conjunction with Forest Composition.

The most significant gap pertains to none of these studies evaluating Forest Composition or Ecological Processes individually, or both, and none of them assessed all three attributes together. The omission of the evaluation of these three ecological attributes in areas undergoing forest restoration can result in an inadequate and limited understanding of the effectiveness and progress of restoration, as each of these attributes plays a crucial role in the recovery of degraded ecosystems and the promotion of healthy and functional ecosystems (Safar et al. 2022).

The failure to assess composition can lead to a restoration that does not properly reintroduce native species, compromising biodiversity and ecosystem functionality (Peng et al. 2021), and the neglect of ecological function assessment may overlook how essential processes like nutrient cycling and climate regulation are re-establishing in the restored ecosystem. This can result in a restoration that cannot provide the necessary ecosystem services to maintain environmental health and benefit the communities that depend on them (Almeida et al. 2019).

Regarding data validation, a concerning bias was noticed as only 5 out of the 9 studies in question used inventories to assess their results. The inclusion of adequate validations is crucial to ensure that the results are reliable and representative of reality, reducing the possibility of distortions or misinterpretations. The lack of inventory usage can compromise the robustness and reliability of the conclusions presented (Lister et al. 2020).

2.5 Final Considerations

Considering the ambitious goals envisioned for the Decade, evidence-based research plays a crucial role in summarizing restoration outcomes towards broad generalizations to promote the practice and science of restoration globally (Romanelli et al. 2021). In this context, this article has presented a systematic literature review, aiming to provide reliable recommendations based on rigorous methods, seeking to offer a comprehensive perspective on the current use of RPAS in forest monitoring.

However, we could observe that despite the wide range of studies using products derived from the combination of RPAs and sensors to obtain/analyze indicators of ecological attributes, there are few studies dedicated exclusively to monitoring areas in the process of forest restoration. This knowledge gap is a significant barrier concerning the ambitious restoration programs planned for the coming years, which have a clear focus on supporting human well-being through ecosystem recovery (Brancalion et al. 2019). Synthesizing existing knowledge based on functional characteristics is imperative to transform the potential of this conceptual approach into successful projects, promoting research in new directions that can better meet the demands of restoration professionals (Carlucci et al. 2020).

The demand for forest monitoring will increase in the next decade, especially in developing countries where financial resources are limited. The combination of more affordable sensors and machine learning techniques emerges as a potential alternative, particularly for analyses on broader scales and with more budget-friendly options, such as those enabled by aerial photogrammetry and remote sensing (Kestur et al. 2018).

Regarding methodologies and sensors, we recommend that researchers expand their focus on the use of more affordable commercial RPAS with RGB sensors, along with machine learning techniques. We emphasize this because, in studies focused on obtaining elevation data or spatial distributions, RGB sensors would offer an excellent cost-benefit ratio when compared to LiDAR.

Regarding forest ecosystems, we recommend conducting studies focused on forest restoration monitoring in different types of forest environments. We noticed a concentration of studies on tropical ecosystems and a gap in boreal ecosystems. We also recommend paying attention to all three ecological attributes, considering the scarcity of research aiming to assess Composition and Ecological Processes.

We hope that our findings can inspire future studies aimed at filling the identified gaps and contributing to the fulfillment of global commitments to restoration and environmental conservation.

Literature Cited

Almeida DRA, Stark SC, Chazdon R, Nelson BW, Cesar RG, Meli P, Gorgens EB, Duarte MM, Valbuena R, Moreno VS, Mendes AF, Amazonas N, Gonçalves NB, Silva CA, Schiatti J, Brancalion PHS (2019) The effectiveness of lidar remote sensing for monitoring forest cover attributes and landscape restoration. *Forest Ecology and Management* 438:34-43

Almeida DRA, Broadbent EN, Zambrano AMA, Wilkinson BE, Ferreira ME, Chazdon R, Meli P, Gorgens EB, Silva CA, Stark SC, Valbuena R, Papa DA, Brancalion PHS (2019b) Monitoring the structure of forest restoration plantations with a drone-lidar system. *International Journal Of Applied Earth Observation And Geoinformation* 79:192–198

Almeida DRA, Broadbent EN, Ferreira MP, Meli P, Zambrano, AMA, Gorgens EB, Resende AF, de Almeida CT, do Amaral CH, Corte APD, Silva CA, Romanelli JP, Prata GA, Papa DA, Stark SC, Valbuena R, Nelson BW, Guillemot J, Feret JB, Chazdon R, Brancalion PHS (2021) Monitoring restored tropical forest diversity and structure through UAV-borne hyperspectral and lidar fusion. *Remote sensing of environment* 264: 112582

Berra EF, Peppas MV (2020) Advances and Challenges of UAV SFM MVS Photogrammetry and Remote Sensing: Short Review. *IEEE Latin American GRSS & ISPRS Remote Sensing Conference (LAGIRS)*, pp. 533-538

Borisova D, Banushev B, Petkov D, Nedkov R, Avetisyan D (2017) Optical hyperspectral measurements of rocks and soils in Central Srednogie, Fifth International Conference on Remote Sensing and Geoinformation of the Environment

Brancalion PHS, Viani RAG, Rodrigues RR, Gandolfi S (2015) *Restauração Florestal. Oficina de Textos*. São Paulo

Brancalion PHS, Goetz S, Reid JL, Strassburg BBN, Wilson S, Chazdon RL, Niamir A, Broadbent E, Crouzeilles R, Barros FSM, Zambrano AMA, Baccini A, Aronson J (2019) Global restoration opportunities in tropical rainforest landscapes. *Science Advances* 5:1–12

Brancalion PHS, de Siqueira LP, Amazonas NT, Rizek MB, Mendes AF, Santiami EL, Rodrigues RR, Calmon M, Benini R, Tymus JRC, Holl KD, Chaves RB (2022) Ecosystem restoration job creation potential in Brazil. *People and Nature* 00:1-9

Boyd J, Banzhaf S (2007) What are ecosystem services? The need for standardized environmental accounting units. *Ecological Economics*, Elsevier 63(2–3): 616-626

Buters TM, Bateman PW, Robinson T, Belton D, Dixon KW, Cross AT (2019) Methodological Ambiguity and Inconsistency Constrain Unmanned Aerial Vehicles as A Silver Bullet for Monitoring Ecological Restoration. *Remote Sensing*. 11(10):1180

Caldwell PH, Bennett T (2020) Easy guide to conducting a systematic review. *J Paediatr Child Health* 56: 853-856

Carlucci MB, Brancalion PHS, Rodrigues RR, Loyola R, Cianciaruso MV (2020) Functional traits and ecosystem services in ecological restoration. *Restor Ecol*, 28: 1372-1383

Castanheiro LF, Tommaselli AMG, Berveglieri A, Campos MB, Junior JM (2021) Modeling Hyperhemispherical Points and Calibrating a Dual-Fish-Eye System for Close-Range Applications. *Photogrammetric Engineering & Remote Sensing* 87(5):375–384

Dainelli R, Toscano P, Di Gennaro SF, Matese A (2021) Recent Advances in Unmanned Aerial Vehicle Forest Remote Sensing—A Systematic Review. Part I: A General Framework. *Forests* 12(3):327

Deo SV (2022) Systematic review and meta-analysis: a brief introduction. *Indian J Thorac Cardiovasc Surg* 38:342–345

de Souza, D.C. (2022), Forest restoration by direct seeding: a global bibliometric analysis. *Restor Ecol*, 30: e13631.

d'Oliveira MVN, Figueiredo EO, de Almeida DRA, Oliveira LC, Silva CA, Nelson BW, da Cunha RM, Papa DA, Stark SC, Valbuena R (2021) Impacts of selective logging on Amazon forest canopy structure and biomass with a LiDAR and photogrammetric survey sequence. *Forest Ecology and Management* 500:119648. ISSN 0378-1127. <https://doi.org/10.1016/j.foreco.2021.119648>.

d'Oliveira MVN, Broadbent EN, Oliveira LC, Almeida DRA, Papa DA, Ferreira ME, Zambrano AMA, Silva CA, Avino FS, Prata GA, et al. (2020) Aboveground Biomass Estimation in Amazonian Tropical Forests: a Comparison of Aircraft- and GatorEye UAV-borne LiDAR Data in the Chico Mendes Extractive Reserve in Acre, Brazil. *Remote Sensing* 12(11):1754. <https://doi.org/10.3390/rs12111754>

Dickinson YL, Pelz KA, Giles E, Howie J (2016) Have we been successful? Monitoring horizontal forest complexity for forest restoration projects. *Scientific Journal (JRNL). Restoration Ecology* 24:8-17

Dupuis C, Lejeune P, Michez A, Fayolle A (2020) How Can Remote Sensing Help Monitor Tropical Moist Forest Degradation?—A Systematic Review. *Remote Sensing* 12(7):1087

Ecke S, Dempewolf J, Frey J, Schwaller A, Endres E, Klemmt H-J, Tiede D, Seifert T (2022) UAV-Based Forest Health Monitoring: A Systematic Review. *Remote Sensing*. 14(13):3205

Evans K, Guariguata MR, Brancalion PHS (2018) Participatory monitoring to connect local and global priorities for forest restoration. *Conservation Biology*, 32: 525-534

FAO (2020) Global forest resources assessment 2020 – key findings. Food and Agriculture Organization of the United Nations, Rome, Italy

Franklin JF, Denison W, Mckee A, Maser C, Sedell J, Swanson F, Juday G (1981) Ecological characteristics of old-growth Douglas-fir forests. General Technical Report. PNW-GTR-118. U.S. Department of Agriculture, Forest Service, Pacific Northwest Research Station, Portland, OR. 48 p

Fu X, Zhang Z, Cao L, Coops NC, Goodbody TRH, Liu H, Shen X, Wu X (2021) Assessment of approaches for monitoring forest structure dynamics using bi-temporal digital aerial photogrammetry point clouds. *Remote Sensing of Environment* 255: 112300. ISSN 0034-4257. <https://doi.org/10.1016/j.rse.2021.112300>.

Gatica-Saavedra P, Echeverría C, Nelson CR (2017) Ecological indicators for assessing ecological success of forest restoration: a world review. *Restor Ecol.* 25: 850-857

Gobbi B, Van Rompaey A, Loto D, Gasparri I, Vanacker V (2020) Comparing Forest Structural Attributes Derived from UAV-Based Point Clouds with Conventional Forest Inventories in the Dry Chaco. *Remote Sensing* 12(23):4005

Hänsch R, Hellwich O (2021) Fusion of Multispectral LiDAR, Hyperspectral, and RGB Data for Urban Land Cover Classification. *IEEE Geoscience and Remote Sensing Letters* 18(2): 366-370

Hoi ND, Dung NT (2021). Seasonal Dynamics of Tropical Forest Vegetation in Ngoc Linh Nature Reserve, Vietnam Based on UAV Data. *Forest and Society*, 5(2):376-389

Holl KD, Aide TM (2011) When and where to actively restore ecosystems? *Forest Ecology and Management*, 261(10):1558-1563

Hubbell SP, Foster RB, O'brien ST, Harms KE, Condit B, Weschsler B, Wright SJ, Loo De Lao S (1999) Light-gap disturbance, recruitment limitation, and tree diversity in a Neotropical Forest. *Science* 283:554-557

ISPRS (International Society for Photogrammetry and Remote Sensing). ISPRS - Historical Background (2023). <https://www.isprs.org/> Consulted on 08/20/2023.

SER (Society for Ecological Restoration). 2004. Society for ecological restoration international's primer of ecological restoration. Available from: <http://www.ser.org/resources/resources-detail-view/ser-international-primer-on-ecological-restoration>).

Kahraman S, Bacher R (2021) A comprehensive review of hyperspectral data fusion with lidar and sar data. *Annual Reviews In Control* 51:236–253

Kestur R, Angural A, Bashir B, Omkar SN, Anand G, Meenavathi MB (2018) Tree Crown Detection, Delineation and Counting in UAV Remote Sensed Images: A Neural Network Based Spectral–Spatial Method. *J Indian Soc Remote Sens* 46:991–1004

Ladouceur E, Shackelford N (2020) The power of data synthesis to shape the future of the restoration community and capacity. *Restoration Ecology* 29:e13251

Lindenmayer DB, Hulvey KB, Hobbs RJ, Colyvan M, Felton A, Possingham H, Steffen W, Wilson K, Youngentob K, Gibbons P (2012) Avoiding bio-perversity from carbon sequestration solutions. *Conservation Letters* 5:28-36

Lister AJ, Andersen H, Frescino T, Gatzolis D, Healey S, Heath LS, Liknes GC, McRoberts R, Moisen GG, Nelson M (2020) Use of Remote Sensing Data to Improve the Efficiency of National Forest Inventories: A Case Study from the United States National Forest Inventory. *Forests* 11(12):1364

Li X, Zhang M, Long J, Lin H. (2021) A Novel Method for Estimating Spatial Distribution of Forest Above-Ground Biomass Based on Multispectral Fusion Data and Ensemble Learning Algorithm. *Remote Sensing*. 13(19):3910

Matzek V (2018) Turning delivery of ecosystem services into a deliverable of ecosystem restoration. *Restor Ecol* 26: 1013-1016

MEA (Millennium Ecosystem Assessment). 2005. Ecosystems and human well-being: synthesis. Island Press. Washington, DC. Available from: <https://www.millenniumassessment.org/en/index.html>

Nedelcu D, Gillich GR, Malin-Tatian C (2019) A comparative study about some application packages used in Photogrammetry. *IOP Conf. Ser.: Mater* 564:012054

Noss RF (1990) Indicators for monitoring biodiversity: a hierarchical approach. *Conservation Biology* 4: 355–364

Nuijten RJG, Coops NC, Watson C, Theberge D (2021) Monitoring the Structure of Regenerating Vegetation Using Drone-Based Digital Aerial Photogrammetry. *Remote Sensing* 13(10):1942. <https://doi.org/10.3390/rs13101942>

- Parron LM, Fidalgo ECC, Luz AP, Campanha MM, Turetta APD, Pedreira BCCG, Prado RB (2019) Research on ecosystem services in Brazil: a systematic review. *Ambiente & Água - An Interdisciplinary Journal of Applied Science* 14(3):2263
- Peng X, Chen ZC, Chen YF, Chen Q, Liu HD, Wang J, Li HY (2021) Modelling of the biodiversity of tropical forests in China based on unmanned aerial vehicle multispectral and light detection and ranging data. *International Journal of Remote Sensing* 42:23:8858-8877
- Peng Z, Xiong Z, Zhao Y, Zhang L (2023) 3-D Objects Detection and Tracking Using Solid-State LiDAR and RGB Camera. *IEEE Sensors Journal* 23(13): 14795-14808
- Poley LG, McDermid GJ (2020) A systematic review of the factors influencing the estimation of vegetation aboveground biomass using unmanned aerial systems. *Remote Sensing* 12:7
- Robinson JM, Harrison PA, Mavoa S, Breed MF (2022) Existing and emerging uses of drones in restoration ecology. *Methods in Ecology and Evolution*, 13:1899–1911
- Rodrigues Rr, Lima Raf, Gandolfi S, Nave Ag (2009) On the restoration of high diversity forests: 30 years of experiences in the Brazilian Atlantic Forest. *Biological Conservation* 142(6):1242-1251
- Rohr JR, Bernhardt E, Cadotte MW, Clements W (2018) The ecology and economics of restoration: when, what, where, and how to restore ecosystems. *Ecology and Society* 23(2):15
- Romanelli JP, Silva LGM, Gonçalves MCP, Naves RP, de Almeida DRA, de Resende AF, Rodrigues RR (2021) Repeatability of the searching process in reviews of restoration outcomes. *Restor Ecol*, 29: e13496
- Ruiz-Jaen MC, Aide TM (2005a). Restoration success: how is it being measured? *Restoration Ecology* 13: 569–577
- Safar NV, van der Sande M, Schaefer CEG, Magnago LFS, Martins SV, Simonelli M, Poorter L (2022) Landscape openness has different effects on the structure, diversity and functional composition of Brazilian rainforests. *Forest Ecology and Management*, 520: 120395.

Safonova A, Hamad Y, Dmitriev E, Georgiev G, Trenkin V, Georgieva M, Dimitrov S, Iliev M. Individual Tree Crown Delineation for the Species Classification and Assessment of Vital Status of Forest Stands from UAV Images. *Drones*. 2021; 5(3):77

Sankey T, Donager J, McVay J, Sankey JB (2017) UAV lidar and hyperspectral fusion for forest monitoring in the southwestern U.S.A. *Remote Sensing of Environment*. 195: 30–43

SER (Society for Ecological Restoration). 2004. Society for ecological restoration international's primer of ecological restoration. Available from: <http://www.ser.org/resources/resources-detail-view/ser-international-primer-on-ecological-restoration>).

Shen X, Cao L, Coops NC, Fan H, Wu X, Liu H, Wang G, Cao F (2020) Quantifying vertical profiles of biochemical traits for forest plantation species using advanced remote sensing approaches. *Remote Sensing of Environment* 250:112041. ISSN 0034-4257. <https://doi.org/10.1016/j.rse.2020.112041>.

Siddaway AP, Wood AM, Hedges LV (2019) How to Do a Systematic Review: A Best Practice Guide for Conducting and Reporting Narrative Reviews, Meta-Analyses, and Meta-Syntheses. *Annu Rev Psychol*. 70:747-770

Sothe C, Dalponte M, Almeida CMd, Schimalski MB, Lima CL, Liesenberg V, Miyoshi GT, Tommaselli AMG (2019) Tree Species Classification in a Highly Diverse Subtropical Forest Integrating UAV-Based Photogrammetric Point Cloud and Hyperspectral Data. *Remote Sensing*. 11(11):1338.

Tedesco AM, López-Cubillos S, Chazon R, Rhodes JL, Archibald CL, Pérez-Hämmerle KV, Brancalion PHS, Wilson KA, Oliveira M, Correa DF, Ota L, Morrison TH, Possingham HP, Mills M, Santos FC, Dean AJ (2023) Beyond ecology: ecosystem restoration as a process for social-ecological transformation. *Trends in Ecology & Evolution* 38(7):643-653

Torres G, Leydy K, Martínez DV, Saba M (2023) The Widespread Use of Remote Sensing in Asbestos, Vegetation, Oil and Gas, and Geology Applications. *Atmosphere* 14(1):172

Valbuena R, Hernando A, Manzanera JS, Görgens EB, Almeida DRA, Mauro F, García-Abril A, Coomes DA (2017) Enhancing of accuracy assessment for forest above-ground biomass estimates obtained from remote sensing via hypothesis testing and overfitting evaluation. *Ecological Modelling* 366:15-26

White JC, Coops N, Wulder MA, 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 JC, Wulder MA, Hermosilla T, Coops NC, Hobart GW (2017) A nationwide annual characterization of 25years of forest disturbance and recovery for Canada using Landsat time series. *Remote Sensing of Environment* 194:303-321

Wolf PR, Dewitt BA (2004) *Elements of Photogrammetry with Application in GIS*. 3^a ed. USA: McGraw-Hill, 2004.

Wortley L, Hero J-M, Howes M (2013) Evaluating Ecological Restoration Success: A Review of the Literature. *Restor Ecol*, 21: 537-543.

Xiaoyan S, Jianghui S, Haijiang W, Xin L, Tian T, Jingang W, Weidi L, Mingtao Z, Menghao J (2023) Improving the monitoring of root zone soil salinity under vegetation cover conditions by combining canopy spectral information and crop growth parameters. *Frontiers in Plant Science* 14: 1664-462X

Zhang H, Bauters M, Boeckx P (2021) Van Oost K. Mapping Canopy Heights in Dense Tropical Forests Using Low-Cost UAV-Derived Photogrammetric Point Clouds and Machine Learning Approaches. *Remote Sensing*. 2021; 13(18):3777

Zhang Z , Liang Z, Zhang, M, Zhao X, Li H, Yang M, Tan W, Pu S, Liang ZD (2022) RangeLVDet: Boosting 3D Object Detection in LIDAR With Range Image and RGB Image. *IEEE Sensors Journal*. 22(2):1391-1403

3. DELINEAMENTO DA PESQUISA: VISÃO GERAL

Nesta seção, faremos uma abordagem geral e detalhada das principais etapas envolvidas no estudo, desde os trabalhos de campo até os processos de tratamento e análise dos dados. Exploraremos os procedimentos metodológicos adotados para garantir a obtenção de resultados precisos e alinhados aos objetivos propostos. Nesta tese, o objetivo foi avaliar a acurácia posicional de produtos RGB e LiDAR, considerando a inserção de pontos de controle no processamento. Para isso, foi necessário primeiro abordar a questão central da acurácia, que está relacionada ao conhecimento do valor "verdadeiro" de uma variável. Com isso em mente, na Etapa 1, descrita no Capítulo 4 desta tese, detalhou-se a implantação da Rede Cepegeo, uma rede geodésica de alta precisão, materializada com o objetivo de analisar a acurácia posicional dos pontos de controle, composta por quinze vértices. Os vértices foram levantados utilizando técnicas convencionais de topografia e geodésia, e os dados obtidos foram ajustados para determinar as coordenadas e as precisões de cada ponto. Essas informações foram organizadas em memoriais descritivos, que podem ser acessados por meio do Centro de Pesquisa e Extensão em Geotecnologias (CePE-Geo).

Com a Rede Cepegeo implantada, a etapa 2, apresentada no capítulo 5 consistiu na análise da acurácia das diferentes metodologias de posicionamento GNSS, levando em conta diferentes tempos de rastreamento e cenários de campo. Foram realizados levantamentos utilizando as metodologias mais comuns empregadas por profissionais da área. Os vértices foram escolhidos para simular condições práticas de uso, incluindo o monitoramento remoto de florestas. Os pontos de controle foram posicionados em áreas adjacentes a florestas e em florestas com copas de baixa densidade, representando cenários típicos de locais abertos, considerados "situações ideais" para técnicas de posicionamento relativo. Além disso, foram investigados cenários mais desafiadores, como vértices próximos a encostas de morros, corpos d'água (como lagos) e edificações, além de florestas com copas de média e alta densidade.

Os levantamentos ocorreram em diferentes períodos, com tempos de rastreamento variando de 1 a 2 minutos a 44 horas. Para aumentar a abrangência das análises, as coletas foram realizadas em diversas datas e estações do ano. Com base nos resultados, foi elaborada uma tabela que apresentou as acurácias encontradas, considerando o custo-benefício, tempo de coleta, método utilizado e a situação do ponto de controle.

Na etapa 3, apresentada no capítulo 6, com o intuito de avaliar a acurácia posicional de produtos RGB e LiDAR no contexto de monitoramento florestal remoto, foi realizado um estudo de caso em uma área em processo de restauração florestal. Foram implantados 90 pontos de controle, distribuídos em 60 pontos de controle horizontal (GCPs), e 30 pontos de controle

verticais, divididos em 15 VCPs (Pontos de Controle Verticais) e 15 TCPs (Pontos de Controle de Árvore), com diferentes densidades de copa. As coordenadas desses pontos foram obtidas por meio de levantamentos topográficos, utilizando estação total, nível e GNSS, conforme os resultados da etapa anterior.

Em seguida, foram realizados voos com drones equipados com sensores RGB e LiDAR, e os dados coletados foram processados com softwares freemium. Esse processamento gerou ortomosaicos, DTMs e DSMs a partir das imagens RGB, utilizando os softwares Metashape e QGIS. Para o processamento dos dados RGB, foram criados 14 cenários distintos, variando desde a ausência de pontos de controle até a inclusão de 60 pontos de controle horizontais.

A classificação das nuvens de pontos LiDAR e a geração dos CHMs foram realizadas com o software DJI Terra para o processamento das nuvens de pontos, enquanto o QGIS foi utilizado para análises detalhadas, incorporando pontos de controle verticais, a fim de melhorar a precisão dos resultados.

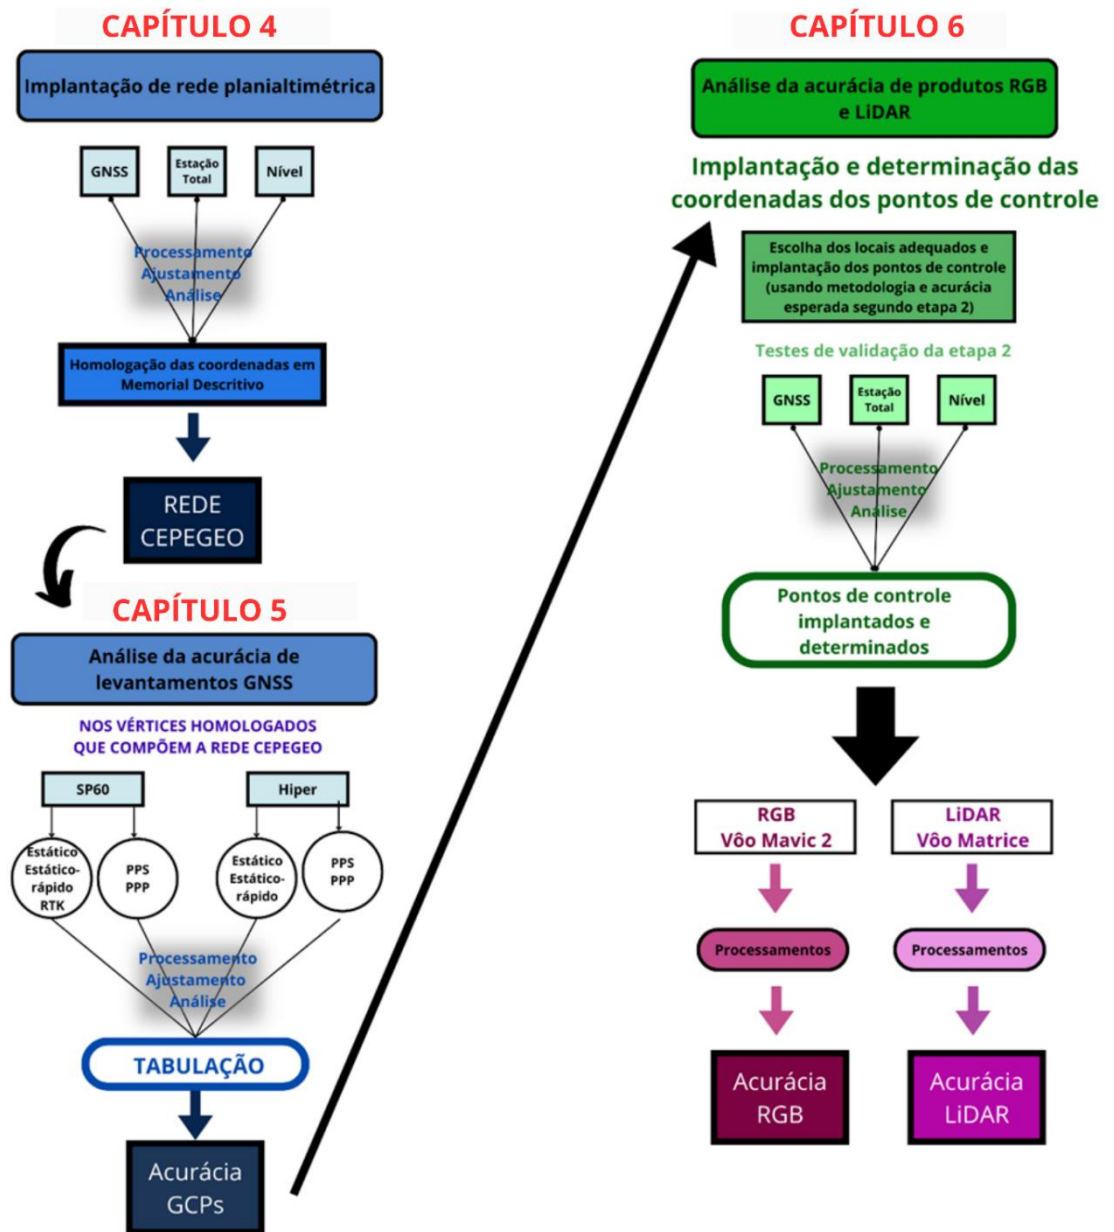
Com os produtos gerados, as coordenadas foram convertidas para o sistema UTM e comparadas com as coordenadas homologadas, passando por tratamento estatístico. No caso do LiDAR, também foram avaliadas as distâncias geométricas para verificar tanto deslocamentos quanto eventuais distorções nos produtos gerados.

Os dados foram processados exclusivamente com softwares comerciais, utilizando apenas as ferramentas livres disponibilizadas pelos mesmos. Além disso, o estudo levou em consideração a influência da quantidade e do tipo de pontos de controle inseridos nos processamentos, bem como os resultados obtidos no pré e pós-processamento e a acurácia posicional dos próprios pontos de controle.

Com base nos resultados obtidos, foram elaboradas tabelas diretrizes para indicar o melhor custo-benefício em termos de acurácia posicional dos pontos de controle obtidos por GNSS. Também foi analisado o impacto da inserção desses pontos na qualidade final dos produtos RGB, identificando o número de pontos de controle necessário para otimizar a precisão e determinar a quantidade ideal para obter produtos RGB com maior acurácia.

A Figura 3 apresenta uma visão geral da metodologia adotada nesta tese, estabelecendo a relação entre os processos executados e os capítulos em que são detalhados.

Figura 3: Metodologia – Visão Geral.



4. CONECTANDO PAISAGENS: IMPLANTAÇÃO DE UMA REDE GEODÉSICA MATERIALIZADA EM AMBIENTES IDEAIS, FLORESTAIS E DIVERSOS

RESUMO

Enquanto mudanças climáticas sem precedentes estão ocorrendo em escala global, torna-se primordial restaurar e preservar ecossistemas florestais, visando mitigar os efeitos das mudanças climáticas. Nesse cenário, mensurar o estoque de carbono positivo das florestas é uma tarefa de importância crítica nas ações de restauração, no entanto, é de extrema importância afastar-se das metodologias tradicionais e desenvolver tecnologias que possibilitem o monitoramento em larga escala. Os drones, e uma ampla variedade de sensores remotos, emergem como ferramentas poderosas, proporcionando insights valiosos para tomadas de decisão, contudo, tais tecnologias dependem fundamentalmente do GNSS, onde, no intuito de alcançar melhores resultados, contar com a existência de uma infraestrutura geodésica robusta torna-se primordial. As redes geodésicas locais têm um papel crucial, complementando a infraestrutura nacional, entretanto, em muitas regiões, especialmente em ambientes florestais, há lacuna dessas redes, limitando a eficácia das geotecnologias no monitoramento e gestão de paisagens diversas. Outro fator diz respeito à ausência de estudos mesclando vértices em situações ideais e não ideais, como adjacências de floresta e edificações. Visando suprir tais lacunas, este estudo apresenta as etapas e técnicas utilizadas na implantação da Rede Geodésica Cepegeo, composta por quinze vértices implantados em ambientes diversos. Todos os vértices foram levantados por técnicas da topografia convencional e geodésia. Posteriormente tais dados foram ajustados, possibilitando a obtenção das coordenadas e precisões de cada vértice, sendo organizados em memoriais descritivos que podem ser acessados através do Centro de Pesquisa e Extensão em Geotecnologias (CePE-Geo).

Palavras-chave: Precisão; GNSS; Geodésia; Topografia; Qualidade Posicional.

ABSTRACT

While unprecedented climate changes are occurring on a global scale, it is crucial to restore and preserve forest ecosystems in order to mitigate the effects of climate change. In this context, measuring the positive carbon stock of forests is a critically important task in restoration efforts. However, it is essential to move away from traditional methodologies and develop technologies that enable large-scale monitoring. Drones, along with a wide range of remote sensing sensors, emerge as powerful tools, providing valuable insights for decision-making. However, these technologies fundamentally rely on the Global Navigation Satellite System (GNSS), where, in

order to achieve better results, having a robust geodetic infrastructure becomes paramount. Local geodetic networks play a crucial role in complementing national infrastructure; however, in many regions, particularly in forested environments, there is a gap in these networks, limiting the effectiveness of geotechnologies in monitoring and managing diverse landscapes. Another factor concerns the lack of studies combining vertices in both ideal and non-ideal situations, such as forest edges and built-up areas. Aiming to fill these gaps, this study presents the steps and techniques used in the implementation of the Cepegeo Geodetic Network, composed of fifteen vertices established in diverse environments. All vertices were surveyed using conventional topographic and geodetic techniques. Subsequently, the data was adjusted, enabling the determination of the coordinates and precisions of each vertex, which were organized into descriptive memorials accessible through the Center for Research and Extension in Geotechnologies (CePE-Geo).

Keywords: Precision; GNSS; Geodesy; Topography; Positional Accuracy

4.1 Introdução

Em meio a mudanças climáticas sem precedentes e em escala global, as florestas desempenham papéis significativos no ciclo global do carbono e na preservação e restauração das florestas, bem como a compreensão de sua dinâmica torna-se imperativa (Liang, 2023), no entanto, no cenário atual, um dos principais desafios no monitoramento de florestas consiste em medir e monitorar as variáveis florestais de maneira eficaz e precisamente, além de menos onerosas, posto que normalmente a medição destas depende de massivas campanhas de campo (Gómez et al 2019; Dupuis et al 2020; da Costa & Quintanilha, 2024; Nishiwaki et al., 2023).

Contudo, é crucial afastar-se das metodologias tradicionais dispendiosas e desenvolver tecnologias que possibilitem um monitoramento em larga escala usando ferramentas mais acessíveis e econômicas. O advento dos RPAS (sistemas de aeronaves remotamente pilotadas, do inglês, Remotely Piloted Aircraft Systems), comumente conhecidos como drones, e de uma ampla gama de sensores capazes de gerar imagens de alta resolução, possibilitou o desenvolvimento de novas abordagens provenientes de sensoriamento remoto e aerofotogrametria (Ball et al., 2023; Liang, 2023; Sinaglia et al, 2023; White et al, 2017). Várias revisões sobre o tema vêm sendo publicadas, atraindo gradualmente a atenção de pesquisadores científicos e da indústria, devido às suas amplas perspectivas de aplicação nas mais diversas áreas, desde aplicações gerais dos mesmos até em áreas específicas (Zhang et al. 2023).

Alves 2023 por exemplo, analisou o uso de um drone compacto e de baixo custo, avaliando seu desempenho, as vantagens que oferece e os principais desafios encontrados na coleta de imagens em comunidades tradicionais na Amazônia brasileira. Já Filho & Silva 2024, efetuaram a classificação da cobertura do solo utilizando imagens RGB e multiespectrais adquiridas por drone em área de floresta seca.

No entanto, um desafio persiste em relação às precisões desses produtos. Diversas pesquisas, investigam a qualidade posicional dos mesmos, mostrando que a preocupação com os erros tem sido uma constante desde os primeiros estudos sobre drones, iniciados na década de 1990; Haspel (1996), por exemplo, examinou a influência dos erros aleatórios na qualidade dos resultados obtidos, desconsiderando os erros sistemáticos.

Neste cenário, visando minimizar os efeitos que possam ocasionar degradação na qualidade desses produtos, é comum a adoção de pontos de controle, que possuem coordenadas definidas usualmente através de levantamentos utilizando receptores GNSS distribuídos estrategicamente na área a ser mapeada, de modo a serem facilmente identificados nas imagens geradas (Sefercik et al., 2023; Singh et al 2023).

Cevick et al 2024 por exemplo investigou o efeito do número e da distribuição de pontos de controle terrestre no processo de correção geométrica das imagens de satélite, e os resultados demonstraram que a distribuição apropriada dos GCPs melhorou significativamente a precisão das ortoimagens.

Contudo, a adoção de GCPs obtidos esporadicamente nas áreas de interesse não é suficiente, sendo crucial que tais pontos sejam respaldados por uma infraestrutura geodésica sólida, e apesar dos avanços tecnológicos e da crescente adoção de técnicas geodésicas em diferentes setores, muitas regiões ainda enfrentam lacunas significativas em sua infraestrutura geodésica (Kobryń, 2019; Santana & Dalazoana, 2020).

Na maioria das cidades brasileiras, ainda há deficiência de bases geodésicas e cartográficas que atendam a essas especificações, sendo, muitas vezes, desatualizadas ou até inexistentes, o que ocasiona uma série de complicações, que vão desde a degradação da qualidade nos levantamentos topográficos até grandes desastres estruturais (Michels et al., 2021).

Uma infraestrutura geodésica robusta basicamente se resume a materialização de pontos com referencial geodésico de alta precisão, compondo uma base cartográfica com estrutura compatível com as modernas técnicas de posicionamento, fornecendo suporte para operações geodésicas em todos os níveis, onde as redes geodésicas locais desempenham um papel

fundamental na complementação e na integração com a infraestrutura geodésica nacional (Kobryń, 2019; Weiss et al., 2022).

Enquanto as redes nacionais estabelecem uma base sólida de referência espacial em grande escala, as redes locais fornecem detalhes e informações específicas para áreas menores e mais detalhadas, sendo crucial a interligação entre as redes geodésicas locais e a infraestrutura geodésica nacional com o intuito de garantir consistência e precisão dos dados geodésicos em todo o território (IBGE, 2024a).

Tradicionalmente, levantamentos que visem monitoramentos são executados com Estações Totais, medidores eletrônicos de distância e receptores GNSS (Javadi et al 2024), onde uma estratégia eficaz que pode ser aplicada, com o intuito de melhorar a qualidade das redes geodésicas, é a combinação dos levantamentos por receptores GNSS com levantamentos que fazem uso das técnicas da topografia convencional (como as que utilizam estação total), posto que, enquanto os levantamentos topográficos convencionais oferecem detalhes locais precisos sobre o terreno e características específicas, os levantamentos geodésicos garantem uma abrangência e precisão global necessárias para estabelecer uma referência geoespacial confiável em larga escala (Weiss et al., 2022).

Posicionar-se sempre foi uma preocupação experimentada pelos homens. No início da evolução humana, quando viviam em pequenos grupos isolados, enfrentavam-se desafios como escassez de recursos e conflitos, o que os levava a buscar novos locais para se estabelecer. Nesse contexto, além da necessidade de se orientar e posicionar, surgiu a demanda por mapeamento, envolvendo o registro dos itinerários em seus deslocamentos. Esses registros eram feitos com instrumentos simples, como bastões e cordas, para medir distâncias e ângulos entre pontos de referência. Esses dados eram então utilizados para criar mapas e representações básicas do terreno, fundamentais para a sobrevivência e organização das comunidades antigas, dando origem aos primeiros conceitos da topografia convencional. (Rocha & Rocha, 2021).

Assim, o termo topografia convencional refere-se ao método tradicional de medição e representação de uma porção da superfície terrestre através do uso de instrumentos ópticos e técnicas de levantamento visando determinar, através de princípios trigonométricos, a posição tridimensional dos pontos de interesse. No entanto, com o avanço das civilizações e a necessidade de mapear áreas cada vez maiores, surgiu a geodésia como uma ciência mais complexa e abrangente. A geodésia é o ramo da ciência que lida com a medição e a representação da forma e das dimensões da Terra. Envolve o uso de técnicas mais sofisticadas, como o emprego de observações astronômicas para determinar as dimensões e formas da Terra em grande escala, considerando a curvatura terrestre (Nero et al., 2023; Dantas & Costa, 2024).

Com o advento da Era Espacial e a introdução dos sistemas de posicionamento global por satélites artificiais, como o GNSS, as atividades geodésicas passaram por uma revolução significativa, posto que esses sistemas possibilitam a determinação precisa das coordenadas geográficas de pontos de interesse, fornecendo uma referência global que combina rapidez e alta precisão, superando os métodos clássicos de levantamento. Como resultado, eles atendem a demandas tanto da comunidade acadêmica e científica quanto do setor prático (Jin et al., 2022; Ocalan, 2022; IBGE, 2024b), tornando-se essenciais em diversas áreas de atuação.

Um exemplo de aplicação é a regularização de imóveis rurais no Brasil, para a qual foi criada a Lei nº 10.267, em 2001, que tornou obrigatório o georreferenciamento desses imóveis. Nesse contexto, os levantamentos realizados por GNSS se destacam como os mais utilizados para esse fim (Paiva et al., 2021). Além disso, o posicionamento por GNSS tem sido amplamente aplicado em levantamentos voltados para o posicionamento e dimensionamento de parcelas florestais (Caizzzone, 2021).

Visando atender às necessidades das diversas áreas que utilizam o GNSS, diferentes métodos foram desenvolvidos, os quais podem ser basicamente classificados em duas modalidades: posicionamento absoluto e posicionamento relativo (Krueger et al., 2020; Caizzzone, 2021; Jin et al., 2022).

O posicionamento relativo é uma técnica usada particularmente quando há duas estações coletando simultaneamente observações. Há diversas técnicas de posicionamento relativo, e em todas elas há a necessidade de dois receptores rastreando simultaneamente, sendo um deles instalado em área aberta (sem obstruções), devendo rastrear durante todo o levantamento, ou por no mínimo 4 horas, denominado base, e o segundo equipamento, denominado rover, percorrendo os vértices de interesse respeitando os procedimentos da técnica escolhida (Peng et al., 2021; Kim & Kim, 2022; Paula et al., 2023).

O que diferencia as técnicas de posicionamento relativo é o procedimento adotado com o rover em campo. O processamento dos dados ocorre em duas etapas: inicialmente, processa-se e ajusta-se o vértice base, e, em seguida, utiliza-se as coordenadas corrigidas e ajustadas da base para processar as coordenadas dos vértices levantados com o rover. Em aplicações geodésicas no Brasil, ao utilizar o método relativo com GNSS, o usuário pode recorrer aos dados das estações da Rede Brasileira de Monitoramento Contínuo (RBMC) para o processamento e ajustamento da base. A RBMC foi iniciada no final de 1996, com o objetivo de estabelecer uma infraestrutura geodésica de referência para posicionamentos com o uso das modernas técnicas GNSS. Essa rede facilita o uso do sistema pelo usuário e garante a qualidade dos resultados obtidos. Antes de disponibilizar as observações para os usuários, é realizado um

controle de qualidade dos dados. Após essa verificação, os arquivos de observação são liberados pela internet, e seus dados podem ser utilizados tanto em trabalhos práticos quanto em pesquisas científicas (IBGE, 2024a).

No posicionamento absoluto, também conhecido como posicionamento por ponto, a posição do vértice de interesse é determinada no sistema de referência do GNSS necessitando de apenas um receptor. Pode ser dividido em duas técnicas: PPS (Posicionamento por Ponto Simples), onde não se efetua processamento, ou seja, os dados são utilizados sem refinamento estatístico, e PPP (Posicionamento por Ponto Preciso), também conhecido como posicionamento por ponto, onde a posição do vértice de interesse é determinada no sistema de referência GNSS com processamento e correções via software, mas sem a necessidade da utilização de uma estação conhecida (Krueger et al., 2020; Freitas et al., 2022; Ocalan, 2022; Atiz et al., 2023; IBGE 2024b).

Uma questão de suma importância diz respeito ao controle da qualidade posicional tanto dos vértices que compõem as redes geodésicas existentes, quanto dos GCPs, visto que trabalhos de mensuração envolvem diversas etapas, que vão desde o planejamento até o processamento dos dados obtidos, e em qualquer atividade que envolva a obtenção de medidas sempre existe algum tipo de erro associado (Michels et al., 2021).

Tais erros podem ser classificados em grosseiros, sistemáticos e aleatórios, onde os erros grosseiros normalmente são oriundos da falta de experiência ou por desatenção de quem realiza o processo de medição, os aleatórios são erros cuja causa tem um caráter randômico, ou seja, não podem ser associados a uma causa específica, e os erros sistemáticos ocorrem devido às condições do meio e imperfeições nos equipamentos. (Gemael, 1994; Weiss et. al., 2022). Assim, os erros sistemáticos podem indicar algum problema no instrumento de medição e os erros aleatórios ou acidentais são aqueles que ocorrem de maneira fortuita, ao acaso (Gemael, 1994; Pourreza et al., 2022).

No que diz respeito à levantamentos utilizando receptores GNSS de precisão, os erros sistemáticos mais impactantes dizem respeito ao erro orbital dos satélites (que ocorre porque os satélites GNSS não seguem órbitas perfeitamente estáveis devido a perturbações gravitacionais e outras influências), aos erros dos relógios (os receptores GNSS dependem da precisão dos relógios atômicos embarcados nos satélites para medir o tempo de propagação dos sinais. Se houver desvio na sincronização do relógio, seja no satélite ou no receptor, isso pode afetar significativamente a precisão do posicionamento), bem como ao multicaminhamento (que ocorre quando os sinais GNSS são refletidos por superfícies próximas, como edifícios, árvores ou terrenos acidentados antes de alcançar o receptor, podendo resultar em leituras distorcidas

ou atrasadas, levando a uma determinação imprecisa da posição). Por outro lado, no que diz respeito aos erros aleatórios incluem o ruído do receptor, que são variações aleatórias devido a condições ambientais ou interferências eletromagnéticas, e as condições atmosféricas variáveis, que podem causar variações nas propriedades dos sinais GNSS ao atravessar a atmosfera terrestre (Setti et al., 2020; Freitas et al., 2023; Paula et. al., 2023; Peng et al., 2023).

Obviamente, por se tratar de processos de obtenção de medidas, a topografia convencional também está sujeitas à fatores que podem ocasionar erros de levantamentos, onde as principais fontes de erros sistemáticos dizem respeito à calibração dos instrumentos utilizados nos levantamentos. Assim, se os instrumentos não estiverem devidamente calibrados ou apresentarem desgaste, isso pode introduzir um viés sistemático nas medições. Por outro lado, os erros aleatórios são variações não sistemáticas nas medições, que podem ocorrer de forma imprevisível, e incluem, por exemplo, erros de observação, que podem resultar de fatores como vibrações do equipamento, movimentos do operador ou variações na luminosidade durante as medições (Nero et al., 2023; Dantas & Costa, 2024).

Vale ressaltar que tanto em levantamentos nas técnicas da topografia convencional, quanto por receptores GNSS, são aplicadas medidas visando minimizar os efeitos desses erros, como, por exemplo, no que diz respeito à topografia convencional, costuma-se efetuar levantamentos considerando poligonais fechadas (para cálculo dos erros angulares e lineares, e posterior correção dos mesmos), e nos levantamentos GNSS, os profissionais utilizam técnicas avançadas de processamento de dados, como modelos atmosféricos para compensar os efeitos da ionosfera e troposfera, e filtros de dados para mitigar o impacto de ruídos e interferências (Dantas & Costa, 2024; Paula et. al., 2023; Peng et al., 2023).

Contudo, ao combinar ambos os métodos, pode-se inferir tratamentos estatísticos visando melhorar a precisão geral das medições, e neste trabalho, o ajustamento escolhido foi o Método dos Mínimos Quadrados (MMQ). Tal método visa estimar e corrigir erros sistemáticos, além de reduzir o impacto dos erros aleatórios nas medições (Weiss et al., 2022).

O ajustamento de observações faz parte de um ramo da matemática aplicada e o seu principal objetivo é uma solução única para problemas onde existe uma abundância de observações e o sistema de equações lineares é consistente. O ajustamento também tem por objetivo a estimativa de qualidade da solução e utiliza a expansão do método dos mínimos quadrados (MMQ) desenvolvidos por Gauss e Legendre (Gemael 1994), que consiste em uma técnica de otimização de um conjunto de valores de modo a minimizar a soma dos quadrados dos resíduos entre os valores observados e os valores estimados, sendo essencial existir um número maior de observações com relação ao número de incógnitas, e usualmente os softwares

comerciais de ajustamento GNSS proporcionam análise do controle de qualidade do ajustamento, através do Teste Tau (teste que utiliza os resíduos normalizados de cada observação para avaliar se, estatisticamente, estão dentro dos limites previstos) (Gemael, 1944; Weiss et al, 2022).

Outra questão a ser considerada diz respeito à escolha dos locais para a materialização da rede, onde os marcos geodésicos da maioria das redes normalmente são implantados em locais ditos de situação ideal, ou seja, sem estruturas e/ou objetos próximos devido à influência na qualidade do sinal e/ou multicaminhamento (Kobryń, 2019), porém, os profissionais da área de mensuração encontram situações adversas em campo, desde regiões com alto índice de corpos d'água, até perímetros urbanos com alta incidência de edificações, e há ausência de trabalhos mencionando a qualidade posicional desses vértices.

Neste estudo, visando contribuir com a infraestrutura geodésica nacional, procedeu-se à implantação de uma rede geodésica local, denominada Rede Cepegeo, cujos vértices foram materializados considerando tanto situações ditas “ideais” (com vértices materializados em áreas menos propensas aos fatores que influenciam na qualidade dos dados GNSS), como foram implantados vértices considerando as diversas situações comumente encontradas pelos profissionais das áreas de mensuração, como pontos em áreas de floresta ou próximas a elas, além de próximas a encostas de morros, “corpos d'água” e edificações.

No que diz respeito à qualidade posicional de levantamentos topográficos georreferenciados, este trabalho utilizou uma combinação de técnicas oriundas da topografia convencional e de posicionamento por GNSS, onde as coordenadas obtidas foram tabeladas e, posteriormente, ajustadas, possibilitando atribuir coordenadas finais para cada vértice da rede, e suas respectivas precisões, onde memoriais descritivos fornecendo as coordenadas, precisões e demais informações de cada vértice foram elaborados. Tais documentos foram disponibilizados ao CePE-Geo, podendo ser acessados por toda comunidade científica e acadêmica.

A implantação da rede geodésica descrita neste trabalho representa um marco significativo para a comunidade científica, acadêmica e profissional, posto que o desenvolvimento e a expansão contínua de uma infraestrutura geodésica são essenciais para atender às demandas crescentes por informações geoespaciais precisas e confiáveis, e o investimento na criação e manutenção de redes geodésicas robustas e interconectadas são fundamentais para impulsionar a inovação e o progresso em áreas que dependem da precisão e da exatidão das informações espaciais.

Espera-se que os resultados obtidos por meio desta rede proporcionem uma base sólida para avanços em diversas áreas, incluindo cartografia de alta precisão, monitoramento geodésico,

planejamento urbano, estudos ambientais e outros. Além disso, esta iniciativa visa não apenas gerar conhecimento científico de alta qualidade, mas também fornecer ferramentas e informações práticas para o desenvolvimento e implementação de projetos de engenharia, infraestrutura e políticas públicas.


4.2 Materiais e Métodos

Nesta seção, seção será apresentada a área de estudo e os materiais e procedimentos metodológicos adotados visando atender aos objetivos deste trabalho serão descritos.

4.2.1 Área de estudo

O estudo foi realizado no campus da Universidade Federal de São Carlos, denominado Lagoa do Sino, localizado na cidade de Buri, no sudoeste do Estado de São Paulo. O campus abrange uma área de 643,3421 hectares e encontra-se a aproximadamente seis quilômetros de Campina do Monte Alegre-SP, nas proximidades do rio Paranapanema. Suas coordenadas centrais são $23^{\circ}47'51''$ S e $48^{\circ}35'34''$ W. A Figura 4 ilustra a área de estudo e a poligonal gerada pela implementação da Rede Cepegeo.

Figura 4: Planta de situação da Rede Cepegeo.



4.2.2 Materiais

Os marcos foram confeccionados em concreto, com 40 cm de altura e 18 cm de diâmetro no topo, e cada um possui uma chapa metálica contendo a identificação correspondente ao ponto.

Em relação aos equipamentos utilizados, para as técnicas de topografia convencional, foi empregada uma estação total da marca Topcon, modelo GTS-239W, nos levantamentos planimétricos, e um nível da marca Geotech, modelo DSZ3-A32X, acompanhado de uma mira graduada de alumínio de 4 metros de altura, para os levantamentos altimétricos. O processamento dos dados foi realizado por meio de planilhas Excel para cálculos manuais e do software Topcon Link para o processamento computacional.

Nos levantamentos geodésicos, utilizou-se um receptor GNSS de alta precisão da marca Trimble, modelo Spectra Precision 60 (SP60). O processamento dos dados foi realizado no software Survey Office e no site PPP do Instituto Brasileiro de Geografia e Estatística (IBGE), para processamento absoluto.


4.2.3 Metodologia – delineamento geral

Inicialmente, foram definidos os parâmetros técnicos a serem utilizados, e iniciou-se a confecção dos marcos de concreto e das plaquetas identificadoras, bem como o estabelecimento dos locais para sua implantação.

Em seguida, teve início a execução dos levantamentos. Após a coleta dos dados, procedeu-se com o cálculo e processamento das informações, que foram tabuladas e analisadas. Por fim, as coordenadas finais foram ajustadas e suas respectivas precisões homologadas por meio de memoriais descritivos de cada marco.

A Figura 5 apresenta o delineamento geral deste trabalho.

Figura 5: Delineamento geral da metodologia.



A seguir descreveremos detalhadamente as etapas desenvolvidas neste trabalho, apresentadas na figura anterior.

4.2.3.1 Definição dos parâmetros iniciais

Neste trabalho, para a definição dos parâmetros técnicos a serem empregados, foram utilizados os documentos “Instruções para Homologação de Estações Estabelecidas por Outras Instituições”, do Instituto Brasileiro de Geografia e Estatística (IBGE), e o “Manual Técnico para Georreferenciamento de Imóveis Rurais”, do Sistema de Gestão Fundiária (SIGEF).

4.2.3.2 Definição dos vértices e materialização da rede

Posteriormente, foram escolhidos os locais que compuseram a rede, com a seleção dos pontos levando em consideração as diversas situações encontradas pelos profissionais das áreas de mensuração.

Os vértices foram implantados tanto em áreas adjacentes a florestas quanto em locais com cobertura florestal, além de pontos em áreas a céu aberto, denominadas “situação ideal”, com o objetivo de atender às exigências para vértices base nas técnicas de posicionamento relativo.

Também foram implantados marcos em locais a céu aberto, próximos a encostas de morros, corpos d'água e edificações. Os vértices da rede foram identificados como Cepegeo + número (de 01 a 20), sendo que a sigla utilizada para denominação foi CP + número (por exemplo, CP01). A Tabela 7 apresenta os vértices e as condições físicas consideradas para a materialização dos mesmos.

Tabela 7: Vértices da Rede Cepegeo e as condições físicas dos mesmos, bem como principal fator que pode ocasionar erros quando efetua-se levantamentos utilizando GNSS.

Vértice	Condição
CP01 e CP20	Situação ideal = céu aberto, e não há estruturas físicas próximas, como edificações, florestas e corpos d'água e/ou encostas de terreno (declividade)
CP19	Céu aberto, mas próximo à encosta de morro (3,5 metros)
CP03 CP07	Distância entre 100 e 140 metros de corpo d'água; Distância entre 4 e 10 metros de edificações
CP05 CP06	Distância entre 10 e 50 metros de corpo d'água;
CP08 e CP09	Adjacência de floresta e/ou clareira em floresta
CP10	Floresta, com copa de média densidade
CP02	Floresta, com copa de alta densidade
CP11 e CP12	Adjacência de floresta e distantes entre 1,5 e 3 metros de edificações
CP13	Cercado por edificações em todas as direções
CP14	Céu aberto, porém próximo à encosta de morro (distante 2 metros) e de edificação (distante 10 metros)

4.2.3.3 Levantamentos, cálculos e processamentos para definição das coordenadas dos vértices

Com o objetivo de obter as coordenadas com a máxima precisão para todos os marcos, foram realizados levantamentos utilizando técnicas de Topografia Convencional, empregando as metodologias de Poligonação para definição das coordenadas planimétricas e Nivelamento Geométrico Composto para a obtenção das coordenadas altimétricas. Além disso, foram efetuados levantamentos com receptores geodésicos de alta precisão para a obtenção das coordenadas por posicionamento GNSS, nas técnicas relativo-estático e PPP.

Poligonação

Neste método, todos os vértices da área de estudo formaram a poligonal de interesse, e o levantamento teve início e término nos vértices CP01 e CP20 (conhecidos). Isso permitiu a triangulação entre os vértices, as linhas de interesse e os vértices e linhas de referência levantados, possibilitando o cálculo do erro angular e linear, bem como as correções proporcionais durante o processamento.

Para o processamento das coordenadas no software Topcon Link, foram inseridas as coordenadas dos vértices de referência, configurando-os como pontos de controle de erros.

No levantamento por poligonação, assim como a sequência do cálculo manual, na qual os vértices de referência também foram usados como pontos de controle de erros.

A classificação dos erros da poligonal foi realizada conforme o Padrão de Exatidão Cartográfico (PEC), estabelecido pelo Decreto Lei nº 89.817 de 20 de junho de 1984.

Nivelamento Geométrico Composto com contranivelamento

Neste método, para a obtenção das altitudes, o nível foi posicionado entre os vértices de interesse, e a mira foi instalada sobre eles. Após a realização das leituras nas miras, os desníveis foram calculados. Considerando o vértice CP01 como referência, as altitudes dos demais marcos foram determinadas com base nos desníveis calculados (Sinegalia, 2022).

Para classificar a qualidade posicional altimétrica, foram considerados os parâmetros da NBR 13.133. De acordo com o erro encontrado, a poligonal pode ser classificada em Classe IN (quando os erros são inferiores a $12 \text{ mm}\sqrt{k}$, sendo "k" a distância horizontal total percorrida durante o nivelamento, em quilômetros) ou em Classe IIN (para erros maiores que $12 \text{ mm}\sqrt{k}$ e menores que $20 \text{ mm}\sqrt{k}$).

Levantamentos utilizando receptores GNSS

Inicialmente, os vértices CP01 e CP20 foram levantados utilizando a metodologia de posicionamento relativo GNSS, com rastreios realizados por três dias consecutivos em horários semelhantes e outros três dias em horários diferentes, sempre em pares, com duração mínima de 4 horas por rastreio. O objetivo foi determinar as coordenadas desses vértices como pontos de referência da rede.

No processamento dos dados, para a técnica relativa, foram utilizadas as estações NEIA (RBMC, no município de Cananéia), SPC1 (no município de Campinas) e SPOR (no município de Ourinhos). A escolha dessas estações visou garantir uma configuração geométrica adequada para as linhas de base, atendendo aos parâmetros estabelecidos por Dorth (2010) para um processamento com linhas de base de classe A. Os parâmetros seguidos foram: i. Boa configuração geométrica entre as estações de controle e os pontos desconhecidos, com linhas de base inferiores a 700 km; ii. Solução

de ambiguidade satisfatória em todas as linhas de base; iii. PDOP (Diluidor de Precisão Posicional) inferior a 3 para todas as linhas de base; iv. Precisão horizontal e vertical inferior a 20 cm em todas as linhas de base.

Atualmente, existem cerca de 53 estações ativas (consulta em 09/01/2024). Também foram realizados testes de processamento com combinações dessas estações e com as estações SPS1 (Sorocaba) e SPBO (Botucatu).

Após o processamento, os dados foram ajustados utilizando o Método dos Mínimos Quadrados (MMQ) e o Teste-Tau, com nível de significância de 5%. Na metodologia absoluta, os dados provenientes dos levantamentos dos vértices foram processados individualmente utilizando o PPP do IBGE. Vale destacar que todas as elevações foram calculadas e convertidas em altitudes elipsoidais utilizando a ondulação geoidal com o datum HNOR_Imbituba (IBGE, 2024a).

Por fim, todos os vértices foram levantados por no mínimo três dias, com rastreios de pelo menos 4 horas, e sempre com rastreios simultâneos entre dois vértices da rede, alternando entre os vértices a serem definidos e os de referência.

Ajustamento envolvendo os resultados de todos os levantamentos para homologação da rede

Neste trabalho, os dados foram ajustados considerando os pesos e as injunções, utilizando o Método Paramétrico e o Método dos Mínimos Quadrados (MMQ), e validados por meio do Teste Tau, com nível de significância de 5%.

Após a obtenção das coordenadas para cada marco e suas respectivas precisões, os resultados foram documentados em Memorial Descritivo.

4.3 Resultados

4.3.1 Materialização da Rede


Como mencionado, após a definição de todos os parâmetros e a confecção dos marcos, estes foram implantados nos locais previamente selecionados.

A figura 6 apresenta o marco CP01 implantado, e a figura 7 mostra a localização de todos os vértices que compõem a Rede Cepegeo, juntamente com as respectivas situações consideradas para sua implantação.

Figura 6: Vértice CP01 da Rede Cepegeo.



Figura 7: Localização dos vértices da Rede Cepegeo.



4.3.2 Coordenadas dos vértices de referência

A Tabela 8 apresenta as coordenadas advindas após o processamento e ajustamento de levantamentos executados utilizando receptores GNSS, e processados de acordo com tal metodologias, para os vértices CP01 e CP20. Posteriormente os dados receberam tratamento estatístico e a Tabela 9 apresenta as coordenadas finais homologadas (consideradas de referência) dos vértices CP01 e CP20.

Vale ressaltar que em ambas as tabelas, a coordenada E obtida pelo PPP foi desconsiderada por caracterizar viés estatístico (por isso está grifada).

Tabela 8: Coordenadas oriundas do posicionamento relativo com GNSS para o CP01.

CP01	Coordenadas UTM			PRECISÃO		
02/03/2023	N	E	H (Elip.)	σ_n	σ_e	σ_H
Survey	7386020,568	140160,148	633,83	0,011	0,011	0,273
Topcon	7386020,563	140160,139	633,826	0,01	0,009	0,014
PPP	7386020,558	140160,068	633,84	0,002	0,007	0,009
21/03/2023	N	E	H (Elip.)	σ_n	σ_e	σ_H
Survey/Topcon	7386020,571	140160,13	633,814	0,11	0,11	0,074
PPP	7386020,561	140160,145	633,907	0,11	0,11	0,074
04/07/2023	N	E	H (Elip.)	σ_n	σ_e	σ_H
Survey/Topcon	7386020,575	140160,136	633,95	0,005	0,023	0,042
PPP	7386020,589	140160,126	633,935	0,002	0,002	0,004
06/07/2023	N	E	H (Elip.)	σ_n	σ_e	σ_H
Survey/Topcon	7386020,56	140160,152	634,016	0,14	0,15	0,1
PPP	7386020,583	140160,134	633,91	0,001	0,002	0,003

CP20	Coordenadas UTM			PRECISÃO		
02/03/2023	N	E	H (Elip.)	σ_n	σ_e	σ_H
Surveys	7386000,338	140220,638	632,554	0,008	0,008	0,272
Topcon	7386000,338	140220,63	632,551	0,011	0,01	0,014
PPP	7386000,332	140220,572	632,54	0,001	0,003	0,003
10-12/02/2023	N	E	H (Elip.)	σ_n	σ_e	σ_H
Survey/Topcon	7386000,348	140220,624	632,518	0,006	0,006	0,009
PPP	7386000,331	140220,638	632,538	0,001	0,001	0,003
18/08/2023	N	E	H (Elip.)	σ_n	σ_e	σ_H
Survey/Topcon	7386000,313	140220,624	632,55	0,01	0,011	0,022
PPP	7386000,344	140220,614	632,69	0,001	0,001	0,003
21/08/2023	N	E	H (Elip.)	σ_n	σ_e	σ_H
Survey/Topcon	7386000,326	140220,63	632,531	0,005	0,004	0,009
PPP	7386000,321	140220,633	632,521	0,002	0,002	0,004

Tabela 9: Coordenadas UTM CP01 e CP20 homologadas.

Vértice	N	σ_n	E	σ_e	Helip	σ_z
CP01	7386020,568	0,003	140160,141	0,009	633,870	0,013
CP20	7386000,336	0,005	140220,634	0,015	632,534	0,018

De posse das coordenadas homologadas, foram gerados documentos com todas as informações geodésicas inerentes à cada vértice (Memorial Descritivo).

A Figura 8 apresenta o memorial descritivo do Vértice CP01 e o memorial completo do referido vértice pode ser obtido contatando-se o CePe-Geo.

Figura 8: Memorial Descritivo CP01.



CePE-Geo
Centro de Pesquisa e Extensão em Geotecnologias

REDE PLANIALTIMÉTRICA DE PRECISÃO CEPEGEO
Relatório de Informação de Marco
CP01

1. Identificação do vértice

Identificação/ Código: **CP01**

Nome do Vértice: CEPEGEO-01



2. Informações sobre a localização

Cidade: Buri

Estado: São Paulo (SP)

Informações Adicionais: Marco de concreto com plaqueta de identificação. Próximo à portaria da Universidade Federal de São Carlos – campus Lagoa do Sino. Rodovia Lauri Simões de Barros, km 12 - SP-189 – Aracaju.



3. Coordenadas Oficiais

SIRGAS2000 (Época 2000.4)

Coordenadas Geodésicas			
Latitude:	- 23° 35' 47,060207''	Sigma:	0,003 m
Longitude:	- 48° 31' 31,542296''	Sigma:	0,009 m
Alt. Elipsoidal:	633,87 m	Sigma:	0,013 m
Alt. Geométrica:	630,187 m		
*Ondulação Geoidal (HNOR_IMBITUBA) =			-3,73m
Coordenadas Planas (UTM)			
UTM (N):	7.386.020,568 m		
UTM (E)	140.160,141 m		
MC:	-45		

4. Informações Adicionais

Coordenadores (as) CePE-Geo

Prof. Dr. Paulo Guilherme Molin

Prof. Dr. André Marcondes Andrade Toledo

Coordenador(a) da Rede Cepegeo

Eng^a. Cartógrafa Me Melodie Kern Sarubo

Dorth Sinegalia

Coordenadas dos vértices da rede: Topografia Convencional

A tabela 10 apresenta as coordenadas calculadas e corrigidas obtidas através dos levantamentos e processamentos oriundos da Topografia Convencional.

Tabela 10: Coordenadas obtidas através por poligonização, com cálculo manual e via Topcon Link.

Vértice	N (m) manual	E (m) manual	N (m) Topcon Link	E (m) Topcon Link	H (m) Topcon Link	H (m) Niv. Geom.
CP20	7386000,336	140220,634	7386000,336	140220,634	632,534	632,534
CP01	7386020,568	140160,141	7386020,568	140160,141	633,87	633,87
CP03	7386017,168	140026,153	7386017,165	140026,167	633,083	633,133
CP05	7385932,389	139913,833	7385919,515	139983,668	632,771	633,019
CP06	7385851,175	139813,397	7385932,376	139913,859	633,008	633,962
CP07	7385815,540	139595,169	7385851,164	139813,428	633,845	638,704
CP08	7385740,596	139628,904	7385815,525	139595,211	638,81	640,734
CP09	7385733,045	139607,590	7385740,58	139628,948	640,489	640,651
CP10	7385718,501	139588,038	7385733,034	139607,652	640,875	641,432
CP02	7385697,555	139593,210	7385722,419	139639,738	641,567	641,715
CP11	7385722,436	139639,693	7385705,365	139636,304	641,57	641,820
CP12	7385705,382	139636,259	7385718,492	139588,103	641,65	641,864
CP13	7385689,786	139669,478	7385697,545	139593,276	641,984	641,886
CP14	7385702,714	139712,417	7385689,767	139669,527	641,592	640,182
CP19	7385863,243	140073,327	7385702,7	139712,487	639,876	629,495

Coordenadas dos vértices da rede: Receptores GNSS

Os demais vértices da rede também foram levantados por posicionamento relativo, efetuando-se rastreios por três dias em horários semelhantes e outros três dias em horários diferentes sempre em pares, por no mínimo 4 horas. Na etapa de processamento utilizou-se o software Survey Office, com as mesmas estações da RBMC como pontos de controle. Também procedeu-se o processamento pelo PPP do IBGE.

Posteriormente tais dados foram ajustados utilizando MMQ e teste Tau para controle da qualidade.

Homologação dos demais vértices da rede

Os dados de todos os levantamentos foram tabulados, analisados e ajustados utilizando o MMQ e validados pelo Teste Tau, a um nível de significância de 5%.

A tabela 11 apresenta as coordenadas homologadas e as respectivas precisões de todos os vértices.

Tabela 11: Coordenadas UTM homologadas Rede Cepegeo.

Ponto	N	σ_n	E	σ_e	Helip	σ_z
CP01	7386020,568	0,003	140160,141	0,009	633,834	0,013
CP02	7385697,555	0,007	139593,210	0,047	641,715	0,190
CP03	7386017,168	0,002	140026,153	0,010	633,132	0,035
CP05	7385932,389	0,009	139913,833	0,018	633,019	0,008
CP06	7385851,175	0,008	139813,397	0,022	633,963	0,083
CP07	7385815,540	0,011	139595,169	0,029	638,702	0,076
CP08	7385740,596	0,011	139628,904	0,031	640,735	0,174
CP09	7385733,045	0,008	139607,590	0,044	640,653	0,157
CP10	7385718,501	0,007	139588,038	0,046	641,432	0,154
CP11	7385722,436	0,012	139639,693	0,032	641,820	0,179
CP12	7385705,382	0,012	139636,259	0,032	641,863	0,207
CP13	7385689,786	0,013	139669,478	0,035	641,886	0,169
CP14	7385702,714	0,010	139712,417	0,050	640,180	0,215
CP19	7385863,243	0,009	140073,218	0,009	629,495	0,041
CP20	7386000,336	0,005	140220,634	0,015	632,534	0,018

4.4 Discussão

As florestas tropicais desempenham um papel crucial na mitigação das mudanças climáticas, armazenando grandes quantidades de carbono em sua biomassa e na matéria orgânica presente no solo. Esse armazenamento é fundamental para a redução das emissões de gases de efeito estufa, ajudando a controlar o aquecimento global. Nesse contexto, a utilização de dados provenientes de inventários florestais, associados a modelos de interpolação geoestatística e geotecnologias, torna-se imprescindível, pois oferece uma maneira precisa e eficiente de obter variáveis florestais com custos reduzidos (da Costa & Quintanilha, 2024).

As geotecnologias, como Sistemas de Informações Geográficas (SIG) e levantamento com GNSS, são ferramentas poderosas para a melhoria desses dados. Para garantir a precisão exigida, é comum o uso de pontos de controle geodésicos, levantados por GNSS, que servem tanto para validar as medições de campo quanto para referenciar as parcelas florestais (Keefe et al., 2019).

No entanto, para que esses dados geoespaciais atendam aos requisitos de qualidade, é essencial que sejam suportados por uma infraestrutura geodésica robusta. Redes geodésicas desempenham um papel fundamental na validação e correção dos erros de mensuração, além de promoverem a integração de dados geoespaciais provenientes de diversas fontes. A ausência de uma rede geodésica adequada pode comprometer gravemente a análise e interpretação dos dados, afetando a precisão das informações geoespaciais (Weiss et al., 2022).

Atualmente, os GNSS fornecem dados precisos para observações em todo o mundo, graças ao crescente número de satélites de diferentes operadores, além de tecnologias mais avançadas e potentes. Isso é acompanhado pela implementação de modelos matemáticos e físicos que descrevem com maior precisão os erros sistemáticos que afetam as observações GNSS, como os efeitos ionosféricos, troposféricos, relativísticos e de multipercurso, no entanto, a combinação adequada dos métodos de medição resulta em dados ainda mais precisos, proporcionando melhores resultados de medição ou estimativas mais confiáveis de parâmetros desconhecidos (França et al. 2022).

Este trabalho visou a implantação de uma rede geodésica, combinando métodos de topografia convencional e posicionamento GNSS, com o intuito de garantir a melhor qualidade posicional para os vértices dessa rede. A densificação de levantamentos geodésicos por meio de técnicas clássicas de posicionamento, como as estações totais, pode ser necessária em razão da qualidade do posicionamento fornecido pelo Sistema Global de Navegação por Satélite (GNSS) (França et al. 2021).

A integração de levantamento topográfico convencional com GNSS oferece uma abordagem abrangente e precisa para a construção de uma estrutura geoespacial confiável. Esse modelo integrado é superior aos métodos tradicionais isolados, proporcionando maior cobertura e precisão, o que é essencial para atender aos requisitos de projetos de grande escala (Kobryń, 2019).

Atualmente, a Rede Geodésica de Precisão Cepegeo é composta por 15 vértices materializados e homologados. Ela foi desenvolvida para atender às necessidades de posicionamento e referenciamento espacial no ambiente acadêmico e científico. No entanto, os resultados obtidos por meio de sua implantação evidenciam a importância de tal infraestrutura, demonstrando sua confiabilidade e aplicabilidade em diversos setores da sociedade, além do campo científico.

Dentre os desafios encontrados na materialização da rede, destaca-se a escolha dos vértices que compõem a rede, um processo que exigiu balancear os objetivos do estudo com os parâmetros técnicos recomendados pelos documentos orientadores da implantação. Também surgiram dificuldades relacionadas às metodologias de levantamento, especialmente na topografia convencional, que demandou a intervisibilidade entre, no mínimo, três vértices da rede para possibilitar a obtenção de ângulos e a amarração da rede. Em relação aos levantamentos com GNSS, a principal dificuldade foi a mobilização intensa de recursos humanos e materiais, uma vez que cada vértice precisou ser ocupado por, no mínimo, três dias, com rastreios de pelo menos quatro horas para garantir a precisão necessária.

Outro problema significativo foi a manutenção dos marcos, que sofreu com quebras nas estruturas, remoção de plaquetas de identificação e, em alguns casos, a construção de edificações próximas aos vértices, o que inutilizou alguns marcos. A partir dessa identificação, a expansão da rede foi iniciada em duas fases adicionais, utilizando as mesmas metodologias, com o objetivo de atender às crescentes demandas do grupo Cepegeo. A construção de uma quadra esportiva próxima ao vértice CP01, ponto de referência para este estudo, também exigiu a ampliação da rede. As fases 2 e 3, ainda em levantamento, adicionarão cerca de 10 vértices à Rede Cepegeo. A incorporação de pontos adicionais a uma rede geodésica aumenta a redundância das medições, permitindo uma avaliação mais precisa dos erros e uma melhor estimativa dos parâmetros geodésicos, resultando em maior confiança nos dados (Weiss et al., 2022).

Quanto à qualidade dos levantamentos realizados com a topografia convencional, a técnica de poligonação, com cálculos manuais via planilha, obteve resultados que destacam sua eficácia no estabelecimento e triangulação entre os vértices da rede. Para o componente planimétrico, a precisão foi de $3 \text{ mm} + 2 \text{ ppm}$, o que é considerado de alta precisão de acordo com a NBR 13.133.

Já o componente altimétrico apresentou precisão de 0,72 m, classificada como classe IIN ($12 \text{ mm}\sqrt{k}$) pela mesma norma. Embora a NBR 13.133 determine que apenas o nivelamento geométrico alcance essa qualidade, a utilização de instrumentos avançados e a execução cuidadosa das medições permitiram formar poligonais com ângulos e distâncias consistentes, garantindo a integridade da rede, inclusive no componente altimétrico.

Um fator relevante foi a discrepância nas coordenadas calculadas pelo software Topcon Link, que apresentaram uma diferença acumulada de até 5 cm no componente planimétrico e de 20 cm no altimétrico. Esse desvio deve-se ao fato de que o cálculo manual foi realizado com base no Método dos Mínimos Quadrados (MMQ), utilizando injunções com os vértices de referência, o que proporcionou um refinamento estatístico dos resultados.

Para a definição das coordenadas altimétricas, a utilização do nivelamento geométrico composto, com contranivelamento, foi crucial. Essa técnica não só permitiu uma maior precisão no componente altimétrico, como também possibilitou ajustes e validações importantes para as metodologias empregadas, além de fornecer uma análise precisa da acurácia de outras técnicas. A conformidade com as especificações da NBR 13.133 garantiu maior confiabilidade nos resultados.

Por fim, a utilização do método relativo de posicionamento com diferentes tempos de rastreo contribuiu significativamente para a melhoria da precisão posicional. A combinação

dessas metodologias — poligonação, nivelamento geométrico e GNSS — não apenas garantiu resultados robustos e de alta qualidade, como também proporcionou redundância nas medições, permitindo verificações cruzadas e aumentando a confiabilidade das coordenadas finais homologadas para os vértices da rede. Essa abordagem integrada, que combina o melhor de cada metodologia, assegura a robustez da rede geodésica e oferece um padrão de qualidade que pode ser replicado em outras aplicações de georreferenciamento e monitoramento ambiental.

4.5 Conclusão

As redes geodésicas desempenham um papel fundamental para os profissionais das áreas de mensuração, pois não só aprimoram a qualidade posicional dos vértices levantados, mas também permitem a validação e correção de erros que afetam a precisão dos levantamentos. Além disso, essas redes viabilizam a integração eficiente de dados geoespaciais, conferindo robustez aos dados adquiridos e garantindo maior confiabilidade nas análises subsequentes. Em um cenário no qual a precisão é essencial para diversas áreas do conhecimento e da prática profissional, a infraestrutura geodésica de qualidade é indispensável.

Neste contexto, o presente trabalho detalha todas as etapas envolvidas na implantação de uma rede geodésica de precisão, com o objetivo de atender aos elevados parâmetros de qualidade posicional e de abordar situações práticas comumente encontradas pelos profissionais de mensuração. A execução de uma rede geodésica com essas características visa proporcionar uma infraestrutura sólida que possa ser replicada em outros projetos de grande escala, beneficiando tanto o meio acadêmico quanto a comunidade profissional.

Os desafios enfrentados ao longo deste processo, como a escolha criteriosa dos vértices, a mobilização extensiva de recursos para os levantamentos GNSS e a necessidade constante de manutenção dos marcos, evidenciam a importância de uma rede geodésica bem estruturada e mantida. Essas dificuldades destacam, ainda, a necessidade de um planejamento adequado, que contemple todas as variáveis envolvidas, desde a escolha dos pontos de referência até a sua preservação no tempo. A integração das metodologias de levantamento adotadas — poligonação, nivelamento geométrico e GNSS — resultou em uma rede de alta qualidade posicional, cumprindo os padrões exigidos pelas normas técnicas e proporcionando dados confiáveis para as análises posteriores. Essa abordagem multidisciplinar, que combina diferentes técnicas de mensuração, se mostrou essencial para o sucesso de projetos geodésicos complexos.

A implantação dessa rede, utilizando métodos de topografia convencional e posicionamento GNSS, foi crucial para a criação de uma estrutura geoespacial local precisa e confiável. A combinação de técnicas tradicionais com as tecnologias mais avançadas, como o

GNSS, proporcionou uma cobertura ampla e uma precisão que superou os métodos isolados (Kobryń, 2019). A integração de diferentes métodos de levantamento – como a poligonação e o nivelamento geométrico – fortaleceu ainda mais a confiabilidade da rede, assegurando a consistência dos dados, mesmo frente às adversidades encontradas durante a materialização e manutenção da rede.

Além disso, o trabalho contribui para o entendimento da importância de uma infraestrutura geodésica bem mantida, especialmente em um país com dimensões continentais como o Brasil, onde a escassez de redes geodésicas de alta precisão pode comprometer projetos de grande impacto. A implantação e manutenção de redes como a Cepegeo são fundamentais não apenas para o aprimoramento da mensuração geoespacial, mas também para o avanço das pesquisas científicas e o planejamento de grandes projetos de infraestrutura, como os relacionados à gestão ambiental, ao ordenamento territorial e ao desenvolvimento urbano sustentável.

A Rede Geodésica Cepegeo representa um avanço significativo para a comunidade científica e profissional, servindo como modelo para a criação de outras redes geodésicas interconectadas em nível nacional. Espera-se que este trabalho inspire futuros estudos e investimentos na expansão da infraestrutura geodésica, principalmente no que se refere à interconexão de diferentes redes e à incorporação de novas tecnologias de medição. Redes geodésicas robustas e bem estruturadas são cruciais para impulsionar a inovação e o progresso nas áreas que dependem de informações espaciais precisas, como a cartografia, o planejamento urbano, a agricultura de precisão, a geologia e o monitoramento ambiental.

Investir na expansão e atualização dessas redes não só preenche as lacunas identificadas ao longo deste estudo, como também contribui para o fortalecimento da infraestrutura geodésica nacional, promovendo a integração entre diferentes áreas do conhecimento e impulsionando a sustentabilidade e o desenvolvimento científico e tecnológico do país.

Literatura Citada

Alves, J. D. G. 2023. Possibilidades e desafios no uso de drone para mapeamento de comunidades tradicionais na Amazônia. *Revista Brasileira de Geografia Física* (online) 16-5, p2594-2608. Disponível em: DOI: <https://doi.org/10.26848/rbgf.v16.5.p2594-2608>

Atiz, O. F., Shakor, A. Q., Ogutcu, S., & Alcay, S. 2023. Performance investigation of Trimble RTX correction service with multi-GNSS constellation. *Survey Review* (online) 55(388).

Disponível: <https://doi-org.ez31.periodicos.capes.gov.br/10.1080/00396265.2021.1999128>. Acesso: 12 abril 2024.

Ball, J. G. C., Hickman S. H. M., Jackson, T. D., Koay, X. J., Hirst, J., Jay, W., Archer, M., Aubry-Kientz, M., Vincent, G., Coomes, D. A. 2023. Accurate delineation of individual tree crowns in tropical forests from aerial RGB imagery using Mask R-CNN. *Remote Sensing in Ecology and Conservation* (online) 9. Disponível: <https://doi-org.ez31.periodicos.capes.gov.br/10.1002/rse2.332>. Acesso: 12 abril 2024.

Caizzone, S., Schönfeldt, M., Elmarissi, W., Circiu, M.-S., 2021. Antennas as Precise Sensors for GNSS Reference Stations and High-Performance PNT Applications on Earth and in Space. *Sensors* (online) 21. Disponível: <https://doi.org/10.3390/s21124192>. Acesso: 08 abril 2024.

Cevik, I.C., Atik, M. E. & Duran, Z., 2024. Investigation of Optimal Ground Control Point Distribution for Geometric Correction of VHR Remote Sensing Imagery. *J Indian Soc Remote Sens* 52 359–369.

Disponível: <https://doi-org.ez31.periodicos.capes.gov.br/10.1007/s12524-024-01826-0>

Costa, J. D. M. da, & Quintanilha, J. A., 2024. Uso das Geotecnologias na Estimativa de Biomassa e Carbono Florestal: Uma Revisão. *Revista Brasileira De Geografia Física* (online) 17(2). Disponível: <https://doi.org/10.26848/rbgf.v17.2.p1127-1146>. Acesso: 08 abril 2024.

Dantas, F. K. D., & Costa, F. R. da, 2024. Altimetria e planimetria, análise de métodos fotogramétricos por vant versos topografia convencional. *Pensar Geografia* (online) 7(1), Recuperado de <https://periodicos.apps.uern.br/index.php/PGEO/article/view/4457> (Original work published 1º de janeiro de 2024). Acesso: 31 março 2024.

Dupuis C., Lejeune P., Michez A., Fayolle A., 2020. How Can Remote Sensing Help Monitor Tropical Moist Forest Degradation?—A Systematic Review. *Remote Sensing* (online) 12(7). Disponível: <https://doi.org/10.3390/rs12071087>. Acesso: 08 nov. 2023.

França R. M., Klein I., Veiga L.A.K., 2021. The influence of the deflection of the vertical on geodetic surveys in Brazil. *Bol Ciênc Geodésicas*, 27(spe). Disponível: <https://doi.org/10.1590/s198221702021000s00020>

França, R.M., Klein, I. & Veiga, L.A.K., 2022. Quality of the deflection of the vertical obtained from global geopotential models in horizontal geodetic positioning. *Appl Geomat* 14, 795–810. Disponível: <https://doi.org/10.1007/s12518-022-00473-9>

Freitas K.X.S., Nascimento L.A., Dal Poz, W.R., 2022. Análise da influência ionosférica e solar na acurácia do IBGE-PPP utilizando séries temporais. *Revista Brasileira de Geomática (online)* 10. Disponível: DOI: 10.3895/rbgeo.v10n1.14495. Acesso: 23 nov. 2023.

Gemael C., 1994. Introdução ao Ajustamento de Observações – Aplicações Geodésicas. Livro. Curitiba: Editora da UFPR.

Gómez C., Alejandro P., Hermosilla T., Montes F., Pascual C., Ruiz L. A., Álvarez-Taboada F., Tanase M., Valbuena R., 2019. Remote sensing for the Spanish forests in the 21st century: a review of advances, needs, and opportunities. *Forest Systems (online)* 28(1):eR001. Disponível: <https://doi.org/10.5424/fs/2019281-14221>. Acesso: 06 abril 2024.

Haspel, M. 1996. LP-based accuracy improvement for UAVs. Nineteenth convention of electrical and electronics engineers in Israel, p440-443. Disponível: <https://www.webofscience.com/wos/woscc/summary/14b2a68e-a6f9-4b0a-9710-5c3653658b8f-0131592773/relevance/1>. Acesso em 03/12/2024.

IBGE. Instituto Brasileiro de Geografia e Estatística, 2024a. Atlas Geográfico Escolar: Sistema Global de Navegação Por Satélite – GNSS. Acesso: 18 mar. 2024.

IBGE (Instituto Brasileiro de Geografia e Estatística. 2024b. Instruções para homologação de estações estabelecidas por outras instituições. Acesso: 18 mar. 2024.

Javadi, P., García-Asenjo, L., Luján, R., & Lerma, J. L. (2024). Assessment of Panorama Photogrammetry as a Tool for Long-Range Deformation Monitoring. *Sensors*, 24(11), 3298. <https://doi.org/10.3390/s24113298>

Jin, S., Wang, Q., Dardanelli, G., 2022. A Review on Multi-GNSS for Earth Observation and Emerging Applications. *Remote Sensing* (online) 14. Disponível: <https://doi.org/10.3390/rs14163930>. Acesso: 11 abril 2024.

Keefe, R.F.; Wempe, A.M.; Becker, R.M.; Zimbelman, E.G.; Nagler, E.S.; Gilbert, S.L.; Caudill, C.C. Positioning Methods and the Use of Location and Activity Data in Forests. *Forests* (online) 10, 458. Disponível: <https://doi.org/10.3390/f10050458>. Acesso: 15 abril 2024.

Kim, E., Kim, S-k. 2022. Global Navigation Satellite System Real-Time Kinematic Positioning Framework for Precise Operation of a Swarm of Moving Vehicles. *Sensors* (online) 22. Disponível: <https://doi.org/10.3390/s22207939>. Acesso: 12 abril 24.

Kobryń, A. 2019. Multicriteria Decision Making in Geodetic Network Design. *Journal of Surveying Engineering* (online) 146. Disponível: [https://doi-org.ez31.periodicos.capes.gov.br/10.1061/\(ASCE\)SU.1943-5428.0000301](https://doi-org.ez31.periodicos.capes.gov.br/10.1061/(ASCE)SU.1943-5428.0000301). Acesso: 11 abril 2024.

Krueger, C. P., Junior, P. S. de O., Garnés, S. J. dos A., Alves, D. B. M., Euriques, J. F., 2020. Posicionamento GNSS em Tempo Real: Evolução, Aplicações Práticas e Perspectivas para o Futuro. *Revista Brasileira de Cartografia* (online) 72. Disponível: <https://doi.org/10.14393/revbrascartogr>. Acesso: 10 abril 2024.

Liang, Y., Kou, W., Lai, H., Wang, J., Wang, Q., Xu, W., Wang, H., Lu, N., 2022. Improved estimation of aboveground biomass in rubber plantations by fusing spectral and textural information from UAV-based RGB imagery. *Ecological Indicators* (online) 142. Disponível: <https://doi.org/10.1016/j.ecolind.2022.109286>. Acesso: 11 nov. 2023.

Michels, N. B., Silva, R. M. da, Souza S. F. de, 2021. Georreferenciamento de imóveis rurais: análise de área entre topografia, RTK e sistema TM. *Revista Brasileira de Geomática* (online) 9. Disponível: <https://revistas.utfpr.edu.br/rbgeo/article/view/12734/8127>. Acesso: 10 abril 2024.

Nero, M. A., Rocha, A. P., Mamede, C. G., Schuler, C. A. B., Temba, P. d. C., & Reinoso-Gordo, J. 2023. Positional accuracy in close-range photogrammetry through topography and geodesy. *Revista De Arquitectura* (online) 25(2). Disponível: doi:<https://doi-org.ez31.periodicos.capes.gov.br/10.14718/RevArq.2023.25.3659>. Acesso: 11 abril 2024.

Nishiwaki, A. A. M., Moura, M. S. B. de, Galvêncio, J. D., Oliveira, C. P. de, Silva, E. A., Lima, J. R. de S., ... Domingues, T. F., 2023. Uso do LiDAR na Estimativa de Atributos Florestais: Uma Revisão. *Revista Brasileira De Geografia Física* (online) 16(1). Disponível: <https://doi.org/10.26848/rbgf.v16.1.p505-527>. Acesso: 10 mar. 2024.

Ocalan, T., Turk, T., Tunalioglu, N. et al. 2022. Investigation of accuracy of PPP and PPP-AR methods for direct georeferencing in UAV photogrammetry. *Earth Sci Inform* (online) 15, 2231–2238. Disponível: <https://doi-org.ez31.periodicos.capes.gov.br/10.1007/s12145-022-00868-7>. Acesso: 20 dez. 2023.

Paiva, A. A. de, Burim, S. C., Borges, P. A. F., & Anjos, C. S. dos., 2021. Avaliação da acurácia posicional de vértices obtidos por imagem de sensor orbital e aerofotogrametria para fins de georreferenciamento de imóveis rurais. *Revista Brasileira De Geografia Física* (online) 14(6), 3530–3541. <https://doi.org/10.26848/rbgf.v14.6.p3552-3563>

Paula E. R, Monico J.F.G., Tsuchiya I.H., Valladares C.E., Costa S.M.A., Marini-Pereira L., Vani B.C., Moraes A.O., 2023. A Retrospective of Global Navigation Satellite System Ionospheric Irregularities Monitoring Networks in Brazil, *Journal of Aerospace Technology and Management* (online) 15. Disponível: <https://doi.org/10.1590/jatm.v15.1288>. Acesso: 23 nov. 2023.

Peng, Y., Scales, W.A., Hartinger, M. et al., 2021. Characterization of multi-scale ionospheric irregularities using ground-based and space-based GNSS observations. *Satell Navig 2* (online) 14. Disponível: <https://doi.org/10.1186/s43020-021-00047-x>. Acesso: 23 nov. 2023.

Pourreza M., Moradi F., Khosravi M., Deljouei A., Vanderhoof M.K., 2022. GCPs-Free Photogrammetry for Estimating Tree Height and Crown Diameter in Arizona Cypress Plantation Using UAV-Mounted GNSS RTK. *Forests* (online) 13(11):1905. Disponível: <https://doi.org/10.3390/f13111905>. Acesso: 20 dez. 2023.

Sefercik, U. G., Kavzoğlu, T., Çölkesen, İ., Nazar, M., et al., 2023. 3D positioning accuracy and land cover classification performance of multispectral RTK UAVs. *International Journal of Engineering and Geosciences* (online) 8(2). Disponível: <https://doi.org/10.26833/ijeg.1074791>. Acesso: 20 dez. 2023.

Setti Junior P. de T., SILVA C.M. da, Oliveira Junior P.S. de; Alves D.B.M., Monico J.F.G., 2020. Posicionamento multi-GNSS. *Revista Brasileira de Cartografia* (online) 72. Disponível: DOI: 10.14393/rbcv72nespecial50anos-56580. Acesso: 30 out. 2023.

SIGEF (Sistema de Gestão Fundiária) 2024. Manual Técnico para Georreferenciamento de Imóveis Rurais” do Sistema de Gestão Fundiária (SIGEF). Acesso em 18 dez. 2023.

Santana, T. A., Dalazoana, R. 2020. Integração dos Referenciais Verticais Terrestre e Oceânico: Conceitos Relacionados, Projetos Desenvolvidos e Desafios. *Revista Brasileira de Cartografia* ISSN 1808-0936. Disponível: <https://doi.org/10.14393/revbrascartogr>. Acesso: 02 dez. 2024.

Sinegalia, M.K.S.D., Santoro, G.B. and Molin, P.G. 2023. How have RPAS helped monitor forests and what can we apply in forest restoration monitoring?. *Restoration Ecology* (online) 32: e14061. Disponível: <https://doi.org/10.1111/rec.14061>. Acesso: 13 dez. 2023.

Rocha, A. G. B., & Rocha, R. B., 2021. A Cartografia ao longo da história da humanidade: importância e avanços técnicos. *Ensino Em Perspectivas*, (online) 2(2), 1–17. Recuperado de <https://revistas.uece.br/index.php/ensinoemperspectivas/article/view/4995>. Acesso: 12 abril 2024.

Weiss, G., Slavomir, L., Gasinec, J., Stankova, H.; Cernota, P., Weiss, E., Weiss, R., 2022. Establishment of local geodetic networks based on least-squares adjustments of GNSS baseline vectors. *Advances in Geodesy and Geoinformation* (online) 71. Disponível: <https://doi.org/10.24425/gac.2022.141168>. Acesso: 20 jan. 2024.

White J.C., Wulder M.A., Hermosilla T., Coops N.C., Hobart, G.W., 2017. A nationwide annual characterization of 25 years of forest disturbance and recovery for Canada using Landsat time series. *Remote Sensing of Environment* 194: 303–321. Disponível: [https://doi-org.ez257.periodicos.capes.gov.br/10.1016/j.rse.2017.03.035](https://doi.org.ez257.periodicos.capes.gov.br/10.1016/j.rse.2017.03.035)

Zhang, Z., & Zhu, L., 2023. A Review on Unmanned Aerial Vehicle Remote Sensing: Platforms, Sensors, Data Processing Methods, and Applications. *Drones*, 7(6), 398. <https://doi.org/10.3390/drones7060398>

5. LOOK DOWN: TO WHAT EXTENT DOES THE PRECISION OF GROUND CONTROL POINTS REFLECT THEIR ACCURACY?

ABSTRACT

Forests play a crucial role in the carbon cycle, making accurate monitoring of their variables essential for conservation and restoration efforts. Remote sensing, especially LiDAR, is widely used for forest mapping, but its high cost has led to the adoption of more affordable alternatives like RGB imagery from drones. The quality of products generated by these technologies relies on georeferenced control points (GCPs) to correct geometric distortions and improve spatial accuracy. These points, obtained through GNSS surveys, can be affected by signal transmission interferences, leading to data quality degradation. While manufacturers provide information on the equipment's precision, accuracy—the proximity of measurements to the true value—may show significant discrepancies. This study investigated the accuracy of various GNSS methodologies, including relative techniques (static, Stop-and-Go (SAG), RTK, and post-processed RTK) and absolute techniques (SPP and PPP), considering factors such as tracking time and environmental conditions (dense forests, open areas, proximity to water bodies, and buildings). The results show that, under ideal conditions, PPP and static tracking with at least 5 hours ensure high planimetric accuracy (millimeter-level). However, proximity to buildings, water bodies, and vegetation density negatively affects data accuracy, revealing significant discrepancies between precision and accuracy, especially in the altimetric component. The study highlights the importance of carefully selecting the GNSS methodology and proposes a reference table for expected accuracy under various conditions. These results are expected to improve forest monitoring strategies and provide a more accurate assessment of carbon stock, supporting restoration and conservation efforts.

Keywords: GNSS; Aerophotogrammetry; Ecological Restoration; Remote Sensing.

5.1 Introduction

Amid unprecedented and globally scaled climate change, an ambitious restoration agenda has been established with the goal of expanding forest cover in deforested and degraded landscapes, aiming to improve their multifunctionality and ability to provide essential ecosystem services, such as biodiversity conservation, water supply, and carbon storage (Liu et al., 2016; Erbaugh and Oldekop, 2018; Gómez et al., 2019). Forest monitoring will play a crucial role in evaluating the success of these goals and supporting adaptive management, generating an urgent demand for collaborative and effective social technologies to monitor

ecosystem recovery over large areas, using relevant ecological indicators (Brancalion and Holl, 2020; Fagan et al., 2020; Guariguata and Evans, 2020; Höhl et al., 2020; Almeida et al., 2021).

However, one of the main challenges in forest monitoring is measuring and tracking forest variables effectively, accurately, and at low cost, since the measurement of these variables often relies on extensive field campaigns (Liu et al., 2016). This makes the development of tools that provide precise and economical solutions for obtaining such variables essential (Liu et al., 2016; Dupuis et al., 2020), where accurate methods aimed at estimating forest attributes to support decision-making and ensure effective remote monitoring of forests in the restoration process become indispensable (Almeida et al., 2019).

Remote sensors installed on orbital platforms, aircraft, or RPAs stand out as powerful tools for monitoring these ecosystems, providing products that allow for analysis, synthesis, and reporting, which are essential to inform decisions that enable sustainable planning and management (Gómez et al., 2019).

Currently, there is a growing trend in the use of LiDAR (Light Detection and Ranging) for estimating these parameters. However, this type of survey requires expensive aircraft and specialized sensors (Patias et al., 2017; Sinegalia et al., 2023). Nevertheless, with the advent and decreasing cost of RPAS, commonly referred to as drones, data from RGB (Red-Green-Blue) sensors, which can be obtained in much more affordable ways, have made it possible to generate photogrammetric products with unprecedented detail and ease. The great potential of these platforms has driven various applications in forest monitoring and its structure, including measurements such as tree height and trunk and canopy diameters (Mlambo et al., 2017; Pourreza et al., 2022; Sinegalia et al., 2023).

A challenge remains regarding the presence of errors in the accuracy of these products. To minimize the effects that could lead to the degradation of the quality of these products, it is common to use control points, which have coordinates typically defined through surveys using GNSS (Global Navigation Satellite System) receivers strategically distributed across the area to be mapped, allowing them to be easily identified in the generated images (Sefercik et al., 2023; Singh et al., 2023; Sinegalia et al., in press).

These control points, often called GCPs (Ground Control Points), can be permanent terrestrial features or reference targets placed on the ground before the flight, and their three-dimensional positions are usually obtained through surveys with GNSS receivers (Swinfield et al., 2019).

In surveys aimed at producing forest restoration interventions on a small scale or monitoring changes over time, the inclusion of georeferenced control points is considered

essential as it plays a crucial role in validating and correcting photogrammetric products, as well as in georeferencing the point cloud. It also provides correction for geometric distortions and improves the spatial accuracy of the generated aerial images (Swinfield et al., 2019).

However, the coordinates obtained when performing this type of positioning are subject to several influences, ranging from the moment the electromagnetic waves are emitted by the satellite antenna to the moment the information is received by the terrestrial receiver's antenna, which causes some degradation in the precision and accuracy of the obtained coordinates (Dorth, 2010; Elsheikh et al., 2023).

In this context, several strategies can be adopted to improve the positioning quality, from the choice of receiver type, the adoption of correct parameters in the survey, such as appropriate elevation masking and attention to the location where the receivers are stationed, to the processing of the data. The implementation of advanced filtering techniques to remove incorrect data and the application of rigorous quality control, including statistical analysis of residuals, are essential practices (Paula et al., 2023).

GNSS positioning has gained significant visibility over the past two decades and is now applied in various activities beyond positioning and navigation. To meet these needs, different positioning methods have been developed (Setti Junior et al., 2020; Sinegalia et al., 2023b), with the most commonly employed in the context of remote forest monitoring for determining the coordinates of control points being relative methods, including static relative, static-rapid, also called Stop-and-Go (SAG), RTK (Real-Time Kinematic), and post-processed RTK, and absolute methods like PPP (Precise Point Positioning) and SPP (Single Point Positioning) (Sinegalia et al., in press).

In relative methodology techniques, two receivers are needed to track simultaneously: one is set up in an open area (without obstructions), far from lakes, rivers, seas, buildings, or any objects that might obstruct signal reception, and must track throughout the survey, or for at least 4 hours, known as the base. The second equipment, called the rover, moves across the points of interest, following the procedures of the chosen technique. What differentiates each relative positioning technique is the procedure used with the rover in the field. Subsequently, the base data is processed in relation to known reference stations, and the rover data is processed in relation to the base (Segantine, 2005; Monico, 2008; Dorth, 2010; Muñoz & Cerón-Calderón, 2018; Sinegalia et al., in press).

In absolute positioning techniques, the goal is to determine the position of the point of interest in the GNSS reference system, but without the need for known stations, requiring only one receiver during the survey (Dorth, 2010; IBGE, 2025). In the SPP technique, no processing

is carried out; that is, the data is used without statistical refinement. In PPP, the data is processed and corrected via software, but without reference station parameters in these corrections (IBGE, 2025).

Another relevant aspect of surveys using GNSS methodologies concerns the estimation of precision and accuracy of the measurements, which are important indices to reflect the performance and quality of the measurement. Although manufacturers provide the possible precisions to be achieved, they do not address the corresponding accuracy (Kai-Feng et al., 2019). Accuracy measures the proximity of an estimate to its true parameter or value, while precision reflects the consistency of the measured quantity with its mean (Muñoz & Cerón-Calderón, 2018).

In this context, a GNSS survey may present a discrepancy of a few millimeters around the mean value of the observations from that tracking, meaning a high value in terms of the precision of the found coordinates, but in terms of accuracy, it could have submetric discrepancies (Swinfield et al., 2019; Pourreza et al., 2022).

In this study, we aimed to determine the possible accuracies for different GNSS positioning methodologies, considering varying tracking times and field scenarios. To do this, we conducted surveys in a previously established planimetric network, called the Cepegeo Network (for more information, refer to Sinegalia et al., in press). The selected points were chosen to simulate common conditions in practical applications, including remote forest monitoring.

The control points were positioned both in areas adjacent to forests and in forests with low-density canopies, representing typical scenarios of points deployed in open areas—considered "ideal situations" for base points in relative positioning techniques. Additionally, we investigated more challenging scenarios, such as points located in open areas near hill slopes, water bodies (such as lakes in the area), and buildings, as well as in forests with medium- and high-density canopies.

The surveys were carried out at different times, with tracking times ranging from 1 to 2 minutes to 44 hours. The 44-hour survey, in addition to allowing the analysis of the impact of long occupations on data quality, enabled the assessment of the influence of the acquisition time on the different positioning techniques used. Furthermore, the surveys were conducted on various dates and seasons of the year, expanding the scope of the analyses.

Based on the results obtained, our objective is to structure a table with the found accuracies that optimize the cost-benefit ratio concerning data collection time, the method used, and the control point situation. Additionally, we aim to create a table detailing the achievable

accuracy in different combinations of factors. We hope that these results contribute to the improvement of tools for developing strategies for carbon stock assessment in forest ecosystems, both preserved and under restoration.


5.2 Methods

5.2.1 Design: Overview

Initially, the vertices of the Cepegeo Geodetic Network that would be surveyed in this study were selected, and the surveys were then conducted using the chosen techniques. Subsequently, the data processing and adjustments were performed, and the data were tabulated and analyzed with the objective of generating the accuracy table proposed in this study.

Figure 9 below presents the overall design developed in this study.

Figura 9: General outline.




5.2.2 Study Area

The study was conducted on the campus of the Federal University of São Carlos (UFSCAR), called Lagoa do Sino, located in the city of Buri, in the southwestern region of the

State of São Paulo, Brazil. The campus covers an area of 643.3421 hectares, near the Paranapanema River. Its central coordinates are $23^{\circ}47'51''$ S and $48^{\circ}35'34''$ W. Figure 10 presents the aforementioned study area.

Figura 10: Study Area.



5.2.3 Methodology

5.2.3.1 Definition of the Vertices

To assess the accuracy of a measurement, it is necessary to know its true value, which is adopted as the reference value. In this context, the vertices selected for this study are part of the Cepegeo Geodetic Network, as these vertices have their coordinates defined and certified in descriptive records.

Geodetic networks are essentially the materialization of points with a high-precision geodetic reference, forming a cartographic base with a structure compatible with modern positioning techniques. However, in most Brazilian cities, there is still a lack of geodetic and cartographic bases that meet these specifications, which are often outdated or even nonexistent. This can lead to a series of complications, ranging from simple topographic surveys to large structural disasters (Luz, 2019).

The vertices of this network are identified as Cepegeo + number (from 01 to 20), with the acronym used for their designation being CP + number (example: CP01). Regarding the choice of the vertices surveyed, 15 points were selected to meet the tests outlined in this study. The simulated conditions include forest monitoring scenarios, with vertices located in areas adjacent to forests and in forest zones with low-density canopies (to simulate the situation of

control points), in addition to points in open areas, considered an "ideal situation" (to meet the requirements for base vertices in relative positioning techniques). Surveys were also conducted in open areas, but near hill slopes, bodies of water, and buildings, as well as in forest areas with medium and high-density canopies. The aim was to evaluate the influence of multipath and cycle loss in GNSS positioning under these conditions, in addition to checking whether there is deterioration in the quality of the survey and the magnitude of this deterioration. Table 12 presents the selected vertices, the physical conditions in which they were placed, and the main factor considered regarding the deterioration of survey quality using GNSS.

Table 12: Vertices of the Cepegeo Network adopted and the influencing factor considered.

Point(s)	Condition	Influencing Factor on Survey Quality
CP01 e CP20	Ideal situation = open sky, no nearby objects such as buildings, forests, bodies of water, or terrain slopes (inclines)	Only random errors
CP19	Open sky, but near a hill slope (3.5 meters away)	Slight deterioration may occur due to multipath errors
CP03 e CP07	Distance between 100 and 140 meters from a body of water; Distance between 4 and 10 meters from buildings	Medium deterioration may occur due to multipath errors
CP05 e CP06	Distance between 10 and 50 meters from a body of water	High deterioration may occur due to multipath errors
CP08 e CP09	Adjacent to a forest and/or forest clearing	Medium to high deterioration may occur due to multipath errors; Cycle losses may occur
CP10	Forest with medium-density canopy	High deterioration may occur due to multipath errors; Medium likelihood of cycle losses
CP02	Forest with high-density canopy	High deterioration may occur due to multipath errors; High likelihood of cycle losses
CP11 e CP12	Adjacent to a forest and located 1.5 to 3 meters from buildings	High deterioration may occur due to multipath errors; Medium likelihood of cycle losses
CP13	Surrounded by buildings in all directions	High deterioration may occur due to multipath errors; Cycle losses
CP14	Open sky, but near a hill slope (2 meters away) and a building (10 meters away)	Light to medium deterioration may occur due to multipath errors

5.2.3.2 Data Acquisition and Processing

Surveys using Relative Positioning Techniques

The relative positioning techniques adopted in this study were the GNSS Relative Static, SAG, RTK, post-processed RTK, and SPP positioning methodologies. GNSS receivers from Spectra Geospatial, model Spectra SP60, were used, and subsequently, the processing and adjustments corresponding to each methodology were carried out using the Survey Office and Topcon Tools software.

The relative methodologies used in this step were RTK, post-processed RTK, relative static, and stop-and-go, with different tracking times (between 1 and 2 minutes for kinematic and 5 to 50 minutes and from 1 hour to 6 hours for static) on vertices with low forest cover, and/or adjacent to forests, as well as near buildings and lakes. With the base receiver, we occupied vertex CP01 and/or CP20, and the rover receiver covered the vertices of interest, in the times established for each technique.

Subsequently, the processing and adjustment of these data were carried out using the data from the Brazilian Continuous Monitoring Network for processing the base in the Survey Office and Topcon Tools software, followed by the processing of the rover in the same two software programs.

Surveys using Absolute Positioning Techniques

Surveys were carried out using the SPP and PPP methodologies, with different tracking times, and subsequently, the processing and adjustment of these data were performed in PPP-IBGE.

The coordinates considered for the PPS technique were provided in the report generated by the mentioned website, in the section “Coordenadas Sirgas: On the date of the survey,” and for the PPP technique, in the section “Coordenadas Sirgas: In 2000.4 (This is the one that should be used).” An example of the generated report can be found in the supplementary material.

Data Tabulation and Analysis

In this step, the data considered relevant for this project were processed and adjusted together using the Least Squares Method (LSM), and validated through the Chi-Square test. Then, the results obtained were tabulated and analyzed with the objective of evaluating the accuracies provided by each method and tracking time, in order to identify the best situation. The analysis compared the control points in a forest environment with the vertices installed under ideal conditions.

5.2.4 Accuracy Table

In this step, we organized the data into a table with the aim of correlating the methodologies used and the accuracy obtained, according to the condition of the vertices, as per the objective of this study. The goal is to provide guidelines for future studies in obtaining control points commonly used to correct and/or validate products generated by drones. The table was subdivided into the following accuracy classes: A1, for accuracy between 0.001 and 0.01 m; A2, for accuracy between 0.011 and 0.05 m; A3, for accuracy between 0.051 and 0.1 m; B, for accuracy between 0.101 and 0.3 m; C, for accuracy between 0.301 and 0.5 m; and D, for accuracy between 0.501 and 0.8 m.

5.2.5 Precision x Accuracy

In this step, the analysis compared the precisions provided in the adjustments of the data from the surveys conducted with each technique and the accuracy effectively obtained for each vertex surveyed.

5.3 Results

5.3.1 Coordinates and Precisions Obtained in the Surveys

The following Table 13 presents the approved coordinates and those obtained using the techniques and methodologies subject to testing for vertex CP01, as well as the respective precisions found in each survey.

The tables for the remaining vertices can be found in the Supplementary Material.

Table 13: oordinates, Precisions, and Techniques - Vertex CP01.

CP01								
N	σ_n	E	σ_e	Helip	σ_z	Situation	Tracking	
7386020,568	0,003	140160,141	0,009	633,87	0,013	Certified	Time	Obs.
7386020,575	0,005	140160,136	0,023	633,950	0,042	Static	5h33	
7386020,569	0,012	140160,147	0,026	635,558	0,029	Static	10h29	
7386020,569	0,012	140160,147	0,026	633,943	0,029	Static	10h29	
7386020,567	0,001	140160,109	0,002	635,580	0,002	PPP	10h29	
7386020,567	0,001	140160,109	0,002	633,890	0,002	PPP	10h29	
7386020,571		140160,129		634,029		SAG	20 min	

5.3.2 Accuracy Table

Table 14 presents the classes considered according to the dispersion, and Tables 15 and 16 show the situation of the vertex, the survey method, and the class it falls into, for both planimetry and altimetry, respectively.

Table 14: Classes and Considered Dispersion.

Classification Class	Accuracy (C) (spread between)
A1	0,001 à 0,01 (m)
A2	0,011 à 0,05 (m)
A3	0,051 à 0,1 (m)
B	0,101 à 0,3 (m)
C	0,301 à 0,5 (m)
D	0,501 à 0,8 (m)

Table 15: Accuracy Table – Planimetry.

Planimetry		
Situation	Method	Accuracy (C)
Ideal	Static e PPP (minimum 5 h)	A1
	Static (3 h)	A3
	RTK post-processed	B
	RTK	C
Ideal and with slope	Static (4 h)	A2
	RTK post-processed and RTK	C
Buildings	SAG e PPP (minimum 30 minutes)	B
	Static (minimum 30 minutes)	B-C-D
Water	SAG, PPP (minimum 30 minutes) and Static (minimum 30 minutes)	B
Forest (low density)	SAG and PPP (minimum 30 minutes) and Static (minimum 30 minutes)	B
Forest (medium density)	Static (minimum 30 minutes)	B
	SAG and PPP (minimum 30 minutes)	C-D
Forest (high density)	Static (minimum 30 minutes)	D

Table 16: Accuracy Table – Altimetry.

Altimetry		
Situation	Method	Accuracy (C)
Ideal	Static (minimum 6h)	A2
	Static (minimum 5h) and PPP (minimum 6h)	A3
	SAG	B-C
Ideal and with slope	Static (minimum 6h) and PPP (minimum 6h)	A3
Buildings	PPP (minimum 3h) and Static (minimum 2h)	B
	Static (minimum 30 minutes)	D
Water	PPP (minimum 3h) and Static (minimum 2h)	B
Forest (low density)	SAG e PPP (minimum 30 minutes)	D
Forest (medium density)	PPP (minimum 50 minutes) and Static (minimum 2h)	D
Forest (high density)	Static (minimum 6 h)	D

According to Tables 15 and 16, it was observed that in ideal conditions, the accuracy in the planimetric component ranged from 5 millimeters to 1 centimeter (class A1) for the static relative method, but only for tracking with a minimum duration of 5 hours.

For tracking of at least 3 hours, this technique showed an accuracy between 5.1 and 10 centimeters (class A2). In vertices located in ideal conditions, but with slope, the accuracy reached class A2, ranging from 1.1 to 5 centimeters.

The SAG, PPP (with a minimum tracking time of 30 minutes), and static (also with a minimum tracking time of 30 minutes) techniques provided accuracies in the range of 10.1 to 30 cm, both for vertices near buildings and bodies of water and those located in low-density forest areas. However, for vertices near buildings, results were also observed in classes C (between 30.1 and 50 centimeters) and D (between 50.1 and 80 cm). This phenomenon can be explained by the influence of multipath on vertices located very close to buildings.

For vertices in areas with medium canopy density, class B was achieved using the static relative method (minimum tracking of 30 minutes), with accuracies between 30.1 and 80 centimeters (classes C and D), when the techniques used were SAG and PPP (with a minimum tracking time of 30 minutes). In vertices in areas with high canopy density, the only class achieved was D.

Regarding the planimetric accuracy for vertices in ideal situations, the SAG methodology allowed accuracies between 10 and 50 cm, while PPP, with tracking of at least 30 minutes, showed accuracies between 30 and 50 cm. As for the altimetric component, for vertices in ideal conditions, the Static methodology (with tracking of at least 6 hours) allowed an accuracy of up to 5 cm. The PPP (tracking of at least 6 hours) and static (tracking of at least 5 hours) methodologies provided accuracies between 5 and 10 cm, while the SAG technique showed accuracies between 10 and 30 cm.

For vertices located near buildings and bodies of water, it was necessary to apply the PPP methodology (minimum tracking of 3 hours) or the Static methodology (minimum tracking of 2 hours) to achieve accuracies between 10 and 30 cm. For points in conditions similar to control points, the altimetric accuracy between 10 and 30 cm was achieved with the static methodology, with a minimum tracking of 2 hours per point. For accuracies up to 50 cm, the surveys could be conducted with the PPP methodology (minimum tracking of 90 minutes) or Stop-and-Go. For the altimetric component, no GNSS methodologies were identified capable of achieving sub-centimetric accuracies.

5.3.3 Precision x Accuracy

Figures 11 and 12 present, respectively, the precisions obtained through processing and the accuracy found after data analysis, as well as the scatter plot of these coordinates, considering CP01.

Figura 11: Precision vs. Accuracy of CP01 Coordinates.





Figura 12: Scatter Plot of Planimetric Coordinates for CP01.



Figures 13 and 14 present the scatter plot for the vertices CP02 and CP09.

Figura 13: Scatter Plot of Planimetric Coordinates for CP02.





Figura 14: Scatter Plot of Planimetric Coordinates for CP09.



5.4 Discussion of results

5.4.1 Coordinates from the surveys and Accuracy Table

An extremely important factor when performing GCP surveys using GNSS receivers is positional quality in terms of accuracy. Although the surveys provide information about the observed precisions, they do not offer sufficient parameters to estimate the accuracy of these measurements. Therefore, it is possible for a sample to show high precision, with small deviations from the mean, but due to the lack of accuracy, the degree of correctness can be lower (Pourreza et al., 2022; Sinegalia et al., in press).

In this context, the present study evaluated the accuracy of measurements obtained with GNSS surveys, considering different conditions, methodologies, and tracking times, with the goal of creating a table that presents the possible accuracies for GCPs in a remote forest monitoring context.

Throughout the research, we analyzed the accuracy of the coordinates obtained by various methodologies and in different scenarios, aiming to understand how variables influence the accuracy of the data.

From the comparison between the approved coordinates of the network vertices and the results of the GNSS surveys, we aimed to tabulate the main conditions for each class considered, as well as evaluate the influence of factors such as tracking time and vegetation density. This analysis is essential to improve data collection techniques and optimize the use of GNSS systems in practical applications, such as forest monitoring and mapping of remote areas.

Analyzing Tables 4 and 5, it was possible to verify that, for vertices in ideal situations—i.e., those not highly impacted by multipath effects (Peng et al., 2021; Paula et al., 2023)—when the PPP and static techniques were used with a minimum of 5-hour tracking, accuracy in class A1 was achieved, while 4-hour tracking resulted in A2 class accuracy. This information is of great relevance, as for surveys using relative techniques, it is recommended to have at least 4-hour tracking for the base point (White et al., 2013; Aguilar et al., 2019; Arévalo-Verjel et al., 2022).

Another important piece of information concerns the SAG, relative static (minimum 30 minutes), and PPP (minimum 30 minutes) techniques, which resulted in accuracies between 10.1 and 30 centimeters, both for vertices near buildings and bodies of water, and for forests with low canopy density. This suggests that the impact of multipath behaves similarly in these situations.

In forests with high canopy density, the best accuracy value was obtained by using the relative static technique (minimum 30 minutes); however, this result yielded accuracy between 50.1 and 80 centimeters, demonstrating that tree canopy density directly impacts the quality of the received signal.

Regarding altimetry, the best GNSS results (between 1.1 and 10 centimeters) were only observed in vertices in ideal situations. For vertices near buildings and bodies of water, the accuracies found ranged from 10.1 to 30 centimeters, exclusively for 2-hour tracking (relative static method) and 3-hour tracking (PPP method). This factor suggests that multipath effects, as well as cycle losses, are also relevant in the degradation of altimetric coordinate quality, alongside tropospheric refraction (Segantine, 2005; Monico, 2008).

Regarding the RTK technique and post-processed RTK, both did not present accuracy values superior to 10 centimeters for any of the situations.

5.4.2 Precision x Accuracy

Aiming to obtain the accuracy analysis possible by method, the results were analyzed through the dispersion around the homologated value for each vertex, considering the different methods, situations, and tracking times.

Figures 4 to 6 present the precisions obtained through the processing and adjustment of the data for vertices CP01, CP02, and CP09, and the accuracy found after statistical treatment of these, while Figure 3 graphically presented the dispersion of these coordinates around the real value for CP01.

The selection of these vertices for the creation of the respective graphs was due to the fact that they are vertices in ideal situations, in forests with high canopy density and in situations similar to control points/forests with low canopy density, respectively, in line with the objectives presented in this study, where the most significant result observed refers to the discrepancy between the precisions and the accuracies obtained in the GNSS surveys.

The precisions presented for methods considered of high precision, such as PPP, with tracking times of 5 and 10 hours, showed absolutely discrepant values when compared to the accuracy.

Figure 03, presented earlier, demonstrates that the precision provided in the report by IBGE for the processed point was 0.002m. However, the accuracy of the same point was 0.032m, which was lower than the accuracy of the SAG method, which had a 5-minute occupation time and an accuracy of 0.012m. The survey that generated the best accuracy value was the one performed with the relative static technique and a 10-hour tracking time.

Another important point is that although the methodologies considered to be of high precision (relative static and, primarily, PPP) presented sub-centimetric precisions, it was possible to verify that, for accuracy, only the “optimal” cases (in ideal situations and with more than 5 hours of tracking) for the planimetric component had accuracies consistent with the provided precisions. For example, the precision of the 5-hour static tracking was better than that of the 10-hour tracking, but the 10-hour tracking was more consistent with reality, showing a precision of 0.019m and an accuracy of 0.0067m.

For the altimetric component, the presented precisions were not compatible with the accuracies found in the GNSS methodologies studied in any of the cases.

5.4.3 Implications in the Context of Forest Restoration Monitoring

Forest ecosystems play a crucial role in maintaining the balance of the Earth's carbon cycle, as the absorption of atmospheric CO₂ is greater than the amount released into the atmosphere through processes such as plant respiration and decomposition by bacteria and fungi (Houghton, 2007). Thus, forest conservation is critically important for mitigating climate change and slowing deforestation. Combined with an increase in reforestation and other management measures to improve forest ecosystem productivity, it can conserve or sequester significant amounts of carbon, promoting negative emissions and contributing to achieving the United Nations (UN) Climate Change goals in the context of Reducing Emissions from Deforestation and Forest Degradation (REDD) (Dixon, 1994; Houghton, 2007).

However, the monitoring of areas undergoing forest restoration typically depends on extensive fieldwork to collect inventory data. In this context, the advent of RPAS and a wide range of sensors capable of generating high-resolution images has enabled the development of new approaches derived from remote sensing and photogrammetry (Berra & Peppia, 2020). This has emerged as a promising alternative, allowing for the complementing of field data collection, reducing costs, and providing precise information on the spatial extent of forests, species composition, physiological characteristics, as well as changes in forest cover and carbon content. Furthermore, it allows for a significant increase in the assessment of the performance of techniques and products at various scales (Gyamfi-Ampadu et al., 2021; White et al., 2017).

LiDAR is an active remote sensing system that uses laser light pulses to measure the distance between the sensor and an object or surface. Its operating principle is based on sending laser pulses toward a target and measuring the time it takes for the light pulse to return to the sensor, thereby directly estimating the vertical structure of objects. It has emerged as a particularly useful technology for the precise characterization of forest fragments at various resolutions, mainly regarding the measurement of structural parameters of the forest (Corte et al., 2020; Sinegalia et al., 2023).

Compared to traditional remote sensing technologies, LiDAR has greater penetration into the canopies of trees and is not easily affected by weather conditions. Its applications have expanded rapidly in recent decades to model forest structural attributes (such as tree height, which is directly related to forest biomass), as it is capable of detecting both the forest floor and canopy elements. This enables the generation of three main products: the DTM (Digital Terrain Model), the DSM (Digital Surface Model), and the CHM (Canopy Height Model), which can be estimated by differentiating between the DSM and DTM (Jaafar et al., 2018; Corte et al., 2020; d' Oliveira, 2021), and allows for the precise estimation of AGB (Above Ground Biomass) and carbon stocks above the ground (Ota et al., 2015).

The use of LiDAR data has proven particularly useful because the detection and delineation of individual tree crowns (ITC - Individual Tree Crown) are commonly generated from the CHM, and this approach is widely used in forest studies for AGB estimation modeling, species identification, and analysis of forest gaps (Jaafar et al., 2018). With the advancement of LiDAR systems and their higher point density, more recent approaches directly use 3D point clouds for ITC segmentation (Garcia et al., 2017; Albuquerque et al., 2019).

However, although airborne LiDAR is one of the most reliable tools for estimating AGB in forests using remote sensors, its acquisition costs are generally high, making it difficult to monitor large forest areas (Ota et al., 2015; Corte et al., 2020).

In this context, RPAS with embedded RGB sensors emerge as a promising alternative, as they are characterized by low cost and an excellent balance between resolution and scale, allowing the generation of high-precision products such as maps, orthophotos, point clouds, and digital surface or terrain models. Essentially, the accuracy of these products varies depending on the technical specifications of the sensors involved in the RPAS system, such as digital cameras, GNSS receiver boards, and IMU (Inertial Measurement Unit) components, as well as the technique adopted in their processing (Maesano et al., 2022; Ocalan et al., 2022).

Additionally, the evolution of sensors coupled to RPAS, including long-range radio control, high-resolution RGB cameras, and automatic processing algorithms for stereoscopic images, facilitates their application in the acquisition of stereoscopic images obtained by optical sensors and processed photogrammetrically by 3D reconstruction software to generate DTMs and DSMs (Singh et al., 2023).

Data derived from photogrammetry offer several advantages over field-based and LiDAR approaches in terms of scale and efficiency, and have been presented as a viable and cost-effective alternative. However, detecting the ground in dense tropical forests, which is necessary for estimating canopy height, is currently considered highly challenging (Zhang, 2021), where the quality of the final product (DTMs, DSMs, orthomosaics) is intrinsically linked to the approach adopted in image acquisition. Spatial resolution, commonly referred to as GSD (Ground Sampling Distance), is a crucial factor for success in the processing stage (Szypuła, 2023; Singh et al., 2023).

The GSD is affected by several factors, including flight altitude and trajectory, the sensor used, lighting conditions (sun angle and cloud cover), and the surface cover of the terrain. Furthermore, the accuracy of the resulting model also depends on camera tilt, image overlap, flight trajectory, camera calibration method, and the software used in the processing (Szypuła, 2023).

Progress in computer science has enabled the production of better quality DSMs using the Structure from Motion (SfM) approach. This approach aims to generate 3D geometry from a collection of unordered overlapping photographs using standard automated techniques involving computer vision. This application has proven satisfactory in producing a high-resolution 3D point cloud model similar to those derived from airborne LiDAR. Previous studies have demonstrated the usefulness of the SfM approach for topographic mapping (Fonstad et al., 2013; Turner et al., 2015; Lucieer et al., 2014; Niethammer et al., 2011; Ota et al., 2015).

However, especially when topographic variation is high, accurate DTMs are essential for producing precise above-ground biomass models and 3D analyses (e.g., gap proportion analyses and height profile). In addition to technical aspects related to the planning and execution of a drone mission, additional measures can be applied to improve the quality of the data collected. The most commonly used method to increase the accuracy of the data includes the use of GCPs (Singh et al., 2023; Ocalan et al., 2022).

In addition to the quality provided in modeling forest attributes, the correct placement of plots also plays a crucial role in forest monitoring. This unfolds into a series of fundamental implications for understanding and preserving forest ecosystems, as strategically located plots enable effective detection of changes in forest composition, facilitating the identification of environmental impacts, climate change, and human activities such as timber exploitation or deforestation. Such dynamic monitoring capability is critical for the sustainable management of forest resources (Wulder et al., 2007; Sparrow et al., 2020).

The correct placement of plots is not merely a logistical matter, but a strategic element that influences the quality and representativeness of the data collected, which aims to support decision-making and the implementation of conservation policies in studies involving predictions about the future of forests. The validation of these models depends on the accuracy of field data, whose quality is directly influenced by the position of the plot. Thus, the careful positioning of plots emerges as a strategic and essential practice for understanding and protecting the forest resources of our planet (Wulder et al., 2007).

However, especially when topographic variation is high, the use of GCPs, properly distributed in the area to be mapped (in easily identifiable locations in the images), is an additional measure commonly adopted to improve the accuracy of products derived from these sensors, enabling absolute orientation in processing, where the cartographic product is oriented, leveled, and scaled (Arévalo-Verjel et al., 2022).

The inclusion of GCPs is considered essential, particularly when the survey aims at implementing small-scale forest restoration interventions or monitoring changes over time (Swinfield et al., 2019).

However, the quality of these GCPs is typically assessed based on precision, rather than accuracy. As demonstrated in this study, precision and accuracy are not always compatible in most GNSS surveys used for determining GCPs. The most concerning aspect is the positional quality of the altimetric component, as, as mentioned earlier, the accuracy of the heights directly impacts the quality of products such as DTM and DSM. If the variation in terms of the accuracy

of GCPs is not properly known, their inclusion in the processing can compromise the final quality of these products.

Thus, while this study has provided valuable contributions regarding the accuracy of control points obtained by GNSS receivers, there are still questions regarding how the quality of such data influences remote forest monitoring.

5.5 Recommendations for Future Work

In light of the questions raised regarding the influence of GCPs in the context of remote forest monitoring, we present some recommendations that can serve as directions for new studies aimed at overcoming the mentioned gaps. These are:

1. Does the precision of Ground Control Points (GCPs) obtained by GNSS influence the model obtained through aerial photogrammetry?
2. If so, is there a significant impact on the measurements of indicators related to carbon stock (such as tree height, for example)?
3. Without GCPs, what precision can we expect for the elevation data of RGB and LiDAR products?

5.6 Final Considerations

This study proposed that, through the analysis of the results and precisions obtained when conducting surveys with different GNSS positioning methodologies, considering various locations and tracking times, a table of accuracy could be developed that reflects what can be found when using such techniques in different practical aspects, with an emphasis primarily on remote forest monitoring.

To achieve the objectives, surveys were conducted at the approved vertices of the Cepegeo Network, using several GNSS techniques, such as relative, rapid static-relative (SAG), real-time kinematic (RTK), single point positioning (PPS), and precise point positioning (PPP). Subsequently, the corresponding processing and adjustments were made using specific software.

Later, we analyzed the accuracy of various GNSS techniques, with a focus on remote monitoring of areas in the process of forest restoration. The results presented highlighted that the accuracy of surveys at vertices in ideal conditions, using the static relative methodology, showed the best relationship between precision and accuracy, as well as the best positional quality. However, for the altimetric component, no GNSS methodology demonstrated accuracy compatible with the precisions provided through the adjustments.

Therefore, we can infer from the analyses in this study that the static relative methodology stood out, providing an excellent relationship between precision and accuracy in ideal situations for the planimetric component. However, for the altimetric component, no GNSS methodology achieved accuracy compatible with the precisions of the adjustments made.

These conclusions contribute to a deeper understanding of the performance of these techniques in different scenarios, guiding more informed choices for future surveys.

Literature Cited

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. <https://doi.org/10.3390/s19081934>.

Albuquerque, R. W., Costa, M. O., Ferreira, M. E., Carrero, G. C., Grohmann, C. H., 2020. Remotely piloted aircraft imagery for automatic tree counting in forest restoration areas: a case study in the Amazon. *Journal of Unmanned Vehicle Systems*. 8(3): 207-223. <https://doi.org/10.1139/juvs-2019-0024/>.

Almeida, D.R.A. de, Stark, S.C., Chazdon, R., Nelson, B.W., Cesar, R.G., Meli, P., Gorgens, E.B., Duarte, M.M., Valbuena, R., Moreno, V.S., Mendes, A.F., Amazonas, N., Gonçalves, N.B., Silva, C.A., Schietti, J., Brancalion, P.H.S., 2019. The effectiveness of lidar remote sensing for monitoring forest cover attributes and landscape restoration. *For. Ecol. Manag.*, 438, pp. 34-43. <https://doi.org/10.1016/j.foreco.2019.02.002>.

Almeida, D. R. A. de, Broadbent, E. N., Ferreira, M. P., Meli, P., Zambrano, A. M. A., Gorgens, E. B., Resende, A. F., Almeida, C. T. de, Amaral, C. H. do, Corte, A. P. D., Silva, C. A., Romanelli, J. P., Prata, G. A., Papa, D. de A., Stark, S. C., Valbuena, R., Nelson, B. W., Guillemot, J., Féret, J-B., Chazdon, R., Brancalion, P. H. S., 2021. Monitoring restored tropical forest diversity and structure through UAV-borne hyperspectral and lidar fusion. *Remote Sensing of Environment*, 264, 112582. ISSN 0034-4257. <https://doi.org/10.1016/j.rse.2021.112582>.

Arévalo-Verjel, A. N., Lerma J. L., Prieto, J. F., Carbonell-Rivera, J. P., Fernández, J., 2022. Estimation of the Block Adjustment Error in UAV Photogrammetric Flights in Flat Areas. *Remote Sensing*. 14(12):2877. <https://doi.org/10.3390/rs14122877>.

Berra, E. F., Peppas, M. V., 2020. Advances and Challenges of UAV SFM MVS Photogrammetry and Remote Sensing: Short Review. *IEEE Latin American GRSS & ISPRS Remote Sensing Conference (LAGIRS)*, pp. 533-538 DOI:[10.5194/isprs-archives-XLII-3-W12-2020-267-2020](https://doi.org/10.5194/isprs-archives-XLII-3-W12-2020-267-2020).

Brancalion, P.H.S., Holl, K.D., 2020. Guidance for successful tree planting initiatives *J. Appl. Ecol.*, 57 (12), pp. 2349-2361. DOI: 10.1111/1365-2664.13725.

Corte, A. P. D., Souza, D. V., Rex, F. E., Sanquetta, C. R., Mohan, M., Silva, C.A., Zambrano, A.M.A., Prata, G., Almeida, D. R. A. de, Trautenmüller, J. W., Klauberg, C., Moraes A. de, Sanquetta, M. N., Wilkinson, B., Broadbent, E.N., 2020. Forest inventory with high-density UAV-Lidar: Machine learning approaches for predicting individual tree attributes. *Computers and Electronics in Agriculture* 179:105815, ISSN 0168-1699, <https://doi.org/10.1016/j.compag.2020.105815>.

Correa Muñoz, N. A. & Cerón-Calderón, L. A., 2018. Precision and accuracy of the static GNSS system for surveying networks used in Civil Engineering. *Ing. Inv.*, 38:1, pp. 52–59. doi:10.15446/ing.investig.v38n1.64543.

Dixon, R. K., Solomon, A. M., Brown, S., Houghton, R. A., Trexler, M. C., Wisniewski, J. 1994. Carbon pools and flux of global forest ecosystems. *Science*, 263, 185–190. DOI: [10.1126/science.263.5144.185](https://doi.org/10.1126/science.263.5144.185).

d'Oliveira, M. V. N., Figueiredo, E.O., Almeida D. R. A. de, Oliveira L. C., Silva, C. A., Nelson, B.W., Cunha R. M. da, Papa, D. A., Stark, S. C., Valbuena, R., 2021. Impacts of selective logging on Amazon forest canopy structure and biomass with a LiDAR and photogrammetric survey sequence, *Forest Ecology and Management*. Volume 500. 119648. ISSN 0378-1127. <https://doi.org/10.1016/j.foreco.2021.119648>.

Dorth, M. K. S., 2010. Proposta De Classificação De Linhas De Base Obtidas Com Dados Gps, A Luz De Árvore De Decisão. Dissertação de mestrado. EESC-USP. São Carlos.

Dupuis, C., Lejeune, P., Michez, A., Fayolle, A., 2020, How Can Remote Sensing Help Monitor Tropical Moist Forest Degradation?—A Systematic Review. *Remote Sensing*, 12(7) (2020),1087. <https://doi.org/10.3390/rs12071087>.

Elsheikh, M., Iqbal, U., Noureldin, A., Korenberg, M., The Implementation of Precise Point Positioning (PPP): A Comprehensive Review. *Sensors* 2023, 23, 8874. <https://doi.org/10.3390/s23218874>.

Erbaugh, J.T. & Oldekop, J.A., 2018. Forest landscape restoration for livelihoods and well-being. *Curr. Opin. Environ. Sustain.*, 32, pp. 76-83. ISSN 1877-3435. <https://doi.org/10.1016/j.cosust.2018.05.007>.

Fagan, M.E., Reid, J.L., Holland, M.B., Drew, J.G., Zahawi, R.A., 2020. How feasible are global forest restoration commitments? *Conserv. Lett.*, 13 (3), p. e12700. ISSN: 1755263X. DOI: 10.1111/conl.12700

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 Surf. Process. Landforms*. 38, 421–430. <https://doi.org/10.1002/esp.3366>.

Gómez, C., Alejandro, P., Hermosilla, T., Montes, F., Pascual, C., Ruiz, L. A., Álvarez-Taboada, F., Tanase, M., Valbuena, R., 2019. Remote sensing for the Spanish forests in the 21st century: a review of advances, needs, and opportunities. *Forest Systems*. 28(1), eR001. <https://doi.org/10.5424/fs/2019281-14221>.

Gyamfi-Ampadu, E., Gebreslasie, M., 2021. Two Decades Progress on the Application of Remote Sensing for Monitoring Tropical and Sub-Tropical Natural Forests: A Review. *Forests*. 12(6):739. <https://doi.org/10.3390/f12060739>

Guariguata, M.R. & Evans, K., 2020. A diagnostic for collaborative monitoring in forest landscape restoration. *Restor. Ecol.*, 28, pp. 742-749. ISSN1061-2971. DOI: <https://doi.org/10.1111/rec.13076> open in new

Höhl, M., Ahimbisibwe, V., Stanturf J.A., Elsasser, P., Kleine, M., Bolt, A., 2020. Forest landscape restoration—what generates failure and success? *Forests*, 11, p. 938. <https://doi.org/10.3390/f11090938>

Houghton, R. A., Nassikas A. A., 2018. Negative emissions from stopping deforestation and forest degradation, globally. *Glob. Chang. Biol.* 24, 350–359. DOI: [10.1111/gcb.13876](https://doi.org/10.1111/gcb.13876)

IBGE (Instituto Brasileiro de Geografia e Estatística). 2024. Instruções para homologação de estações estabelecidas por outras instituições.

Jaafar, W. M., Woodhouse, I. H., Silva, C. A., Omar, H., Abdul Maulud, K. N., Hudak A. T., Klauberg, C., Cardil, A., Mohan, M., 2018. Improving Individual Tree Crown Delineation and Attributes Estimation of Tropical Forests Using Airborne LiDAR Data. *Forests*. 2018; 9(12):759. <https://doi.org/10.3390/f9120759>

Kai-Feng, M., Gui-Ping, H., Hai-Jun, X., Wei-Feng, W., 2019. Research on a Precision and Accuracy Estimation Method for Close-Range Photogrammetry. [https://doi-org.ez31.periodicos.capes.gov.br/10.1142/S0218001419550024](https://doi.org/ez31.periodicos.capes.gov.br/10.1142/S0218001419550024).

Liu, J., Hyyppä J., Yu, X., Jaakkola, A., Liang, X., Kaartinen, H., Kukko, A., Zhu, L., Wang, Y., Hyyppä, H., 2016. Can global navigation satellite system signals reveal the ecological attributes of forests? *International Journal of Applied Earth Observation and Geoinformation*, 50, pp.74-79. ISSN 1569-8432. <https://doi.org/10.1016/j.jag.2016.03.007>.

Lucieer, A., Jong, S.M., Turner, D., 2014. Mapping Landslide Displacements using Structure from Motion (SfM) and Image Correlation of Multi-Temporal UAV Photography. *Prog. Phys. Geogr.* 2014, 38, 97–116 DOI:[10.1177/0309133313515293](https://doi.org/10.1177/0309133313515293).

Maesano, C. N., Campbell, J. S., Foteinis, S., Furey, V., Hawrot, O., Pike, D., Aeschlimann, S., Reginato, P. L., Goodwin D. R., Looger, L. L., Boyden, E. S., Renforth, P., 2022. Geochemical

Negative Emissions Technologies: Part II. Roadmap. *Front. Clim.*, Sec. Negative Emission Technologies. <https://doi.org/10.3389/fclim.2022.945332>.

Mlambo, R., Woodhouse, I. H., Gerard, F., Anderson, K., 2017. Structure from Motion (SfM) Photogrammetry with Drone Data: A Low Cost Method for Monitoring Greenhouse Gas Emissions from Forests in Developing Countries. *Forests*. 8(3):68. <https://doi.org/10.3390/f8030068>.

Monico, J. F. G., 2008. Posicionamento pelo GNSS: descrição, fundamentos e aplicações. São Paulo: Ed. da Unesp, 2 ed., 476p.

Ocalan, T., Turk, T., Tunalioglu, N. *et al.*, 2022. Investigation of accuracy of PPP and PPP-AR methods for direct georeferencing in UAV photogrammetry. *Earth Sci Inform* 15, 2231–2238. <https://doi-org.ez31.periodicos.capes.gov.br/10.1007/s12145-022-00868-7>.

Ota T., Ogawa, M., Shimizu, K., Kajisa, T., Mizoue, N., Yoshida, S., Takao, G., Hirata, Y., Furuya, N., Sano, T., et al., 2015. Aboveground Biomass Estimation Using Structure from Motion Approach with Aerial Photographs in a Seasonal Tropical Forest. *Forests* 6(11):3882-3898. <https://doi.org/10.3390/f6113882>.

Niethammer, M., Huang, Y., Vialard, F.X., 2011. Geodesic regression for image time-series. *Med Image Comput Comput Assist Interv*. 11;14(Pt 2):655-62. doi: 10.1007/978-3-642-23629-7_80.

Patias, P., Giagkas, F., Georgiadis, C., Mallinis, G., [Kaimaris](#), D., Tsioukas, V., 2017. Evaluating horizontal positional accuracy of low-cost UAV orthomosaics over forest terrain using ground control points extracted from different sources. Fifth International Conference on Remote Sensing and Geoinformation of the Environment. <https://doi.org/10.1117/12.2278008>.

Paula, E. R., Monico, J. F. G., Tsuchiya, I. H., Valladares, C. E., Costa, S. M. A., Marini-Pereira, L., B. Vani, C., Moraes, A. O., 2023, A Retrospective of Global Navigation Satellite System Ionospheric Irregularities Monitoring Networks in Brazil. [Journal of Aerospace Technology and Management](#), 15.1288. <https://doi.org/10.1590/jatm.v15.1288>.

Peng, Y, Scales, WA, Hartinger, M. et al., 2021. Characterization of multi-scale ionospheric irregularities using ground-based and space-based GNSS observations. *Satell Navig* 2, 14. <https://doi.org/10.1186/s43020-021-00047-x>.

Pourreza, M., Moradi, F., Khosravi, M., Deljouei, A., Vanderhoof, M. K., 2022. GCPs-Free Photogrammetry for Estimating Tree Height and Crown Diameter in Arizona Cypress Plantation Using UAV-Mounted GNSS RTK. *Forests*. 13(11):1905. <https://doi.org/10.3390/f13111905>.

Sefercik, U. G., Kavzoğlu, T., Çölkesen I., Nazar, M., et al., 2023. 3D positioning accuracy and land cover classification performance of multispectral RTK UAVs. *International Journal of Engineering and Geosciences* (online) 8(2). <https://doi.org/10.26833/ijeg.1074791>.

Segantine, P. C. L., 2005. GPS – Sistema de Posicionamento Global. São Carlos: EESC/USP.

Setti Junior, P. de T., SILVA, C. M. da, Oliveira Junior, P. S. de; Alves D. B. M., Monico, J. F. G., 2020. Posicionamento multi-GNSS. *Revista Brasileira de Cartografia*, (S. l.), v. 72, p. 1200–1224. DOI: 10.14393/rbcv72nespecial50anos-56580.

Sinegalia, M. K. S. D., Santoro, G. B., Molin, P. G., 2023. How have RPAS helped monitor forests and what can we apply in forest restoration monitoring? *Restoration ecology* 32:1:e14061. <https://doi.10.1111/rec.14061>.

Sinegalia, M. K. S. D., Filho, J. R. K., Viveiros, J. M. S. M., Amaral, V. C., Soares, B. J. M., Fernandes P. F., Molin, P. G., 2023b. Influência da cintilação ionosférica na qualidade posicional de pontos de controle obtidos com GNSS: considerações no contexto do monitoramento florestal remoto. V Workshop do INCT GNSS-NavAer. INPE - São José dos Campos/SP.

Sinegalia, M. K. S. D., Ferreira, G. de A., Fernandes, P. F., Filho, J. R. K., Amaral, V. C., Viveiros, J. M. S. M., Soares, B. J. M., Rodrigues, N. B. D., Toledo, A. M. A., P. G. Molin. “no prelo”. *Conectando Paisagens: Implantação de Uma Rede Geodésica materializada em Ambientes Ideais, Florestais e Diversos. Revista Brasileira de Geografia Física. No prelo.*

Singh, C. H., Rai, A., Harshit, Mishra, V., Kushwaha, S. K. P., Jain, K., 2023. Quality Assessment of UAV Data using Multiple RTK Reference Stations. International Conference on Machine Intelligence for GeoAnalytics and Remote Sensing (MIGARS), Hyderabad, India. 1-4. <https://doi.org/10.1109/MIGARS57353.2023.10064555>

Sparrow, B. D., Foulkes, J. N., Wardle, G. M., Leitch, E. J., Caddy-Retalic, S., van Leeuwen, S. J., Tokmakoff, A., Thurgate, N. Y., Guerin, G. R., Lowe, A. J., 2020. Vegetation and Soil Survey Method for Surveillance Monitoring of Rangeland Environments. *Frontiers in Ecology and Evolution*; V8. DOI=10.3389/fevo.2020.00157. ISSN=2296-701X.

Swinfield, T., Lindsell, J. A., Williams, J. V., Harrison, R., Agustiono, D., Habibi, E., Gemita, C. B., Schönlieb, Coomes, D. A., 2019. Accurate Measurement of Tropical Forest Canopy Heights and Aboveground Carbon Using Structure From Motion. *Remote Sensing*. 11(8):928. <https://doi.org/10.3390/rs11080928>.

Szypuła, B., 2023. Accuracy of UAV-based DEMs without ground control points. *GeoInformatica*. <https://doi-org.ez31.periodicos.capes.gov.br/10.1007/s10707-023-00498-1>

Turner, D., Lucieer, A., Jong, S. M. de, 2015. Time Series Analysis of Landslide Dynamics using an Unmanned Aerial Vehicle (UAV). *Remote Sens*. 7:1736–1757. <https://doi.org/10.3390/rs70201736>.

White, J. C., Wulder, M. A., Hermosilla, T., Coops, N.C., Hobart, G.W., 2017. A nationwide annual characterization of 25 years of forest disturbance and recovery for Canada using Landsat time series. *Remote Sensing of Environment* 194:303-321. <https://doi.org/10.1016/j.rse.2017.03.035>.

Wulder, M. A., Nelson, T. A., Seemann, D., 2007. Using Spatial Pattern to Quantify Relationship Between Samples, Surroundings, and Populations. *Environ Monit Assess* 131, 221–230. <https://doi.org/10.1007/s10661-006-9470-8>

Zhang, H., Bauters, M., Boeckx, P., Van Oost, K., 2021. Mapping Canopy Heights in Dense Tropical Forests Using Low-Cost UAV-Derived Photogrammetric Point Clouds and Machine Learning Approaches. *Remote Sensing*. 13(18):3777. <https://doi.org/10.3390/rs13183777>.

6. ACURÁCIA POSICIONAL DE PRODUTOS RGB E LIDAR: UM ESTUDO DE CASO EM ARARAS-SP

RESUMO

A restauração florestal tem sido impulsionada por compromissos globais e demanda soluções eficientes para o monitoramento de áreas em recuperação. Tradicionalmente, o levantamento de dados em campo é eficaz, porém oneroso e de difícil escalabilidade. Nesse contexto, o uso de drones equipados com sensores RGB e LiDAR, emergem como alternativa promissora para viabilizar o monitoramento em larga escala. Este estudo teve como objetivo avaliar a acurácia dos produtos gerados por RPAS equipados com sensores RGB e LiDAR em uma área em processo de restauração florestal, onde, para isso, foram estabelecidos 90 pontos de controle na área de estudo, cujas coordenadas foram obtidas por levantamentos com GNSS de dupla frequência, estação total e nível geométrico. No que diz respeito aos dados RGB coletados, os mesmos foram processados visando gerar ortomosaicos e modelos digitais de elevação, em diferentes cenários considerando a inserção de nenhum a 60 pontos de controle. As nuvens de pontos LiDAR foram geradas e classificadas para criar modelos de altura do dossel. Os resultados indicaram que a quantidade de pontos de controle influencia diretamente a precisão dos produtos RGB, com o melhor desempenho alcançado com 15 pontos, garantindo elevada acurácia nos componentes planimétrico e altimétrico. No entanto, a inclusão de um número excessivo de pontos (acima de 50) ocasionou saturação do modelo (overfitting), reduzindo a precisão em determinadas áreas. Para os produtos LiDAR, a análise planimétrica revelou que os dados processados sem correção por base RTK apresentaram um deslocamento médio de 60 cm em comparação aos dados corrigidos. Além disso, a avaliação das distâncias geométricas entre pontos de referência evidenciou pequenas deformações na região central do modelo, sugerindo interferências na acurácia espacial. Quanto ao componente altimétrico, os resultados demonstraram que, no contexto deste estudo, a avaliação da qualidade posicional do LiDAR não pode ser considerada de forma absoluta, pois a combinação específica de sensor e software adotada pode ter introduzido variabilidades, especialmente nas correções das geotags. Diante dessas limitações metodológicas, enfatiza-se a necessidade de investigações futuras que aprimorem o processamento e a validação dos dados, a fim de possibilitar uma reavaliação mais precisa e robusta da qualidade posicional dos produtos LiDAR. Mesmo com tais restrições, os sensores RGB e LiDAR demonstraram ser ferramentas robustas para a coleta de dados geoespaciais em áreas florestais, e a combinação dessas tecnologias potencializa a precisão e a

eficiência do monitoramento, contribuindo significativamente para o desenvolvimento de estratégias de restauração e gestão ambiental.

Palavras-chave: Acurácia; Precisão; GNSS; Aerofotogrametria; Restauração Ecológica; Sensoriamento Remoto.

ABSTRACT

Global commitments have driven forest restoration and require efficient solutions for monitoring areas in recovery. Traditionally, field data collection has proven effective; however, it is costly and challenging to scale up. In this context, the use of drones equipped with RGB and LiDAR sensors emerges as a promising alternative for enabling large-scale monitoring. This study aimed to evaluate the accuracy of the products generated by RPAS equipped with RGB and LiDAR sensors in a forest restoration area. To achieve this, 90 control points were established in the study area, with their coordinates obtained through surveys using dual-frequency GNSS, total station, and geometric levelling. The collected RGB data were processed to generate orthomosaics and digital elevation models under various scenarios, considering the incorporation of anywhere from zero to 60 control points. Meanwhile, the LiDAR point clouds were generated and classified to create canopy height models. The results indicated that the number of control points directly influences the accuracy of the RGB products, with the best performance achieved using 15 points, ensuring high accuracy in both planimetric and altimetric components. However, including an excessive number of points (over 50) led to model saturation (overfitting), reducing accuracy in certain areas. For LiDAR products, planimetric analysis revealed that data processed without RTK base correction exhibited an average offset of 60 cm compared to corrected data. Moreover, the evaluation of geometric distances between reference points revealed slight deformations in the central region of the model, suggesting interference with spatial accuracy. Regarding the altimetric component, the results demonstrated that, in the context of this study, the evaluation of LiDAR positional quality cannot be considered absolute, as the specific combination of sensor and software employed may have introduced variability — particularly in the geotag corrections. Considering these methodological limitations, future research should refine data processing and validation to enable a more precise and robust re-evaluation of the positional quality of LiDAR products. Despite these restrictions, both RGB and LiDAR sensors have proven to be robust tools for collecting geospatial data in forested areas, and the integration of these technologies enhances the precision and efficiency of monitoring, significantly contributing to the development of forest restoration and environmental management strategies.

Keywords: Accuracy; Precision; GNSS; Aerial Photogrammetry; Ecological Restoration; Remote Sensing

6.1 Introdução

A restauração florestal vive um momento sem precedentes, impulsionada por compromissos globais como a Meta 2 do Quadro Global de Biodiversidade, a Década das Nações Unidas para a Restauração e o Desafio de Bonn (Almeida et al., 2024). Esses compromissos têm desafiado os métodos tradicionais de monitoramento, que, embora eficazes para medir estrutura e diversidade florestal *in loco*, são caros e de escalabilidade limitada (Nuijten et al., 2021; Sinegalia et al., 2023). Em vista disso, torna-se fundamental desenvolver abordagens acessíveis, adaptáveis e capazes de avaliar indicadores-chave – como biodiversidade, estoque de carbono e proteção do solo – em larga escala, considerando que os benefícios ambientais da restauração e as respostas dos ecossistemas podem ser não lineares, defasadas no tempo e variáveis espacialmente (Albuquerque et al., 2021; Romanelli et al., 2022; Almeida et al., 2024).

Nesse contexto, o uso de RPAS integrados a uma ampla variedade de sensores vem se destacando (Sinegalia et al., 2023). Sensores RGB, LiDAR, multiespectrais e hiperespectrais oferecem informações complementares sobre os ecossistemas, possibilitando a geração de mapas, ortoimagens, nuvens de pontos e modelos digitais de superfície ou terreno com alto nível de precisão (Berra & Peppia, 2020; Kahraman & Bacher, 2021; Sinegalia et al., 2023). Em particular, os RPAS equipados com câmeras RGB se mostram como uma alternativa promissora devido ao baixo custo e ao excelente equilíbrio entre resolução e escala, enquanto o LiDAR, apesar dos custos elevados, permite a modelagem precisa de atributos estruturais florestais – como a altura das árvores e a biomassa –, por captar tanto o solo quanto os elementos do dossel e gerar produtos como DTMs, DSMs e CHMs (Corte et al., 2020; d'Oliveira, 2021; Jaafar et al., 2018).

A qualidade dos dados obtidos por aerofotogrametria depende fortemente da resolução espacial (GSD – Ground Sampling Distance) e de fatores como altura e trajetória do voo, condições de iluminação, sobreposição de imagens, calibragem das câmeras e software utilizado (Szypuła, 2023; Singh et al., 2023). O avanço da abordagem Structure from Motion (SfM) tem permitido a geração de DSMs de alta resolução a partir de fotografias sobrepostas, aproximando os resultados dos modelos obtidos com LiDAR, especialmente em áreas de topografia variada (Fonstad et al., 2013; Turner et al., 2015; Maesano et al., 2014; Niethammer et al., 2011; Ota et al., 2015).

Visando aumentar a precisão dos modelos, métodos comumente utilizados para aumentar a precisão incluem o uso de pontos de controle (Arévalo-Verjel et al., 2022). Esses pontos, estrategicamente distribuídos e facilmente identificados nas imagens, permitem a orientação absoluta dos produtos cartográficos, reduzindo erros planimétricos e altimétricos (Singh et al., 2023; Ocalan et al., 2022; Arévalo-Verjel et al., 2022). A quantidade e a distribuição dos GCPs influenciam diretamente a acurácia do modelo, o que é essencial para intervenções de restauração florestal em pequena escala ou para o acompanhamento das mudanças ao longo do tempo (Cisneros et al., 2019; Casella et al., 2020; Swinfield et al., 2019). Além disso, o Sistema Global de Navegação por Satélite (GNSS) tem revolucionado os levantamentos geodésicos, proporcionando posicionamento rápido, preciso e econômico, embora os sinais possam sofrer interferências atmosféricas que afetam principalmente a precisão altimétrica (Mendonça, 2013; Pourreza et al., 2022; Swinfield et al., 2019).

O LiDAR também se destaca na detecção e no delineamento individual das copas das árvores (ITC), sendo amplamente utilizado para estimar a biomassa acima do solo, identificar espécies e analisar clareiras (Jaafar et al., 2018; Garcia et al., 2017). Diversos algoritmos – que vão desde a subtração do DSM pelo DTM até métodos baseados em grade, triangulação irregular, filtragem morfológica e segmentação por objetos – podem ser empregados para gerar o CHM, cada um com suas vantagens e limitações (Li et al., 2012; Jaafar et al., 2018; Meng et al., 2018; Vahid et al., 2021).

Impulsionados pela necessidade de uma compreensão mais precisa dos ecossistemas em recuperação, avanços recentes têm demonstrado o potencial de combinar produtos gerados por sensores RGB e LiDAR para estimar a composição e a diversidade funcional das florestas (Sankey et al., 2017; Sinegalia et al., 2023).

A integração desses sensores oferece uma abordagem robusta para a análise dos ecossistemas florestais. Os sensores RGB capturam imagens de alta resolução, fornecendo detalhes visuais essenciais para a identificação de espécies e características do dossel, enquanto o LiDAR gera dados tridimensionais precisos sobre a estrutura da vegetação, como a altura das árvores, a densidade do dossel e a topografia do solo (Scholl et al. 2021; Silva et al. 2022). Essa sinergia possibilita uma avaliação abrangente, não apenas da composição e da diversidade funcional das florestas, mas também da estimativa dos estoques de carbono e do monitoramento das mudanças na cobertura vegetal ao longo do tempo (Sinegalia et al, 2023).

A precisão dos dados obtidos por esses sensores é crucial para o monitoramento de áreas em restauração florestal, onde decisões de manejo e intervenções dependem diretamente de informações exatas, uma vez que dados imprecisos podem levar a interpretações equivocadas

sobre o progresso da restauração, impactando negativamente a alocação de recursos e a eficácia das estratégias implementadas (Juan-Ovejero, 2023; Alonzo et al. 2018; Scholl et al. 2021). Dessa forma, a alta precisão dos sensores garante que parâmetros essenciais – como biomassa, estrutura do dossel e cobertura do solo – reflitam fielmente a realidade do ecossistema, permitindo um monitoramento confiável e a adoção de medidas corretivas quando necessário (Alonzo et al. 2018; Scholl et al. 2021).

Neste estudo, foram estabelecidos 90 pontos de controle em uma área de restauração florestal, com coordenadas obtidas tanto por levantamento topográfico quanto geodésico. Em seguida, voos com drones equipados com sensores RGB e LiDAR foram realizados, e os dados foram processados utilizando softwares freemium. À partir das imagens RGB foram gerados ortomosaicos, DTMs e DSMs, criando cenários à partir da inclusão dos pontos de controle. Para os produtos LiDAR, as nuvens de pontos foram classificadas e os CHMs foram gerados. A análise de acurácia envolveu, inicialmente, a conversão das coordenadas geodésicas para o sistema UTM, comparando-as com coordenadas homologadas obtidas à partir do tratamento estatístico dos dados advindos de topografia clássica e geodésia. Também foram avaliadas as distâncias geométricas do LiDAR para identificar deslocamentos e deformações nos produtos gerados.

Espera-se que os resultados obtidos neste estudo desempenhem um papel fundamental no aprimoramento das estratégias de monitoramento florestal, contribuindo para a obtenção de dados mais detalhados e precisos sobre a estrutura e dinâmica das florestas em recuperação. Além disso, esses resultados poderão contribuir para uma avaliação mais acurada do estoque de carbono, o que é essencial para o desenvolvimento de políticas públicas e privadas voltadas à mitigação das mudanças climáticas. Ao fornecer informações valiosas sobre o comportamento e a saúde dos ecossistemas em restauração, essa pesquisa contribuirá diretamente para otimizar os esforços de restauração e conservação ambiental, fortalecendo iniciativas que buscam promover a recuperação de áreas degradadas e o equilíbrio ecológico.

6.2 Metodologia

6.2.1 Área de estudo

A coleta de dados foi realizada em uma área de restauração florestal vinculada ao Laboratório de Silvicultura e Pesquisas Florestais (LaSPEF), situada no Centro de Ciências Agronômicas da UFSCar, no município de Araras, localizada no interior do estado de São Paulo.

A área de estudo está inserida no campus Araras da UFSCar, localizado na zona rural do município e abrangendo aproximadamente 220 hectares. Nesse espaço, são conduzidas atividades de ensino, pesquisa e extensão voltadas às ciências agrárias e ambientais. A infraestrutura do campus inclui laboratórios especializados, áreas experimentais, viveiros, estufas e uma extensa reserva florestal, que proporciona suporte para estudos em conservação ambiental e sustentabilidade.

A área de restauração florestal possui 4,6 hectares e seu plantio foi realizado em março de 2021, e as espécies utilizadas em tal processo são nativas da Mata Atlântica, bioma predominante na região. No total, foram plantadas 24 espécies, organizadas em quatro blocos distintos, todos com a mesma idade de plantio.

Situado nas coordenadas geográficas centrais 22°21'23" S e 47°23'03" W, o campus Araras da UFSCar desempenha um papel estratégico no avanço científico e tecnológico da região, contribuindo significativamente para o desenvolvimento de pesquisas e projetos voltados à sustentabilidade e conservação ambiental. A figura 15 apresenta a área de estudo.

Figura 15: Área de estudo localizada na UFSCAR – campus Araras.



Fonte: CePe-Geo.

6.2.2 Metodologia

6.2.2.1 Delineamento Geral

Inicialmente foram implantados 90 pontos de controle na área, sendo 60 horizontais e 30 verticais, onde as coordenadas desses pontos foram obtidas por meio de levantamentos utilizando estação total e nível, além de levantamentos geodésicos com receptores GNSS. Os dados foram processados com softwares comerciais específicos,

Posteriormente executou-se os vôos com RPAs embarcados com sensores RGB e LiDAR, onde, à partir das imagens advindas do sensor RGB, foram gerados ortomosaicos, DTMs e DSMs em 14 cenários diferentes, variando de acordo com a inserção dos pontos de controle no processamento.

A acurácia dos modelos foi avaliada utilizando o erro médio quadrático e a raiz do RMSE para precisão, e o Erro Médio para identificar a tendência dos modelos, com ajustes via mínimos quadrados e validação estatística dos dados.

Para os produtos LiDAR, as nuvens de pontos foram classificadas e os CHMs gerados, incorporando os 30 pontos de controle verticais, e as coordenadas geodésicas convertidas para o sistema UTM foram comparadas com as homologadas, considerando deslocamentos e possíveis distorções.

O estudo também examinou a influência do número e do tipo de pontos de controle no pré e pós-processamento, bem como a acurácia posicional dos próprios pontos, utilizando exclusivamente ferramentas livres dos softwares comerciais empregados.

6.2.2.2 Pontos de Controle

Implantação e levantamento

Foram implantados 90 pontos de controle na área, entre eles 60 pontos de controle horizontal (GCPs), e 30 pontos de controle vertical, divididos em: 15 pontos de controle vertical (VCPs) materializados através de mourões de madeira de 1, 2 e 3 metros, com a quantidade de 5 VCPs por altura. Todos os mourões continham objetos com superfícies planas instaladas nos topos dos mesmos, visando simular a densidade de copas de indivíduos arbóreos.; e 15 árvores de controle (TCPs), com alturas entre 0,9 e 4,9 metros. Os pontos de controle verticais foram concebidos visando avaliar as alturas fornecidas através do processamento dos dados LiDAR para estes.

A figura 16 apresenta um GCP implantado na área de estudo, e as figuras 17 e 18 apresentam o projeto concebido para os VCPs, e a imagem de um VCP implantados na área de estudo, respectivamente

Figura 16: GCP materializado na área de estudo.



Figura 17: Projeto técnico de concepção dos VCPs.




Figura 18: VCP materializado na área de estudo.



As coordenadas de todos os pontos de controle foram obtidas por meio de levantamentos topográficos, utilizando estação total da marca Topcon GTS-239W e o método poligonação, nos levantamentos planialtimétricos, e um nível da marca Geotech, modelo DSZ3-A32X, acompanhado de uma mira graduada de alumínio de 4 metros de altura, para os levantamentos altimétricos de precisão, utilizando o método Nivelamento Geométrico Composto com contranivelamento. Após, as alturas das árvores (TCPs e VCPs) foram medidas geometricamente (com mira e estação total) e, além dos métodos já mencionados, os TCPs também foram medidos por meio de clinômetro e vertex.

Os levantamentos geodésicos foram executados utilizando receptores GNSS de dupla frequência, da marca Spectra Geospatial, modelo Spectra SP60, tanto nas metodologias absoluta quanto relativa, onde, para esta última, o método adotado foi Relativo Estático-Rápido, também denominado *Stop-and-Go (SAG)*, onde o receptor base foi instalado no ponto denominado E0 e manteve rastreo durante todos os períodos de levantamento, e o vértice rover ocupou o primeiro vértice de cada etapa por 20 minutos, e, posteriormente, sem que o equipamento fosse desligados, os demais vértices foram ocupados por 5 minutos.

Vale ressaltar que as posições dos pontos de controle foram escolhidas de modo a possibilitarem visibilidade nos produtos oriundos das etapas de levantamento remoto.

Processamento e ajustamento dos pontos de controle

Todos os pontos de controle foram processados considerando a metodologia Poligonação, com coordenadas corrigidas e ajustadas via software topográfico Topcon Link v. 8.2.3, quanto utilizando planilhas de excel para a planialmetria.

Para a altimetria utilizando nivelamento geométrico composto com contranivelamento, as leituras advindas do levantamento por nível foram alocadas em planilha de excel e a obtenção das altitudes foi realizada através do método dos desníveis.

Os dados GNSS foram processados através do software online PPP do IBGE, no que diz respeito à metodologia absoluta, considerando os arquivos individuais para cada vértice ocupado com o rover, e no software Survey Office v. 8.2.3, no que diz respeito à metodologia relativa SAG, onde inicialmente processou-se os dados advindos do receptor considerado base utilizando as estações RBMC de Cananéia, Campinas e Sorocaba. Posteriormente, utilizou-se as coordenadas ajustadas da base para o processamento dos dados oriundos do receptor rover.

Posteriormente todos os dados foram tabulados e ajustados utilizando o método dos mínimos quadrados, injuncionando linhas de base e validados através do Teste Tau, fornecendo coordenadas homologadas para todos os pontos de controle.

6.2.2.3 RGB

Aquisição dos dados

Os voos para a obtenção das imagens RGB foram realizados com o drone DJI Mavic 2 Pro, seguindo um planejamento criterioso para garantir a qualidade dos dados adquiridos. A missão foi executada com uma sobreposição geral (overlap) de 80%, incluindo um overlap específico para rodovias (Overlap for Road) também de 80%.

A aeronave manteve uma velocidade de 7 m/s e uma altitude de voo fixa de 120 metros acima do solo, com o recurso Terrain Follow desativado, assegurando uniformidade na captação das imagens. Essas configurações foram adotadas visando otimizar a resolução espacial, minimizar distorções geométricas e garantir a obtenção de um ortomosaico de alta precisão.

Processamentos dos dados

As imagens RGB foram processadas utilizando o software Agisoft Metashape, versão 1.8.1. O processamento foi realizado em 14 cenários distintos, com o objetivo de comparar o alinhamento dos produtos gerados, considerando diferentes números de GCPs, a saber: 0, 4, 6, 10, 15, 20, 25, 30, 35, 40, 45, 50, 55 e 60.

Em todos os casos, as seguintes etapas de processamento dos dados foram realizadas:

1. As imagens foram alinhadas para a geração da nuvem esparsa de pontos;
2. Foi efetuada a construção da nuvem densa de pontos;
3. O ortomosaico foi gerado.

Todos os processamentos foram executados em uma estação de trabalho de alta performance (128 GB de RAM e 16 GB de VRAM). Assim, configuramos todas as etapas de processamento para qualidade alta (do inglês, “high”), definindo também os valores dos pontos de referência (denominados em inglês de “key points”) e dos pontos de amarração (denominados em inglês de “tie points”) na etapa 1 para 60.000 e 40.000, respectivamente.

A partir da etapa 2, iniciou-se a diferença nos processamentos devido aos cenários propostos, uma vez que as imagens do voo precisavam ser “amarradas” aos GCPs. Assim, cada cenário teve um número diferente de GCPs, começando com 0 (sem GCPs) até 60 GCPs.

A amarração das imagens do voo aos GCPs foi realizada manualmente dentro do software, onde os pontos foram importados no projeto e corretamente alocados nas cenas em que apareciam. Neste estudo, cada GCP foi amarrado a no mínimo 5 imagens, a fim de garantir o melhor ajuste possível.

Após a amarração das imagens, o processamento continuou para a geração do ortomosaico na etapa 3. Com o ortomosaico gerado em todos os cenários, foi realizada a

vetorização manual do centro de cada um dos GCPs e VCPs na área de estudo. Em seguida, foram extraídas as coordenadas de cada um desses pontos nos 14 cenários, sendo comparadas com as coordenadas homologadas em planilhas utilizando o software Excel

É importante ressaltar que, para os VCPs, o ponto considerado foi aquele em que o "caibro de madeira" toca o solo, pois as coordenadas reais foram medidas a partir do nível do caibro.

Para a obtenção da coordenada altimétrica, foi gerado o MDS e extraído o valor do pixel correspondente. Como o MDS é utilizado para gerar os ortomosaicos dos cenários e estes foram empregados para posicionar cada ponto em seu respectivo alvo, o MDS está alinhado com o ortomosaico.

Os pontos utilizados como controle podem ser visualizados na figura 19, No anexo 1, consta uma tabela com os pontos de controle inseridos em cada cenário.

Figura 19: Pontos de controle espacialmente distribuídos na área de estudo.



Análise da acurácia

As coordenadas geodésicas foram convertidas para o sistema UTM e divididas em observações E (este) e N (norte), obtidas em cada cenário. Essas coordenadas foram então tabeladas e comparadas com as coordenadas homologadas, consideradas “verdadeiras”, com o objetivo de realizar a análise da acurácia dos dados.

Posteriormente, procedeu-se ao tratamento e à análise estatística dessas coordenadas para determinar as acurácias tanto nos componentes planimétricos (E e N, isoladamente, e posterior ajustamento para componente planimétrico, através do MMQ), quanto no componente altimétrico (Z).

Para a análise da acurácia utilizou-se o erro médio quadrático (RMSE, do inglês Root Mean Square Error) de cada ponto e a raiz do RMSE para avaliar a precisão do modelo, e o Erro Médio (ME, do inglês “Mean Error”) para avaliar a tendência do mesmo. Posteriormente procedeu-se o ajustamento dos dados por MMQ com injunções, gerando um polígono para cada cenário. Os polígonos foram avaliados à partir da área, perímetro, deslocamento e posição dos pontos de controle (externos, ou internos, considerando o polígono formado).

6.2.2.4 LiDAR

Aquisição dos dados

No que diz respeito a coleta dos dados LiDAR, utilizou-se o sensor Zenmuse L1, embarcado no drone Matrice 300 RTK. Durante o voo, a densidade de pontos registrada foi de aproximadamente 236 pontos por metro quadrado (ptos/m²), proporcionando um detalhamento expressivo da superfície mapeada.

O modelo gerado apresentou um GSD de 1,64 cm, garantindo uma resolução refinada dos produtos finais. Além disso, a sobreposição das passagens do sensor foi configurada para 75%, aumentando a redundância dos dados e aprimorando a precisão das representações tridimensionais.

Processamentos dos dados

Os dados das nuvens de pontos foram reconstruídos utilizando o software DJI Terra (v. 4.4.0), versão gratuita, em dois cenários: sem a utilização da base RTK e com o pós-processamento da base RTK. É importante ressaltar que, no momento da reconstrução para o cenário com pós-processamento da base RTK, as coordenadas do local (GCP19), onde o receptor GNSS D-RTK2 estava posicionado, foram informadas ao software.

Após a reconstrução, as nuvens de pontos foram processadas no software R, utilizando o pacote lidR. Através desse pacote, a nuvem foi classificada, possibilitando a distinção entre os pontos de chão e os demais pontos. Posteriormente, foram realizados a remoção dos ruídos e a normalização da nuvem. Por fim, foram gerados os CHMs (Modelos de Altura de Canais) em resoluções de 20 cm, 50 cm, 1 m, 15 m e 30 m.

Para identificar os valores de altura dos VCPs e TCPs, os CHMs gerados foram abertos no software QGIS, o que possibilitou a comparação dos ortomosaicos RGB com os CHMs. Isso permitiu verificar se o arquivo vetorial que representava os pontos de posição dos VCPs e TCPs estava correto.


Assim, cada um dos pontos vetoriais representando os VCPs e TCPs foi ajustado manualmente, com base na comparação entre o CHM e o ortomosaico RGB, para garantir o melhor alinhamento. O objetivo era ajustar os pontos para o topo dos VCPs e TCPs.

Os CHMs utilizados para extrair as informações de altura dos VCPs e TCPs foram aqueles com melhor representação de detalhes, ou seja, aqueles que apresentaram maior nível de detalhamento. Esses CHMs tinham resoluções de 20 cm e 50 cm. Para cada ponto, foi gerado um buffer de 50 cm de diâmetro, e esse buffer foi utilizado para extrair as informações de altura por meio da ferramenta “Estatísticas Zonais”.

Após o ajuste dos pontos com o CHM, foram extraídas métricas de cada um dos VCPs e TCPs (contagem de pixels, valor mínimo, valor máximo, média e mediana), que foram posteriormente comparadas com as medidas homologadas.

Com o intuito de comparar o deslocamento das nuvens de pontos LiDAR no componente planimétrico, foram criados sete Pontos de Referência (PR, do inglês "Reference Points") distribuídos pela área e alocados em regiões com maior visibilidade, como as copas de árvores com valores de altura mais elevados (Figura 20).

Figura 20: Pontos de referência no CHM gerado utilizando RTK com pós-processamento.



Fonte: CePe-Geo.

A figura 21 demonstra a distribuição espacial dos RPs obtidos através do CHM utilizando RTK com pós-processamento, distribuídos espacialmente na área de estudo.

Figura 21: RPs distribuídos espacialmente na área de estudo.



Vale salientar que os sete RP foram criados duas vezes, um para cada cenário, e as coordenadas de todos os RP gerados em ambos cenários foram extraídas, bem como as distâncias geométricas entre eles em cada cenário.

Análise da acurácia

As coordenadas N e E dos RPs foram tabeladas e organizadas para ambos os cenários, onde efetuamos um comparativo entre as coordenadas de cada RP para cada cenário, possibilitando identificar o deslocamento que o mesmo ponto teve.

Para a análise da acurácia utilizou-se o erro médio quadrático (RMSE, do inglês Root Mean Square Error) considerando o deslocamento em cada RP e a raiz do RMSE para avaliar a precisão do modelo, e o Erro Médio (ME, do inglês “Mean Error”) para avaliar a tendência do mesmo. Posteriormente procedeu-se o ajustamento dos dados por MMQ com injunções, gerando 2 polígonos, um utilizando os vértices advindos do LiDA sem a correção da base RTK e o outro, considerado como referência, utilizando a base RTK. Os polígonos foram avaliados à partir do deslocamento do polígono geral, bem como à partir das distâncias geométricas entre cada ponto, entre RP1 e RP2, RP1 e RP3, etc.), no intuito de avaliar se houve deformação no centro do produto.

Para a avaliação do componente altimétrico, as métricas estatísticas extraídas do buffer em ambos os cenários foram tabeladas de acordo com as alturas dos VCPs (1, 2 e 3 metros) e

intervalos de alturas dos TCPs (Menor que 1 metro; Entre 1 e 2 metros; Entre 2 e 3 metros; Entre 3 e 4 metros; e Entre 4 e 5 metros) e também procedeu-se à análise estatística desses dados.

6.3 Resultados

Todos os dados de processamentos, relatórios e tabelas constam do repositório que pode ser obtido no link a seguir:

https://drive.google.com/drive/folders/1eYjddTncne8xGCzzeLI5QvZ4BmzadTUX?usp=drive_link

6.3.1 Pontos de Controle

A tabela 17 apresenta as coordenadas homologadas após o tratamento estatístico, de todos os pontos de controle.

Tabela 17: Coordenadas homologadas dos pontos de controle.

ID	E	N	Z
0016AA	254084,596	7530907,953	674,705
0016BA	254095,337	7530948,9	672,167
0016CA	254120,205	7530942,288	672,665
E0	254183,088	7530950,996	671,665
E10	254055,115	7530995,501	669,01
E11	254006,129	7530999,297	668,814
E12	254000,37	7530962,129	670,7
E13	253970,366	7530987,035	668,682
E14	253962,775	7530950,488	670,186
E15	253948,726	7530913,024	672,265
E16	253911,118	7530935,887	670,067
E1	254168,141	7530938,483	672,572
E2	254169,298	7530911,179	674,095
E3	254156,172	7530910,805	674,333
E4	254146,714	7530909,645	674,553
E5	254128,789	7530907,466	674,762
E5-1	254130,354	7530907,604	674,803
E7	254087,393	7530969,967	671,001
E8	254081,141	7530988,275	669,515
E9	254058,487	7531006,497	668,255
G16	254007,228	7530913,037	673,648
G17	254160,602	7531024,804	667,554
G18	254159,476	7531019,038	667,891
G19	254159,937	7531052,279	666,218

G20	254129,293	7531048,117	666,528
G21	254103,951	7531042,314	666,942
G22	254094,955	7531035,439	667,265
G23	254083,565	7531019,774	668,024
G24	254051,303	7531017,972	668,153
G25	254023,313	7531011,168	668,589
G26	253984,748	7531005,156	668,279
G27	254033,51	7530980,078	670,879
G28	253988,678	7530971,071	669,876
G29	253945,666	7530997,08	667,826
G30	253911,025	7530964,998	668,386
G31	253875,417	7530955,614	667,974
G32	253892,481	7530984	666,644
G33	253858,085	7530961,132	667,074
G34	253890,013	7530917,417	670,555
G35	253876,647	7530898,163	671,312
G36	253881,711	7530871,292	672,944
G37	253836,399	7530886,119	671,073
G38	253833,875	7530902,934	670,12
G39	253827,97	7530938,75	667,663
G40	253821,795	7530963,578	665,995
G41	253838,261	7530873,027	671,739
G42	253838,882	7530860,541	672,45
G43	253842,459	7530834,666	673,759
G44	253868,318	7530853,761	673,51
G45	253917,764	7530868,667	674,116
G46	253951,321	7530885,909	673,799
G47	253962,808	7530882,732	674,38
G48	254007,027	7530896,505	674,512
G49	254028,87	7530934,159	672,309
G50	254038,25	7530904,192	674,151
G51	254114,472	7530939,236	674,095
G52	254156,448	7530944,605	671,56
G53	254159,625	7530919,072	672,069
G54	254165,215	7530970,376	670,908
G55	254162,812	7530974,69	671,292
G56	254164,791	7530980,162	669,9
G57	254124,98	7530961,389	671,518
G58	254126,839	7530979,995	670,829
G59	254135,83	7531016,546	668,177
G60	254117,862	7530998,223	669,284
G61	254061,062	7530956,336	671,152
G62	254026,471	7530954,892	671,173
P6	254104,935	7530912,346	674,502

P9	254084,41	7531004,876	668,369
T1	254164,206	7530940,601	672,339
T10	254082,708	7530987,347	669,562
T11	254004,069	7530976,935	669,923
T12	253975,511	7530956,424	670,348
T13	253961,797	7530965,196	669,448
T14	253947,284	7530945,07	670,105
T15	253972,544	7530937,421	671,165
T2	253855,79	7530861,151	672,692
T3	253906,505	7530874,524	673,428
T4	254127,149	7530936,067	673,371
T5	254146,08	7530945,127	672,279
T6	254141,093	7530992,485	669,549
T7	254140,168	7531005,034	668,735
T8	254117,762	7530981,73	670,811
T9	254123,936	7530984,886	670,063
V1	254155,031	7530928,945	673,246
V10	253944,552	7530977,314	668,572
V12	253869,062	7530970,869	666,517
V13	253864,114	7530885,82	671,238
V14	254041,143	7530906,202	674,288
V15	254142,475	7531047,627	666,304
V2	254126,072	7530922,043	673,957
V3	254092,938	7530957,008	671,661
V4	254059,61	7530987,589	669,505
V6	254030,444	7531015,286	667,943
V7	254014,699	7530988,165	668,969
V8	254004,94	7530928,619	672,612
V9	253977,74	7531007,727	667,612

6.3.2 RGB

6.3.2.1 Ortomosaico e MDT


A figura 22 a seguir apresenta o ortomosaico gerado para o cenário com a inserção de 4 GCPs.

Figura 22: Ortomosaico para o cenário com 4 GCPs.



A figura 23 a seguir apresenta o MDT para o cenário de 4 GCPs.

Figura 23: DTM para o cenário com 4 GCPs.



6.3.2.2 Tratamento Estatístico

ME e RMSE

A tabela 18 a seguir foi organizada por cenário apresentando a coordenada E, bem como o erro médio quadrático de cada ponto, bem como de cada modelo, apresentando as diferenças

entre as coordenadas homologadas e as calculadas, e o ME e o RMSE (últimas linhas da tabela) para os cenários “SEM GCPs” e “com 4 GCPs”.

Tabela 18: Coordenadas homologadas, e nos cenários sem GCPs e com 4 GCPs, além do ME e RMSE dos mesmos.

Homologada		sem GCPs			4 GCPs		
ID	E	E	ME	RMSE	E	ME	RMSE
0016AA	254084,596	254086,688	-2,09	4,376	254084,557	0,039	0,001521
0016BA	254095,337	254097,637	-2,3	5,29	254095,372	-0,035	0,001225
0016CA	254120,205	254122,972	-2,77	7,656	254120,243	-0,038	0,001444
E0	254183,088	254187,266	-4,18	17,46	254183,389	-0,301	0,090601
E10	254055,115	254056,29	-1,18	1,381	254054,937	0,178	0,031684
E11	254006,129	254006,363	-0,23	0,055	254005,965	0,164	0,026896
E12	254000,37	254000,606	-0,24	0,056	254000,226	0,144	0,020736
E13	253970,366	253969,934	0,432	0,187	253970,218	0,148	0,021904
E14	253962,775	253962,358	0,417	0,174	253962,669	0,106	0,011236
E15	253948,726	253948,136	0,59	0,348	253948,621	0,105	0,011025
E16	253911,118	253909,692	1,426	2,033	253910,975	0,143	0,020449
E1-BASE	254168,141	254171,802	-3,66	13,4	254168,16	-0,019	0,000361
E2	254169,298	254172,983	-3,68	13,58	254169,261	0,037	0,001369
E3	254156,172	254159,59	-3,42	11,68	254156,132	0,04	0,0016
E4	254146,714	254149,958	-3,24	10,52	254146,666	0,048	0,002304
E5	254128,789	254131,712	-2,92	8,544	254128,743	0,046	0,002116
E5-1	254130,354	254132,485	-2,13	4,541	254130,354	0	0
E7	254087,393	254089,344	-1,95	3,806	254087,284	0,109	0,011881
E8	254081,141	254082,897	-1,76	3,084	254081,012	0,129	0,016641
E9	254058,487	254059,731	-1,24	1,548	254058,326	0,161	0,025921
G16	254007,228	254007,864	-0,64	0,404	254007,197	0,031	0,000961
G17	254160,602	254164,069	-3,47	12,02	254160,683	-0,081	0,006561
G18	254159,476	254162,913	-3,44	11,81	254159,554	-0,078	0,006084
G19	254159,937	254163,433	-3,5	12,22	254160,123	-0,186	0,034596
G20	254129,293	254132,177	-2,88	8,317	254129,454	-0,161	0,025921
G21	254103,951	254106,254	-2,3	5,304	254104,036	-0,085	0,007225
G22	254094,955	254097,116	-2,16	4,67	254095,076	-0,121	0,014641
G23	254083,565	254085,404	-1,84	3,382	254083,538	0,027	0,000729
G24	254051,303	254052,555	-1,25	1,568	254051,315	-0,012	0,000144
G25	254023,313	254023,998	-0,68	0,469	254023,294	0,019	0,000361
G26	253984,748	253984,615	0,133	0,018	253984,672	0,076	0,005776
G27	254033,51	254034,33	-0,82	0,672	254033,351	0,159	0,025281
G28	253988,678	253988,657	0,021	4E-04	253988,525	0,153	0,023409
G29	253945,666	253944,672	0,994	0,988	253945,496	0,17	0,0289
G30	253911,025	253909,605	1,42	2,016	253910,996	0,029	0,000841
G31	253875,417	253873,305	2,112	4,461	253875,365	0,052	0,002704

G32	253892,481	253890,377	2,104	4,427	253892,219	0,262	0,068644
G33	253858,085	253855,55	2,535	6,426	253857,99	0,095	0,009025
G34	253890,013	253888,331	1,682	2,829	253889,916	0,097	0,009409
G35	253876,647	253874,78	1,867	3,486	253876,559	0,088	0,007744
G36	253881,711	253880,061	1,65	2,723	253881,647	0,064	0,004096
G37	253836,399	253833,832	2,567	6,589	253836,301	0,098	0,009604
G38	253833,875	253831,189	2,686	7,215	253833,792	0,083	0,006889
G39	253827,97	253824,987	2,983	8,898	253827,874	0,096	0,009216
G40	253821,795	253818,536	3,259	10,62	253821,703	0,092	0,008464
G41	253838,261	253835,769	2,492	6,21	253838,182	0,079	0,006241
G42	253838,882	253836,492	2,39	5,712	253838,851	0,031	0,000961
G43	253842,459	253840,236	2,223	4,942	253842,405	0,054	0,002916
G44	253868,318	253866,459	1,859	3,456	253868,231	0,087	0,007569
G45	253917,764	253916,844	0,92	0,846	253917,725	0,039	0,001521
G46	253951,321	253950,992	0,329	0,108	253951,288	0,033	0,001089
G47	253962,808	253962,735	0,073	0,005	253962,794	0,014	0,000196
G48	254007,027	254007,764	-0,74	0,543	254007,049	-0,022	0,000484
G49	254028,87	254029,558	-0,69	0,473	254028,585	0,285	0,081225
G50	254038,25	254039,627	-1,38	1,896	254038,36	-0,11	0,0121
G51	254114,472	254116,603	-2,13	4,541	254114,472	0	0
G52	254156,448	254158,579	-2,13	4,541	254156,448	0	0
G53	254159,625	254161,756	-2,13	4,541	254159,625	0	0
G54	254165,215	254168,856	-3,64	13,26	254165,3	-0,085	0,007225
G55	254162,812	254166,37	-3,56	12,66	254162,903	-0,091	0,008281
G56	254164,791	254168,42	-3,63	13,17	254164,888	-0,097	0,009409
G57	254124,98	254127,862	-2,88	8,306	254125,072	-0,092	0,008464
G58	254126,839	254129,717	-2,88	8,283	254126,946	-0,107	0,011449
G59	254135,83	254138,849	-3,02	9,114	254135,947	-0,117	0,013689
G60	254117,862	254120,577	-2,71	7,371	254117,989	-0,127	0,016129
G61	254061,062	254062,504	-1,44	2,079	254060,928	0,134	0,017956
G62	254026,471	254027,247	-0,78	0,602	254026,352	0,119	0,014161
P6	254104,935	254107,381	-2,45	5,983	254104,87	0,065	0,004225
P9	254084,41	254086,139	-1,73	2,989	254084,234	0,176	0,030976
T1	254164,206	254166,337	-2,13	4,541	254164,206	0	0
T10	254082,708	254084,839	-2,13	4,541	254082,708	0	0
T11	254004,069	254006,2	-2,13	4,541	254004,069	0	0
T12	253975,511	253977,642	-2,13	4,541	253975,511	0	0
T13	253961,797	253963,928	-2,13	4,541	253961,797	0	0
T14	253947,284	253949,415	-2,13	4,541	253947,284	0	0
T15	253972,544	253974,454	-1,91	3,648	253972,323	0,221	0,048841
T2	253855,79	253857,921	-2,13	4,541	253855,79	0	0
T3	253906,505	253908,636	-2,13	4,541	253906,505	0	0
T4	254127,149	254129,28	-2,13	4,541	254127,149	0	0
T5	254146,08	254148,211	-2,13	4,541	254146,08	0	0

T6	254141,093	254143,224	-2,13	4,541	254141,093	0	0
T7	254140,168	254142,299	-2,13	4,541	254140,168	0	0
T8	254117,762	254119,893	-2,13	4,541	254117,762	0	0
T9	254123,936	254126,067	-2,13	4,541	254123,936	0	0
V1	254155,031	254158,401	-3,37	11,36	254155,091	-0,06	0,0036
V10	253944,552	253943,521	1,031	1,063	253944,298	0,254	0,064516
V12	253869,062	253866,709	2,353	5,537	253868,958	0,104	0,010816
V13	253864,114	253861,787	2,327	5,415	253863,75	0,364	0,132496
V14	254041,143	254042,418	-1,27	1,626	254041,075	0,068	0,004624
V15	254142,475	254145,482	-3,01	9,042	254142,49	-0,015	0,000225
V2	254126,072	254128,818	-2,75	7,541	254125,933	0,139	0,019321
V3	254092,938	254094,954	-2,02	4,064	254092,747	0,191	0,036481
V4	254059,61	254060,98	-1,37	1,877	254059,457	0,153	0,023409
V6	254030,444	254031,053	-0,61	0,371	254030,225	0,219	0,047961
V7	254014,699	254015,125	-0,43	0,181	254014,561	0,138	0,019044
V8	254004,94	254005,389	-0,45	0,202	254004,816	0,124	0,015376
V9	253977,74	253977,459	0,281	0,079	253977,663	0,077	0,005929
		<i>ME</i>	-1,0			0,05	
			<i>RMSE</i>	1,028			0,046

As tabelas 19, 20 e 21 a seguir, apresentam o resumo do ME e do RMSE para as coordenadas E,N e Z, respectivamente, encontrado em cada cenário.

Tabela 19: ME e RMSE obtidos em cada um dos cenários deste estudo para as coordenadas E.

CENÁRIO	ME	RMSE (m)
Sem pontos de controle	-1	1,028 m
4 pontos de controle	0,05	0,046
6 pontos de controle	0,02	0,110
10 pontos de controle	0,008	0,116
15 pontos de controle	-0,006	0,006
20 pontos de controle	0,01	0,011
25 pontos de controle	0,02	0,015
30 pontos de controle	0,009	0,103
35 pontos de controle	0,01	0,012
40 pontos de controle	0,01	0,011
45 pontos de controle	0,007	0,007
50 pontos de controle	0,006	0,006
55 pontos de controle	0,008	0,008
60 pontos de controle	0,02	0,101

Tabela 20: ME e RMSE obtidos em cada um dos cenários deste estudo para as coordenadas N.

CENÁRIO	ME	RMSE (m)
Sem pontos de controle	-0,5	0,533 m
4 pontos de controle	0,06	0,056
6 pontos de controle	0,01	0,165
10 pontos de controle	0,02	0,161
15 pontos de controle	-0,01	0,010
20 pontos de controle	0,007	0,007
25 pontos de controle	0,004	0,004
30 pontos de controle	-0,007	0,168
35 pontos de controle	-0,008	0,008
40 pontos de controle	-0,006	0,006
45 pontos de controle	0,003	0,003
50 pontos de controle	0,001	0,001
55 pontos de controle	0,001	0,001
60 pontos de controle	0,0002	0,162

Tabela 21: ME e RMSE obtidos em cada um dos cenários deste estudo para as coordenadas Z.

CENÁRIO	ME	RMSE (m)
Sem pontos de controle	-6	5,98 m
4 pontos de controle	0,07	0,072
6 pontos de controle	-0,057	0,472
10 pontos de controle	-0,163	0,491
15 pontos de controle	-0,114	0,114
20 pontos de controle	-0,117	0,117
25 pontos de controle	-0,12	0,122
30 pontos de controle	-0,1	0,453
35 pontos de controle	-0,06	0,055
40 pontos de controle	-0,08	0,077
45 pontos de controle	-0,08	0,077
50 pontos de controle	-0,09	0,089
55 pontos de controle	-0,09	0,093
60 pontos de controle	-0,1	0,474

As tabelas com todos os cenários de ME e RMSE constam do link disponibilizado para acesso do banco de dados deste trabalho.

Polígonos

As figuras 24 e 25 apresentam a diferença entre o polígono obtido das coordenadas homologadas para os polígonos para os cenários sem GCPs e com 4 GCPs, respectivamente.

Figura 24: Comparativo polígono coordenadas homologadas x cenário sem GCPs.





Figura 25: Comparativo polígono coordenadas homologadas x cenário com 4 GCPs.



6.3.2.3 Tabela de Acurácia

As tabelas 22 e 23 a seguir apresentam a tabela de acurácia esperada para os cenários analisados, nos componentes planimétricos e altimétricos, respectivamente.

Tabela 22: Tabela de Acurácia RGB, componente planimétrico.

Componente Planimétrico		
Cenário	Acurácia esperada	
	Polígono externo	Polígono interno
Sem pontos de controle	Entre 2,5 e 3 m	Entre 0,7 e 1,4 m
Entre 4 e 6 pontos de controle	Entre 14 e 18cm	22 cm
10 pontos de controle	Entre 18 e 22cm	17 cm
Entre 15 e 40, pontos de controle	Entre 18 e 22cm	15 cm
Entre 45 e 55 pontos de controle	Entre 17 e 21cm	14 cm

Tabela 23: Tabela de Acurácia RGB, componente altimétrico.


Componente Altimétrico	
Cenário	Acurácia esperada
Sem pontos de controle	6 m
Entre 4 e 6 pontos de controle	17 cm
10 pontos de controle	50 cm
Entre 15 e 30 pontos de controle	20 cm
Entre 35 e 45 pontos de controle	18 cm
Entre 50 e 55 pontos de controle	22 cm

6.3.3 LiDAR

6.3.3.1 Nuvem de Pontos e CHM


A figura 26 apresenta as nuvens de pontos obtidas para o cenário com pós-processamento.

Figura 26: Nuvem de pontos obtida à partir de dados LiDAR com pós-processamento.



A figura 27 apresenta o CHM de 20 cm gerado neste trabalho.

Figura 27: CHM de 20 cm obtido à partir de dados LiDAR.



6.3.3.3 Tratamento Estatístico

ME e RMSE

No que diz respeito ao componente planimétrico, foram organizadas tabelas comparativas entre as coordenadas E e N para cada um dos cenários, conforme tabelas 24 e 25 apresentadas a seguir.

Tabela 24: Métricas estatísticas obtidas em cada um dos cenários deste estudo para as coordenadas E.

Coordenada E				
id	<i>com RTK pós-processado</i>	<i>sem RTK</i>	<i>ME</i>	<i>RSME</i>
1	254174,19966396	254173,39573993	0,80392403	0,646293846
2	254198,13738711	254197,52111868	0,61626843	0,379786778
3	254043,17070860	254042,50815803	0,66255057	0,438973258
4	254009,20520882	254008,53237630	0,67283252	0,4527036
5	253969,37530092	253968,60602616	0,76927476	0,591783656
6	253857,30180557	253856,61945566	0,68234991	0,4656014
7	253890,37478120	253889,95678848	0,41799272	0,174717914
		<i>ME</i>	<i>0,660741849</i>	
			<i>RMSE</i>	<i>0,660741849</i>

Tabela 25: Métricas estatísticas obtidas em cada um dos cenários deste estudo para as coordenadas E.

Coordenada N				
id	<i>com RTK pós-processado</i>	<i>sem RTK</i>	<i>ME</i>	<i>RMSE</i>
1	7530988,20834957	7530989,16726586	-0,95891629	0,9195205
2	7531046,67733000	7531047,35656332	0,67923332	0,4613579
3	7531026,11422985	7531027,54335119	1,42912134	2,0423878
4	7530985,45461855	7530986,27599772	0,82137917	0,6746637
5	7530933,16242500	7530934,30817012	1,14574512	1,3127319
6	7530913,78609953	7530914,63539529	0,84929576	0,7213033
7	7530988,78326945	7530989,63576901	0,85249956	0,7267555
		<i>ME</i>	<i>0,688336854</i>	
			<i>RMSE</i>	<i>0,688336854</i>

Visando avaliar se há deformação quando não utilizamos a base RTK, foram obtidas as distâncias entre cada um dos RPs, conforme tabela 26 a seguir.

Tabela 26: Distâncias geométricas entre os RPs para ambos os cenários.

Pontos	Dist com RTK	Dist sem RTK	Diferença
1-2	63,179	62,992	0,187
1-3	136,402	136,398	0,004
1-4	165,017	164,889	0,128
1-5	212,092	212,01	0,082
1-6	325,519	325,426	0,093
1-7	283,825	283,439	0,386
2-3	156,325	156,274	0,051
2-4	198,604	198,614	-0,01
2-5	255,378	255,308	0,07
2-6	365,826	365,826	0
2-7	313,161	312,934	0,227
3-4	52,98	53,454	-0,474
3-5	118,684	118,972	-0,288
3-6	217,175	217,492	-0,317
3-7	157,29	157,191	0,099
4-5	65,734	65,534	0,2
4-6	167,961	167,958	0,003
4-7	118,877	118,623	0,254
5-6	113,736	113,701	0,035
5-7	96,617	96,161	0,456
6-7	81,966	82,076	-0,11

No que diz respeito ao componente altimétrico, foram organizadas tabelas comparativas com as alturas dos VCPs e TCPs, em ambos os cenários, e foram criadas tabelas comparativas com as alturas dos VCPs homologadas, e as obtidas através dos CHMs de 20 e 50 cm. Para os TCPs, além das mencionadas, também foram introduzidas as medidas obtidas em campo para os mesmo através de clinômetro e vertex.

As alturas encontradas podem ser visualizadas nas tabelas 27, 28 e 29.

Tabela 27: Alturas dos VCPs de 1 m medidas geometricamente e através dos CHM.

VCP 1m	Campo	CHM20	CHM50
VCP1	0,891	0	0
VCP2	0,875	0	0
VCP8	0,906	0	n
VCP10	0,912	0,823	n
VCP11	0,883	0,2175	0,87

Tabela 28: Alturas dos VCPs de 2 m medidas geometricamente e através dos CHM.

VCP 2m	Campo	CHM20	CHM50
VCP4	1,792	1,622	2,216
VCP6	1,763	0,87125	n
VCP12	1,785	1,3665	2,135
VCP13	1,803	1,18125	2,974
VCP15	1,946	1,3652	2,481

Tabela 29: Alturas dos VCPs de 3 m medidas geometricamente e através dos CHM.

VCP 3m	Campo	CHM20	CHM50
VCP3	2,93	0	0
VCP5	2,73	2,27875	3,207
VCP7	2,674	2,3616	3,741
VCP9	2,661	1,9425	2,989
VCP14	2,69	0	0

A tabela 30 a seguir apresenta as medidas nos TCPs obtidas geometricamente, por clinômetro, vertéx e pelos CHM.


Tabela 30: Alturas dos TCPs obtidas geometricamente, por clinômetro, vertéx e pelos CHM.

						CHM20		CHM50	
TCPs	Homologada	CHM20	CHM50	Clin	Vert	EM	RSME	EM	RSME
TCP1	2,083	0	0	2,1	2	2,083	4,338889	2,083	4,338889
TCP2	3,19	1,69725	0,67	3,2	3,2	1,49275	2,2283024	2,52	6,3503999
TCP3	0,904	1,69725	0,67	0,9	0,8	-0,79325	0,6292456	0,234	0,054756
TCP4	4,199	2,34975	3,5680001	4,3	4,2	1,84925	3,4197256	0,6309999	0,3981609
TCP5	2,19	1,99275	2,1300001	2,2	2,3	0,19725	0,0389076	0,0599999	0,0036
TCP6	4,893	3,5679999	4,3179998	5	5	1,3250001	1,7556252	0,5750002	0,3306252
TCP7	2,25	1,3678	2,0539999	2,4	2,2	0,8822	0,7782768	0,1960001	0,038416
TCP8	2,399	1,5491667	1,65	2,6	2,3	0,8498333	0,7222167	0,749	0,561001
TCP9	1,945	0	0	2	2,1	1,945	3,783025	1,945	3,783025
TCP10	2,366	1,463	1,545	2,5	2,4	0,903	0,815409	0,821	0,6740411
TCP11	2,768	2,28675	2,4170001	2,7	2,8	0,48125	0,2316016	0,3509999	0,123201
TCP12	1,846	1,305	1,5369999	2,1	1,8	0,541	0,292681	0,3090001	0,095481
TCP13	2,566	1,9338	2,302	2,3	2,6	0,6322	0,3996769	0,264	0,069696
TCP14	1,949	1,2075	n	1,6	1,9	0,7415	0,5498223		0
TCP15	2,585	0	0	2,3	2,5	2,585	6,682225	2,585	6,682225
						ME	1,0476656	1,2047326	
						RMSE	1,0476656		1,2047326

Polígono

A figura 28 apresenta a diferença entre o polígono obtido à partir das coordenadas planimétricas advindas do produto com correção da base RTK e sem a correção da base.

Figura 28: Comparativo entre o polígono obtido à partir das coordenadas planimétricas advindas do produto com correção da base RTK e sem a correção da base.



6.4 Discussão

Este estudo teve como objetivo avaliar a acurácia dos produtos gerados por RPAS equipados com sensores RGB e LiDAR em uma área em processo de restauração florestal. Para isso, utilizamos receptores GNSS de dupla frequência, e os dados foram processados utilizando as metodologias relativas de SAG (Static) e PPP (Precise Point Positioning). Além disso, para melhorar a qualidade posicional, também foram empregados levantamentos com estação total e nível, aplicando técnicas convencionais de topografia. Esses métodos de levantamento, ao contrário dos GNSS, não são influenciados pelas copas das árvores, proporcionando uma maior precisão.

Observou-se que os pontos de controle localizados próximos a árvores com copas densas apresentaram uma qualidade posicional inferior quando levantados apenas com GNSS, especialmente no componente altimétrico. No entanto, ao aplicar ajustes e correções paramétricas, foi possível melhorar significativamente a qualidade posicional desses pontos.

Todos os pontos de controle foram ajustados por meio do método paramétrico e suas coordenadas homologadas (ver tabela X). Esses pontos foram, então, utilizados nos processamentos das nuvens de pontos e ortomosaicos gerados ao longo deste estudo.

6.4.1 Coordenadas homologadas dos GCPs, VCPs e TCPs

Desenvolvimentos recentes na área de visão computacional permitiram avanços significativos no processamento de grandes volumes de dados de imagens, por meio de técnicas como a fotogrametria a partir de múltiplas imagens (Structure from Motion - SfM). Diferentemente dos métodos fotogramétricos digitais tradicionais, que dependem de informações sobre a posição 3D da câmera, a abordagem SfM reconstrói a geometria da cena a partir da identificação automática e correspondência de características em múltiplas imagens. Isso resulta no alinhamento dessas imagens e na geração de uma nuvem de pontos composta por pontos correspondentes, que podem ser posteriormente densificados (Westoby et al., 2012; Tomaščík et al., 2017).

Entretanto, a utilização de pontos de controle geodésicos (GCPs) continua sendo essencial para o georreferenciamento preciso da nuvem de pontos. Na prática, a nuvem de pontos, assim como outros produtos derivados, como ortomosaicos, são dimensionados com base nas posições dos GCPs, que são levantados por meio de técnicas de posicionamento precisas, como receptores GNSS ou estação total (Puliti et al., 2015; Mikita et al., 2016).

O levantamento de GCPs em ambientes florestais, contudo, apresenta desafios adicionais em relação a áreas abertas, devido à dificuldade de acesso e interferência das copas das árvores. A precisão do georreferenciamento é crucial em qualquer análise subsequente que exija a determinação exata da posição de elementos, como troncos ou copas de árvores, onde a precisão espacial é de alta importância (Getzin et al., 2014; Tomaščík et al., 2017; Sinegalia et al., no prelo).

6.4.2 RGB

Visando obter dados geoespaciais de alta qualidade por meio do uso de drones equipados com sensores, os GNSS, IMUs e pontos de controle (GCPs) têm sido amplamente utilizados para aprimorar a precisão dos parâmetros de orientação externa das imagens adquiridas (Park et al., 2020; Cho et al., 2023), contribuindo para que os dados geoespaciais coletados durante os voos apresentem elevada precisão espacial. Essa precisão é crucial para aplicações em mapeamento topográfico e monitoramento ambiental (Hastaoglu et al., 2022).

Diversos estudos sugerem que, ao utilizar esses sensores em conjunto com um número adequado de GCPs, a qualidade dos dados obtidos tende a melhorar significativamente, reduzindo o desvio-padrão ou viés e, conseqüentemente, aumentando a precisão no georreferenciamento das imagens (Tomaščík et al., 2017; Siqueira et al., 2019; Hastaoglu et al., 2022). No entanto, para alcançar resultados de alta precisão, é necessário considerar o efeito da

distribuição geométrica dos GCPs, que pode impactar diretamente tanto a precisão das triangulações aéreas quanto a extensão da área de estudo. Assim, estudos adicionais voltados à otimização do número de GCPs para diferentes configurações espaciais se fazem necessários (Laporte-Fauret et al., 2019).

Neste estudo, foram criados 14 cenários distintos, nos quais o número de GCPs variou de 0 a 60. Além dos parâmetros RMSE e ME, utilizados para avaliar a precisão e a tendência do modelo, foram analisadas as acurácias entre os pontos em cada cenário. Esses dados foram avaliados conjuntamente, resultando na tabela de acurácia apresentada no item XX.

Nos cenários sem GCPs, as coordenadas E apresentaram um RMSE de 1,028 m, e o ME indicou uma forte tendência à superestimação ($ME < 0$) da qualidade do modelo, evidenciando baixa acurácia, apesar da superestimação dos dados. A análise desses dados, aliada às diferenças nos valores dos vértices externos e internos do polígono gerado, revelou que a acurácia esperada na ausência de pontos de controle varia entre 2,5 e 3 metros para os pontos que definem o polígono e entre 70 cm e 1,4 metros para os pontos internos. Ademais, não se observou um padrão uniforme de deslocamento dos vértices, já que estes não tendem a se deslocar consistentemente para um mesmo lado.

Do ponto de vista prático, caso tais dados fossem empregados no monitoramento de uma área em processo de restauração florestal, poderiam ocorrer impactos significativos na análise espacial e na tomada de decisões, como a discrepância na localização de mudas e vegetação, dificultando a avaliação precisa do crescimento e da regeneração; a inconsistência na comparação temporal, uma vez que o deslocamento não uniforme pode impedir a sobreposição exata de imagens de diferentes períodos, comprometendo análises temporais como taxas de crescimento e expansão de vegetação; o comprometimento das análises espaciais, pois estudos de fragmentação, conectividade ecológica e estimativa de biomassa podem ser distorcidos, afetando a interpretação dos dados e a eficácia das ações de manejo; e a dificuldade no georreferenciamento de intervenções, já que a localização incorreta de ações como o plantio de espécies estratégicas ou o controle de espécies invasoras pode prejudicar o acompanhamento das medidas adotadas no terreno (Alonzo et al. 2018; Scholl et al. 2021).

No cenário com 4 e 6 GCPs, as análises realizadas a partir do polígono formado pelas posições geométricas dos pontos de controle, associadas aos valores de ME e RMSE, indicaram uma melhoria considerável na acurácia. Nos pontos do perímetro (externos), a acurácia passou a variar entre 14 e 18 cm, enquanto nos pontos internos foi registrada em 22 cm. Embora esse cenário apresente melhores resultados no polígono externo em comparação aos modelos com 10, entre 15 e 40 e entre 45 e 55 GCPs — que demonstraram acurácias de 18 a 22 cm para os

dois primeiros grupos e de 17 a 21 cm para o último — houve, para os pontos internos, uma melhoria da qualidade posicional, com acurácias de 17, 15 e 14 cm, respectivamente. Na prática, se esse produto apresentar maior deslocamento nos pontos externos do polígono em relação aos internos, poderá ocorrer distorção na delimitação da área monitorada, pois a borda da área de estudo pode ser posicionada incorretamente, afetando medições de expansão da vegetação e confundindo a interpretação de ganhos ou perdas na cobertura vegetal (Scholl et al. 2021).

No componente Z (altimétrico), os resultados mostraram que, sem GCPs, a acurácia foi de 6 metros, melhorando significativamente com a inclusão de 4 ou 6 pontos de controle, passando para 17 cm. Contudo, ao utilizar 10 GCPs, a qualidade posicional deteriorou para 50 cm, melhorando novamente para 20 cm quando foram inseridos entre 15 e 30 pontos. Embora esse valor seja melhor que o obtido com 10 GCPs, ele foi inferior ao cenário com 4 e 6 GCPs, evidenciando que, para a altimetria, o melhor desempenho foi alcançado com 4 ou 6 pontos de controle.

Em um contexto de monitoramento de áreas em processo de restauração, se os produtos RGB apresentarem uma diferença de altitude de aproximadamente 20 cm em relação às altitudes reais, o impacto dependerá do tipo de análise realizada. Entre os possíveis efeitos, pode ocorrer erro na estimativa de biomassa e crescimento vegetal, pois pequenas variações altimétricas podem influenciar a estimativa da altura de árvores e da vegetação em regeneração, afetando a avaliação do crescimento ao longo do tempo, especialmente para espécies de pequeno porte. Além disso, há a incerteza na modelagem do microrelevo, pois em áreas com topografia sutil essa variação pode interferir na geração de Modelos Digitais de Elevação (MDE), prejudicando a análise do relevo e da hidrologia local, bem como a identificação de microdepressões ou elevações (Getzin et al., 2014; Tomaščík et al., 2017; Alonzo et al. 2018).

Outro efeito possível é o impacto nas análises de estratificação da vegetação, uma vez que, se os dados forem utilizados para classificar a vegetação em diferentes estratos (herbáceo, arbustivo e arbóreo), essa variação pode introduzir erros na separação entre as classes. Por fim, a detecção de alterações ao longo do tempo também pode ser comprometida, pois pequenas variações podem gerar falsas indicações de crescimento ou perda de cobertura vegetal, dificultando a identificação precisa das mudanças na estrutura da vegetação (Alonzo et al. 2018; Scholl et al. 2021). Assim, embora uma diferença de 20 cm possa parecer pequena, seu impacto dependerá do objetivo da análise. Em estudos detalhados sobre o crescimento de espécies de pequeno porte ou topografia de precisão, essa discrepância pode ser significativa, enquanto em

análises mais gerais de restauração florestal o efeito pode ser menos relevante (Getzin et al., 2014; Tomaščík et al., 2017).

Do exposto, com 4 pontos de controle, número este comumente utilizado em diversos contextos, desde monitoramento florestal remoto até análise de paisagens e georreferenciamento de áreas urbanas e rurais (Tomaščík et al., 2017), o modelo apresentou uma acurácia de aproximadamente 14 a 18 cm para o componente planimétrico e 22 cm para os pontos internos, além de 17 cm para o componente altimétrico. Esse desempenho pode ser considerado "ótimo" em termos de custo-benefício para aplicações submétricas, pois não há necessidade de um grande número de GCPs distribuídos pela área, o que tornaria o levantamento mais oneroso. Ressalta-se que os 4 GCPs utilizados foram dispostos nos cantos extremos da área em estudo. Vale ainda notar que, ao utilizar 30 GCPs, observou-se uma piora na qualidade posicional, possivelmente devido a erros aleatórios, e que a utilização de 35 a 55 GCPs pode levar à saturação do modelo, fenômeno conhecido como *overfitting*. Nesse caso, o modelo ajusta-se excessivamente aos pontos de controle, perdendo a capacidade de generalizar e apresentando erros em áreas fora desses pontos, o que pode comprometer a precisão do ortomosaico (Zhang et al., 2018).

Por fim, é importante destacar que, em diversos cenários, os valores de ME e RMSE apresentaram correspondência quase exata ou discrepâncias mínimas. Embora esses parâmetros não devam necessariamente ser iguais — uma vez que o RMSE é mais sensível a erros maiores —, quando os erros são pequenos e consistentes, ambos podem convergir. Isso indica que o modelo apresenta um erro distribuído de maneira uniforme, sem grandes desvios em relação à média.

6.4.3 LiDAR

O LiDAR é uma tecnologia avançada de sensoriamento remoto ativo, reconhecida por sua alta resolução e precisão na aquisição de dados. Ele gera nuvens de pontos 3D que representam objetos ou superfícies por meio de coordenadas específicas (x, y, z), podendo ser visualizadas em sistemas locais ou globais, com densidade variável conforme o sensor utilizado (Lim et al., 2003; Sharma et al., 2021; Idris et al., 2023). Uma das principais aplicações do LiDAR no sensoriamento remoto é a geração de Modelos Digitais de Terreno (MDTs) e Modelos Digitais de Superfície (MDS), que fornecem informações detalhadas sobre o relevo. Esses modelos possibilitam a criação de produtos de alta resolução e a extração precisa de parâmetros topográficos (Sharma, 2021).

No entanto, o georreferenciamento preciso da nuvem de pontos LiDAR é um processo complexo. Isso ocorre porque, por um lado, os pontos de controle de solo não são visíveis devido ao dossel denso, e, por outro, a precisão do georreferenciamento depende justamente do uso desses pontos de controle. Com o objetivo de superar essa limitação, diversos pesquisadores têm buscado maneiras de melhorar a qualidade da nuvem de pontos georreferenciada, desde o uso de alvos refletivos específicos para LiDAR, que podem ser utilizados nos pontos de controle de solo (GCPs), até a utilização de tecnologias GNSS RTK em campo (citação), bem como o uso de DEMs disponíveis como controle no posicionamento (Qinghua & Jie, 2021).

No que diz respeito às coordenadas planimétricas dos RPs, em ambos os cenários, elas foram utilizadas para avaliar o deslocamento da área de estudo, juntamente com o ME, o RMSE e as distâncias geométricas entre os pontos, considerando tanto o polígono como um todo quanto as relações entre os RPs, a fim de verificar a ocorrência de deformações, especialmente na região central do produto. É importante destacar que, apesar do cuidado e da acuidade visual empregados na demarcação do centróide das copas, algum deslocamento pode ter ocorrido; entretanto, esse parâmetro foi analisado estatisticamente, considerando a população amostral. Excluindo-se os outliers, como as distâncias inferiores a 1 cm, que possivelmente decorrem da acuidade visual, constatou-se uma tendência do modelo para um deslocamento de 1,2 metros. Ou seja, ao comparar o produto obtido sem a base RTK com o produto gerado utilizando os parâmetros de correção dessa base, observou-se um deslocamento das coordenadas planas de 1,2 metros.

Em termos práticos, esse deslocamento pode impactar as análises provenientes do monitoramento de uma área em restauração florestal a partir de produtos LiDAR, ocasionando erro na delimitação da área de monitoramento, uma vez que a definição imprecisa dos limites da área restaurada pode causar inconsistências na mensuração do progresso da recuperação vegetal e na identificação de zonas que necessitam de intervenção. Além disso, a comparação temporal pode ser prejudicada, pois a restauração florestal é acompanhada ao longo do tempo e um deslocamento de 1,2 metros dificulta a sobreposição precisa dos levantamentos, comprometendo a avaliação real da regeneração da vegetação (Almeida et al., 2019; Qinghua & Jie, 2021; Almeida et al., 2024).

Esse deslocamento também pode afetar a análise de cobertura e a estrutura da vegetação, pois mesmo pequenas variações podem resultar em falhas na correspondência entre os pontos de amostragem, influenciando a interpretação do crescimento da vegetação, o recrutamento de novas espécies e a cobertura arbórea. Ademais, a localização imprecisa de intervenções, como o plantio de espécies nativas ou o controle de invasoras, pode dificultar o acompanhamento da

eficácia dessas ações ao longo do tempo, e a imprecisão na localização das feições pode impactar a precisão de Modelos Digitais do Terreno e de Superfície, interferindo em modelos hidrológicos, análises de erosão e na avaliação do microrelevo, aspectos essenciais para a gestão do solo e das áreas em recuperação (Lim et al., 2003; Sharma et al., 2021; Idris et al., 2023; Almeida et al., 2024).

Quanto às distâncias geométricas entre os RPs, observou-se que, no RP1, a maior deformação ocorreu na distância para o RP7, com uma magnitude de 39 cm, enquanto a menor deformação foi registrada para o RP3, na ordem de 4 mm, valor que pode ser desconsiderado. O RP mais distante do RP1 é o RP6, cuja distância, no produto processado com a base RTK, foi de 283,825 m, havendo uma diferença de -0,093 cm nessa medida. Do RP2, o maior deslocamento também ocorreu para o RP7, com uma diferença de 0,227 m, enquanto a menor diferença foi registrada para o RP6, sem apresentar variação significativa. No caso do RP3, a maior diferença foi observada para o RP4, que é o mais próximo dele, com uma distância de 52,98 m e uma deformação de -0,474 m; entre o RP3 e o RP5, também foi constatada uma diferença significativa, de -0,29 m, sendo que esses três RPs estão localizados na região central do produto.

Ainda em relação ao RP3, a diferença registrada para o RP6, na extremidade do produto, foi de -31,7 cm, e não se observaram diferenças significativas entre o RP3 e os RPs 1 e 2, todos localizados na mesma região do produto. Do RP4, além da diferença mencionada para o RP1, constatou-se que a distância para o RP5 apresentou uma variação considerável, da ordem de +20 cm, sendo que ambos estão relativamente próximos e na região central. Do RP4 para o RP7, observou-se uma tendência semelhante àquela registrada do RP3 para o RP7, e entre o RP5 e o RP7 a diferença foi de aproximadamente 50 cm. Por fim, a diferença entre o RP6 e o RP7, ambos na mesma extremidade do produto, foi considerada desprezível.

Diante do exposto, verificou-se uma tendência de deformação na região central do produto ao comparar os levantamentos com e sem a correção da base RTK. Esse fator pode afetar o monitoramento da restauração florestal, ocasionando distorções na estrutura interna da vegetação, já que um deslocamento maior na região central compromete a precisão das medições de altura e densidade, influenciando a interpretação do crescimento e da sucessão ecológica.

Além disso, o deslocamento irregular pode dificultar a sobreposição exata dos levantamentos em diferentes períodos, criando a falsa impressão de alterações na distribuição da vegetação, especialmente no núcleo da área monitorada (Getzin et al., 2014; Tomaščík et al., 2017; Alonzo et al., 2018; Scholl et al., 2021). Outro impacto relevante é a influência na geração

de Modelos Digitais de Superfície e Terreno, o que compromete análises topográficas e a modelagem da vegetação, afetando estudos sobre biomassa e regeneração, bem como a identificação de padrões de crescimento. Em contextos de restauração florestal, que frequentemente ocorrem de fora para dentro, quando há vegetação remanescente nas bordas, ou de dentro para fora, quando núcleos de regeneração se formam, o deslocamento central pode mascarar esses padrões ecológicos (Tomaščík et al., 2017; Scholl et al., 2021).

Ademais, a alteração na localização de pontos de interesse, decorrente do deslocamento central, pode prejudicar a identificação e o rastreamento de elementos-chave, como áreas de maior regeneração ou locais específicos de intervenção, como plantios experimentais ou controle de espécies invasoras. Assim, esse tipo de deslocamento compromete a precisão na análise da estrutura da vegetação e o acompanhamento da recuperação florestal, dificultando a interpretação das mudanças ocorridas ao longo do tempo (Alonzo et al., 2018; Scholl et al., 2021).

No que diz respeito ao componente altimétrico, verificou-se que nenhum dos CHMs gerados, mesmo os com resoluções de 20 cm e 50 cm (que proporcionaram maior possibilidade de observações), retornou dados com qualidade posicional passível de avaliação. Esse fator pode estar intrínseco ao alvo colocado acima do caibro das árvores.

Com relação aos TCPs, além das observações geométricas, os dados LiDAR foram comparados com as medidas de altura feitas por clinômetro e vertex. Nos dois casos de TCPs com alturas de até 1 m, os CHMs apresentaram alturas diferentes das homologadas, onde o CHM de 20 cm superestimou em 70 cm e o CHM de 50 cm subestimou em até 20 cm.

Para os TCPs com alturas entre 1 e 2 metros, ocorreram três casos. O CHM de 20 cm não permitiu a obtenção de uma das árvores, e, nos outros casos, subestimou as alturas em cerca de 50 cm e 70 cm. O CHM de 50 cm permitiu a medição de apenas um TCP, e a medida foi subestimada em 30 cm.

Para os TCPs com alturas entre 2 e 3 metros, ocorreram oito casos. O CHM de 20 cm não permitiu a obtenção de dois TCPs, e as demais medições foram subestimadas entre 19 cm e 90 cm. O CHM de 50 cm também não possibilitou a obtenção de dois casos e, para os outros, apresentou medidas subestimadas na ordem de 6 cm a 80 cm.

Para TCPs com alturas entre 3 e 4 metros, ambos os CHMs permitiram a obtenção de apenas um elemento, subestimando sua medida em 1,5 m (para o CHM de 20 cm) e 2,5 m (para o CHM de 50 cm).

Para TCPs com alturas entre 4 e 5 metros, o CHM de 20 cm efetuou medições nos dois casos, mas as alturas foram subestimadas em 1,30 m e 1,80 m. O CHM de 50 cm subestimou as medidas em 60 cm.

As observações geométricas realizadas com mira e estação total apresentaram diferenças consideradas ótimas quando comparadas entre si, com variações na ordem de 10 cm. No entanto, as análises dos CHMs gerados revelaram que, nos produtos LiDAR, considerando os sensores, os parâmetros de voo e os métodos de processamento empregados, a dispersão em torno do valor verdadeiro foi da ordem de 1 metro.

A magnitude do Erro Médio e da Raiz do Erro Quadrático Médio indicou a ausência de discrepâncias significativas. Como os erros estavam uniformemente distribuídos, conclui-se que a qualidade posicional do LiDAR no componente altimétrico foi inferior à dos produtos RGB nos modelos analisados. Contudo, para a avaliação da acurácia dos produtos LiDAR, foi necessário considerar erros inerentes ao observador, ou seja, à pessoa responsável pelo processamento dos dados, uma vez que eventuais imprecisões nesse procedimento podem comprometer a qualidade dos resultados.

Além disso, a altura de voo adotada pode ter influenciado a precisão das informações coletadas, assim como o fato de o ortomosaico RGB utilizado na análise não ter sido processado diretamente no software DJI Terra, devido à necessidade de licença. Essa limitação impediu a correção das geotags diretamente nesse ambiente.

As geotags são metadados inseridos nas imagens que registram suas coordenadas geográficas no momento da captura. Quando imprecisas, as imagens podem ser mal posicionadas, comprometendo a precisão geoespacial e a qualidade do produto final. A correção das geotags consiste no ajuste dessas informações para garantir que as coordenadas de latitude, longitude e altitude estejam corretamente alinhadas no espaço. Esse processo é fundamental para assegurar que as imagens RGB, normalmente utilizadas para ortomosaicos e análises visuais, estejam devidamente sincronizadas com os dados LiDAR. Dessa forma, ambos os conjuntos de dados podem ser combinados com precisão na geração de produtos geoespaciais, como modelos digitais de elevação e ortomosaicos.

Diante dessas limitações, optou-se por não gerar uma tabela de acurácia para os resultados LiDAR obtidos. Recomenda-se que estudos futuros levem em consideração esses fatores, a fim de aprimorar a confiabilidade das análises e a precisão dos produtos gerados.

6.5 Considerações finais

Os resultados advindos dos processamentos dos produtos obtidos com os sensores RGB e LiDAR, ambos utilizados em uma área em processo de restauração florestal, revelaram aspectos importantes sobre a precisão posicional e a qualidade dos dados gerados por essas tecnologias. Com relação ao sensor RGB a quantidade de GCPs teve um impacto direto na acurácia dos modelos gerados, onde, a partir de 4 GCPs, foi possível alcançar uma acurácia excelente, com erros reduzidos para os componentes planimétricos e altimétricos. No entanto, a análise revelou que o número ideal de GCPs não é infinito: com o aumento da quantidade de GCPs, especialmente acima de 50, o modelo começou a apresentar sinais de saturação (overfitting), o que pode afetar a precisão geral, especialmente em áreas fora da cobertura dos GCPs.

O LiDAR, por sua vez, mostrou-se um excelente aliado na geração de nuvens de pontos georreferenciadas. A comparação entre cenários com e sem a correção pela base RTK evidenciou um deslocamento de cerca de 1,2 metros nos dados obtidos sem o uso da base RTK, o que demonstra a importância desse processo para a redução de erros.

A qualidade posicional do LiDAR no componente altimétrico mostrou-se inferior à dos produtos RGB nos modelos avaliados, contudo, a análise da acurácia dos produtos LiDAR também deve levar em consideração possíveis erros relacionados ao processamento dos dados, bem como a altura de voo adotada e a não utilização do software DJI Terra para processar o ortomosaico RGB, impactando diretamente na correção das geotags.

Diante dessas limitações, optou-se por não gerar uma tabela de acurácia e recomenda-se que estudos futuros considerem esses fatores para aprimorar a confiabilidade das análises.

Este estudo demonstrou a viabilidade do uso de RPAS equipados com sensores RGB e LiDAR para o mapeamento e análise de áreas de restauração florestal, com ênfase na avaliação da qualidade posicional dos produtos gerados. A integração de pontos de controle geodésicos e técnicas avançadas de processamento de dados possibilitou a obtenção de resultados que evidenciam o potencial complementar dessas tecnologias. Tanto o sensor RGB quanto o LiDAR mostraram-se ferramentas poderosas para a coleta de dados geoespaciais precisos em áreas florestais. A escolha adequada do número e da distribuição de GCPs, assim como o uso de tecnologias de correção, como a base RTK, são fundamentais para garantir a precisão dos produtos gerados. Contudo, a saturação do modelo devido ao excesso de GCPs e a necessidade de ajustes finos nos dados LiDAR ressaltam a importância de um planejamento meticuloso na configuração dos levantamentos. A combinação dessas tecnologias pode aprimorar

significativamente a eficiência e a precisão no monitoramento e na restauração de áreas florestais, proporcionando resultados robustos para diversas aplicações ambientais.

Literatura Citada

Albuquerque, R. W., Ferreira, M. E., Olsen, S. I., Tymus, J. R. C., Balieiro, C. P., Mansur, H., Moura, C. J. R., Costa, J. V. S., Branco, M. R. C., & Grohmann, C. H. (2021). Forest restoration monitoring protocol with a low-cost remotely piloted aircraft: Lessons learned from a case study in the Brazilian Atlantic Forest. *Remote Sensing*, 13(12), Article 12. <https://doi-org.ez31.periodicos.capes.gov.br/10.3390/rs13122>

Almeida, D.R.A. de, Stark, S.C., Chazdon, R., Nelson, B.W., Cesar, R.G., Meli, P., Gorgens, E.B., Duarte, M.M., Valbuena, R., Moreno, V.S., Mendes, A.F., Amazonas, N., Gonçalves, N.B., Silva, C.A., Schietti, J., Brancalion, P.H.S., 2019. The effectiveness of lidar remote sensing for monitoring forest cover attributes and landscape restoration. *For. Ecol. Manag.*, 438, pp. 34-43.

<https://doi.org/10.1016/j.foreco.2019.02.002>.

Almeida, D. R. A. de, Broadbent, E. N., Ferreira, M. P., Meli, P., Zambrano, A. M. A., Gorgens, E. B., Resende, A. F., Almeida, C. T. de, Amaral, C. H. do, Corte, A. P. D., Silva, C. A., Romanelli, J. P., Prata, G. A., Papa, D. de A., Stark, S. C., Valbuena, R., Nelson, B. W., Guillemot, J., Féret, J-B., Chazdon, R., Brancalion, P. H. S., 2021. Monitoring restored tropical forest diversity and structure through UAV-borne hyperspectral and lidar fusion. *Remote Sensing of Environment*, 264, 112582. ISSN 0034-4257.

<https://doi.org/10.1016/j.rse.2021.112582>.

Almeida, D. R. A. de, Vedovato, L., Fuza, M., Molin, P. G., Cassol, H., Resende, A. F., Krainovic, P. M., Almeida, C. T. de, Amaram, C., Haneda, L., Albuquerque, R. W., Gorgens, E., Romanelli, J., Ferreira, M., Salk, C., Espinoza, N., Silva, c., Broadbent, E., Brancalion, P. H. S., 2024. Remote sensing approaches to monitor tropical forest restoration: Current methods and future possibilities. *Journal of Applied Ecology*. <https://doi-org.ez31.periodicos.capes.gov.br/10.1111/1365-2664.14830>

Alonzo M, Andersen H-E, Morton DC, Cook BD. Quantifying Boreal Forest Structure and Composition Using UAV Structure from Motion. *Forests*. 2018; 9(3):119. <https://doi.org/10.3390/f9030119>

Arévalo-Verjel, A. N., Lerma J. L., Prieto, J. F., Carbonell-Rivera, J. P., Fernández, J., 2022. Estimation of the Block Adjustment Error in UAV Photogrammetric Flights in Flat Areas. *Remote Sensing*. 14(12):2877. <https://doi.org/10.3390/rs14122877>.

Alsadik, B.; Ellsäßer, F.J.; Awawdeh, M.; Al-Rawabdeh, A.; Almahasneh, L.; Oude Elberink, S.; Abuhamoor, D.; Al Asmar, Y. Remote Sensing Technologies Using UAVs for Pest and Disease Monitoring: A Review Centered on Date Palm Trees. *Remote Sens*. 2024, 16, 4371. <https://doi.org/10.3390/rs16234371>

Atik, M.E.; Arkali, M. Comparative Assessment of the Effect of Positioning Techniques and Ground Control Point Distribution Models on the Accuracy of UAV-Based Photogrammetric Production. *Drones* 2025, 9, 15. <https://doi.org/10.3390/drones9010015>

Berra, E. F., Peppas, M. V., 2020. Advances and Challenges of UAV SFM MVS Photogrammetry and Remote Sensing: Short Review. *IEEE Latin American GRSS & ISPRS Remote Sensing Conference (LAGIRS)*, pp. 533-538
DOI:10.5194/isprs-archives-XLII-3-W12-2020-267-2020.

Cho, J.M.; Lee, B.K. GCP and PPK Utilization Plan to Deal with RTK Signal Interruption in RTK-UAV Photogrammetry. *Drones* 2023, 7, 265. <https://doi.org/10.3390/drones7040265>

Corte, A. P. D., Souza, D. V., Rex, F. E., Sanquetta, C. R., Mohan, M., Silva, C.A., Zambrano, A.M.A., Prata, G., Almeida, D. R. A. de, Trautenmüller, J. W., Klauberg, C., Moraes A. de, Sanquetta, M. N., Wilkinson, B., Broadbent, E.N., 2020. Forest inventory with high-density UAV-Lidar: Machine learning approaches for predicting individual tree attributes. *Computers and Electronics in Agriculture* 179:105815, ISSN 0168-1699, <https://doi.org/10.1016/j.compag.2020.105815>.

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 Surf. Process. Landforms*. 38, 421–430.
<https://doi.org/10.1002/esp.3366>.

Getzin, S.; Nuske, R.S.; Wiegand, K. Using unmanned aerial vehicles (UAV) to quantify spatial gap patterns in forests. *Remote Sens*. 2014, 6, 6988–7004.

Hastaoglu, K. O., Kapicioglu, H. S., Gül, Y., & Poyraz, F. (2022). Investigation of the effect of height difference and geometry of GCP on position accuracy of point cloud in UAV photogrammetry. *Survey Review*, 55(391), 325–337. <https://doi-org.ez257.periodicos.capes.gov.br/10.1080/00396265.2022.2097998>

Idris, R., Abu Bakar, R., and Abdul Rasam, A. R.: LIDAR ASSESSMENTS AND MAPPING FOR KLANG VALLEY: A CASE STUDY AT JINJANG DISTRICT, SELANGOR, *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, XLVIII-4/W6-2022, 445–450, <https://doi.org/10.5194/isprs-archives-XLVIII-4-W6-2022-445-2023>, 2023.

Jaafar, W. M., Woodhouse, I. H., Silva, C. A., Omar, H., Abdul Maulud, K. N., Hudak A. T., Klauberger, C., Cardil, A., Mohan, M., 2018. Improving Individual Tree Crown Delineation and Attributes Estimation of Tropical Forests Using Airborne LiDAR Data. *Forests*. 2018; 9(12):759. <https://doi.org/10.3390/f9120759>

Juan-Ovejero, R., Elghouat, A., Navarro, C.J. et al. Estimation of aboveground biomass and carbon stocks of *Quercus ilex* L. saplings using UAV-derived RGB imagery. *Annals of Forest Science* 80, 44 (2023). <https://doi-org.ez31.periodicos.capes.gov.br/10.1186/s13595-023-01210-x>

Laporte-Fauret, Q.; Marieu, V.; Castelle, B.; Michalet, R.; Bujan, S.; Rosebery, D. Low-cost UAV for high-resolution and large-scale coastal dune change monitoring using photogrammetry. *J. Mar. Sci. Eng.* 2019, 7:63.

Li, W.; Guo, Q.; Jakubowski, M. K.; Kelly, M.; 2012. A comparative analysis of grid-based and object-based modeling approaches for poplar forest growing stock volume estimation in plain regions using airborne LIDAR data. *Photogrammetric Engineering & Remote Sensing*,

pp. 75-84(10). American Society for Photogrammetry and Remote Sensing. DOI: <https://doi.org/10.14358/PERS.78.1.75>

Lucieer, A., Jong, S.M., Turner, D., 2014. Mapping Landslide Displacements using Structure from Motion (SfM) and Image Correlation of Multi-Temporal UAV Photography. *Prog. Phys. Geogr.* 2014, 38, 97–116
DOI:10.1177/0309133313515293.

Maesano, C. N., Campbell, J. S., Foteinis, S., Furey, V., Hawrot, O., Pike, D., Aeschlimann, S., Reginato, P. L., Goodwin D. R., Looger, L. L., Boyden, E. S., Renforth, P., 2022. Geochemical Negative Emissions Technologies: Part II. Roadmap. *Front. Clim., Sec. Negative Emission Technologies*.
<https://doi.org/10.3389/fclim.2022.945332>.

Meng et al., 2018

Meng, Q.; Chen, X.. Zhang, J. et al. 2018. Canopy Structure Attributes Extraction from LiDAR Data Based on Tree Morphology and Crown Height Proportion. *J Indian Soc Remote Sens* 46, 1433–1444. <https://doi.org/10.1007/s12524-018-0789-8>

Mikita, T.; Janata, P.; Surový, P. Forest stand inventory based on combined aerial and terrestrial close-range photogrammetry. *Forests* 2016, 7, 165.

Ocalan, T., Turk, T., Tunalioglu, N. *et al.*, 2022. Investigation of accuracy of PPP and PPP-AR methods for direct georeferencing in UAV photogrammetry. *Earth Sci Inform* 15, 2231–2238.
<https://doi-org.ez31.periodicos.capes.gov.br/10.1007/s12145-022-00868-7>.

Ota T., Ogawa, M., Shimizu, K., Kajisa, T., Mizoue, N., Yoshida, S., Takao, G., Hirata, Y., Furuya, N., Sano, T., et al., 2015. Aboveground Biomass Estimation Using Structure from Motion Approach with Aerial Photographs in a Seasonal Tropical Forest. *Forests* 6(11):3882-3898.
<https://doi.org/10.3390/f6113882>.

Niethammer, M., Huang, Y., Vialard, F.X., 2011. Geodesic regression for image time-series. *Med Image Comput Comput Assist Interv.* 11;14(Pt 2):655-62.
doi: 10.1007/978-3-642-23629-7_80.

Park, S.; Choi, Y.; Bae, J.; Hong, S.; Sohn, H. Three-dimensional positional accuracy analysis of uav imagery using ground control points acquired from multisource geospatial data. *Korean J. Remote Sens.* 2020, 36, 1013–1025.

Puliti, S.; Olerka, H.; Gobakken, T.; Næsset, E. Inventory of Small Forest Areas Using an Unmanned Aerial System. *Remote Sens.* 2015, 7, 9632–9654

Qinghua, L. & Jie, S. 2021. Georeferencing with Self-Calibration for Airborne Full-Waveform Lidar Data Using Digital Elevation Model. Source: *Photogrammetric Engineering & Remote Sensing*, Volume 87, Number 1, January 2021, pp. 43-52(10). Publisher: American Society for Photogrammetry and Remote Sensing. DOI: <https://doi-org.ez257.periodicos.capes.gov.br/10.14358/PERS.87.1.43>

Romanelli, J. P., Meli, P., Santos, J. P. B., Jacob, I. N., Souza, L. R., Rodrigues, A. V., Trevisan, D. P., Huang, C., Almeida, D. R. A. de, Silva, L. G. M., Assad, M. L. R. C. L., Cadotte, M. W., Roodrigues, R. R., 2022. Biodiversity responses to restoration across the Brazilian Atlantic Forest, *Science of The Total Environment*, v. 821, 153403, ISSN 0048-9697, <https://doi.org/10.1016/j.scitotenv.2022.153403>.

Scholl VM, McGlinchy J, Price-Broncucia T, Balch JK, Joseph MB. 2021. Fusion neural networks for plant classification: learning to combine RGB, hyperspectral, and lidar data. *PeerJ* 9:e11790 <https://doi.org/10.7717/peerj.11790>

Sharma, M., Garg, R. D., Badenko, V ., Fedotov, A., Min, L., Yao, A. Potential of airborne LiDAR data for terrain parameters extraction. *Journal: Quaternary International*, 2021, p. 317-327. <https://doi.org/10.1016/j.quaint.2020.07.039>

Silva, AR da, Demarchi L, Sikorska D, Sikorski P, Archiciński P, Jóźwiak J, Chormański J. Multi-source remote sensing recognition of plant communities at the reach scale of the Vistula River, Poland, *Ecological Indicators*, v. 142, 2022, 109160, ISSN 1470-160X. <https://doi.org/10.1016/j.ecolind.2022.109160>

Sinegalia, M. K. S. D., Santoro, G. B., Molin, P. G., 2023. How have RPAS helped monitor forests and what can we apply in forest restoration monitoring? *Restoration ecology* 32:1:e14061.

<https://doi.10.1111/rec.14061>.

Sinegalia, M. K. S. D., Filho, J. R. K., Viveiros, J. M. S. M., Amaral, V. C., Soares, B. J. M., Fernandes P. F., Molin, P. G., 2023b. Influência da cintilação ionosférica na qualidade posicional de pontos de controle obtidos com GNSS: considerações no contexto do monitoramento florestal remoto. V Workshop do INCT GNSS-NavAer. INPE - São José dos Campos/SP.

Sinegalia, M. K. S. D., Ferreira, G. de A., Fernandes, P. F., Filho, J. R. K., Amaral, V. C., Viveiros, J. M. S. M., Soares, B. J. M., Rodrigues, N. B. D., Toledo, A. M. A., P. G. Molin. “no prelo”. Conectando Paisagens: Implantação de Uma Rede Geodésica materializada em Ambientes Ideais, Florestais e Diversos. *Revista Brasileira de Geografia Física*.

No prelo.

Singh, C. H., Rai, A., Harshit, Mishra, V., Kushwaha, S. K. P., Jain, K., 2023. Quality Assessment of UAV Data using Multiple RTK Reference Stations. *International Conference on Machine Intelligence for GeoAnalytics and Remote Sensing (MIGARS)*, Hyderabad, India. 1-4.

<https://doi.org/10.1109/MIGARS57353.2023.10064555>

Siqueira, H. L., J. Marcato, E. T. Matsubara, A. Eltner, R. A. Colares and F. M. Santos, "The Impact of Ground Control Point Quantity on Area and Volume Measurements with UAV SFM Photogrammetry Applied in Open Pit Mines," *IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium*, Yokohama, Japan, 2019, pp. 9093-9096, doi: 10.1109/IGARSS.2019.8897829.

Štroner, M., Urban, R., Křemen, T., & Braun, J. (2023). UAV DTM acquisition in a forested area – comparison of low-cost photogrammetry (DJI Zenmuse P1) and LiDAR solutions (DJI Zenmuse L1). *European Journal of Remote Sensing*, 56(1). <https://doi-org.ez257.periodicos.capes.gov.br/10.1080/22797254.2023.2179942>

Swinfield, T., Lindsell, J. A., Williams, J. V., Harrison, R., Agustiono, D., Habibi, E., Gemita, C. B., Schönlieb, Coomes, D. A., 2019. Accurate Measurement of Tropical Forest Canopy Heights and Aboveground Carbon Using Structure From Motion. *Remote Sensing*. 11(8):928. <https://doi.org/10.3390/rs11080928>.

Szypuła, B., 2023. Accuracy of UAV-based DEMs without ground control points. *GeoInformatica*.
<https://doi-org.ez31.periodicos.capes.gov.br/10.1007/s10707-023-00498-1>

Tomašík, J.; Mokroš, M.; Saloň, Š.; Chudý, F.; Tunák, D. Accuracy of Photogrammetric UAV-Based Point Clouds under Conditions of Partially-Open Forest Canopy. *Forests* 2017, 8, 151. <https://doi.org/10.3390/f8050151>

Turner, D., Lucieer, A., Jong, S. M. de, 2015. Time Series Analysis of Landslide Dynamics using an Unmanned Aerial Vehicle (UAV). *Remote Sens.* 7:1736–1757. <https://doi.org/10.3390/rs70201736>.

Vahid, N., Ali, A. D., Hossein, A., Marc, P.-D., Manochehr, N., Arnaud, L. B., 2021. Unmanned aerial vehicles (UAV)-based canopy height modeling under leaf-on and leaf-off conditions for determining tree height and crown diameter (case study: Hyrcanian mixed forest). *Canadian Journal of Forest Research*. 51(7): 962-971. <https://doi.org/10.1139/cjfr-2020-0125>

Westoby, M.J.; Brasington, J.; Glasser, N.F.; Hambrey, M.J.; Reynolds, J.M. “Structure-from-Motion” photogrammetry: A low-cost, effective tool for geoscience applications. *Geomorphology* 2012, 179, 300–314.

White JC, Coops N, Wulder MA, Vastaranta M, Hilker T, Tompalski P (2016) Remote sensing technologies for enhancing forest inventories: a review. *Canadian Journal of Remote Sensing* 42: 619–641. <https://doi.org/10.1080/07038992.2016.1207484>

White, J. C., Wulder, M. A., Hermosilla, T., Coops, N.C., Hobart, G.W., 2017. A nationwide annual characterization of 25years of forest disturbance and recovery for Canada using Landsat time series. *Remote Sensing of Environment* 194:303-321.

<https://doi.org/10.1016/j.rse.2017.03.035>.

Zhang, H., Bauters, M., Boeckx, P., Van Oost, K., 2021. Mapping Canopy Heights in Dense Tropical Forests Using Low-Cost UAV-Derived Photogrammetric Point Clouds and Machine Learning Approaches. *Remote Sensing*. 13(18):3777.

<https://doi.org/10.3390/rs13183777>.

Zhenchao Zhang, Markus Gerke, George Vosselman, Michael Ying Yang, A patch-based method for the evaluation of dense image matching quality, *International Journal of Applied Earth Observation and Geoinformation*, v. 70, 2018, Pages 25-34, ISSN 1569-8432,

<https://doi.org/10.1016/j.jag.2018.04.002>.

7. CONSIDERAÇÕES FINAIS

O objetivo principal desta tese foi avaliar a acurácia posicional de produtos RGB e LiDAR. Inicialmente, para fundamentar a importância do tema, realizamos uma revisão sistemática da literatura, que, além de ampliar o conhecimento sobre o assunto, evidenciou a relevância de se avaliar a qualidade posicional das geotecnologias aplicadas no monitoramento de restauração florestal. Embora existam diversos estudos sobre o uso de drones equipados com sensores para obtenção de atributos florestais, notou-se uma lacuna significativa de pesquisas focadas especificamente na aplicação dessas tecnologias no contexto de restauração florestal. Além disso, identificou-se uma escassez alarmante de estudos que avaliem a acurácia dos produtos gerados por drones e sensores (Sinegalia et al., 2023).

Após a validação do tema, visando alcançar os objetivos propostos, iniciou-se a implementação da pesquisa, que envolveu primeiramente a criação de uma rede geodésica de alta precisão, denominada Rede Cepegeo. As redes geodésicas são essenciais para os profissionais de mensuração, pois melhoram a qualidade posicional dos pontos levantados e permitem a validação e correção de erros que podem comprometer a precisão dos resultados. Elas também facilitam a integração de dados geoespaciais, conferindo robustez às informações adquiridas e aumentando a confiabilidade das análises subsequentes. Em contextos nos quais a precisão é essencial, uma infraestrutura geodésica bem estruturada é indispensável.

Ao longo do processo, enfrentaram-se desafios como a escolha dos pontos de levantamento, a mobilização de recursos para os levantamentos GNSS e a necessidade constante de manutenção dos marcos geodésicos. Esses desafios ressaltaram a importância de uma rede geodésica bem mantida, que assegura dados confiáveis para as fases seguintes da pesquisa. A integração das metodologias adotadas resultou em uma rede geodésica de alta qualidade posicional, atendendo aos padrões técnicos e fornecendo dados precisos para a continuidade da pesquisa. Este estudo também destaca a importância da infraestrutura geodésica no Brasil, um país de grandes dimensões, onde a falta de redes adequadas pode prejudicar projetos de grande impacto. A implantação e manutenção de redes como a Cepegeo são essenciais não apenas para a melhoria da mensuração geoespacial, mas também para o avanço científico e o planejamento de grandes projetos de infraestrutura, como os relacionados à gestão ambiental, ordenamento territorial e desenvolvimento urbano sustentável. A Rede Cepegeo representa um marco importante para a comunidade científica e profissional, funcionando como um modelo para a criação de outras redes geodésicas interconectadas em nível nacional, promovendo a integração entre diferentes áreas do conhecimento e impulsionando o desenvolvimento científico e tecnológico do país.

Seguindo com o estudo, foi realizada a avaliação da acurácia das metodologias GNSS, considerando diferentes tempos de rastreo e cenários variados, incluindo áreas adjacentes a florestas e ambientes desafiadores. Os resultados indicaram que as técnicas de relativo estático rápido, relativo estático (com tempo mínimo de 30 minutos) e Posicionamento por Ponto Preciso (PPP), com ocupação mínima de 30 minutos, forneceram acurácia entre 10,1 e 30 centímetros, tanto em vértices próximos a edificações e corpos d'água quanto em florestas de baixa densidade. Para florestas de alta densidade de copa, a melhor acurácia foi obtida com a técnica de relativo estático (mínimo de 30 minutos), mas os resultados variaram entre 50,1 e 80 centímetros de acurácia, evidenciando o impacto da densidade das copas das árvores na qualidade do sinal recebido.

No que se refere à altimetria, os melhores resultados (entre 1,1 e 10 centímetros) foram obtidos em vértices em condições ideais. Para pontos próximos a edificações e corpos d'água, as acurácias variaram entre 10,1 e 30 centímetros, observadas exclusivamente em rastreios de 2 horas (para o método relativo estático) e 3 horas (para o método PPP). Portanto, a metodologia de relativo estático apresentou a melhor relação entre precisão e acurácia, com dados de excelente qualidade posicional.

Por fim, para avaliar a acurácia posicional de produtos RGB e LiDAR no contexto do monitoramento florestal remoto, foi realizado um estudo de caso em uma área em processo de restauração florestal. Nessa etapa, foram implantados 90 pontos de controle com técnicas topográficas. Voos com drones equipados com sensores RGB e LiDAR geraram ortomosaicos e DTMs para o RGB, enquanto a classificação das nuvens de pontos LiDAR possibilitou a geração de CHMs, melhorando a precisão ao incorporar pontos de controle verticais.

Os produtos gerados foram analisados por meio de comparações de coordenadas no sistema UTM, e também foram avaliadas as distâncias geométricas nos cenários propostos para o LiDAR, visando identificar distorções. Os resultados revelaram aspectos importantes sobre a precisão posicional e a qualidade dos dados. Para o sensor RGB, o número de GCPs teve impacto direto na acurácia dos modelos. Com 4 GCPs, obteve-se excelente precisão, com erros mínimos nos componentes planimétricos e altimétricos. Porém, quando o número de GCPs ultrapassou 50, o modelo começou a apresentar sinais de saturação (overfitting), prejudicando a precisão geral, especialmente nas áreas fora da cobertura dos GCPs. Em contrapartida, cenários com apenas 4 GCPs apresentaram ótima acurácia em termos de custo-benefício, sugerindo que um número reduzido de pontos é suficiente para aplicações submétricas.

O sistema LiDAR também se mostrou eficaz para a geração de nuvens de pontos georreferenciadas. A comparação entre cenários com e sem correção por base RTK revelou um

deslocamento de aproximadamente 1,2 m nos dados não corrigidos, sublinhando a importância dessa correção. Embora pequenas deformações tenham sido observadas, especialmente na região central da área, a variação foi de cerca de 40 cm. No entanto, a qualidade posicional do LiDAR no componente altimétrico foi inferior à dos produtos RGB. A acurácia do LiDAR pode ter sido influenciada por fatores como o processador de dados, a altura de voo e a ausência do software DJI Terra para o processamento do ortomosaico RGB, o que impactou a correção das geotags. Dado a complexidade desses fatores, optou-se por não gerar uma tabela de acurácia e recomenda-se que futuros estudos considerem essas variáveis para aprimorar a confiabilidade das análises.

Este estudo demonstrou a viabilidade do uso de RPAS equipados com sensores RGB e LiDAR no mapeamento e análise de áreas de restauração florestal. A combinação de pontos de controle geodésicos e técnicas avançadas de processamento de dados resultou em resultados que destacam o potencial complementar dessas tecnologias. Ambas as tecnologias, RGB e LiDAR, mostraram-se ferramentas poderosas para a coleta de dados geoespaciais precisos em áreas florestais. A escolha adequada do número e da distribuição dos GCPs, além do uso de tecnologias de correção como a base RTK, é fundamental para garantir a precisão dos produtos gerados. No entanto, a saturação do modelo devido ao excesso de GCPs e a necessidade de ajustes finos nos dados LiDAR ressaltam a importância de um planejamento cuidadoso nos levantamentos. A integração dessas tecnologias pode aprimorar significativamente a eficiência e a precisão no monitoramento e na restauração de áreas florestais, oferecendo resultados robustos para diversas aplicações ambientais.

A relevância deste trabalho transcende os limites individuais, uma vez que busca contribuir de maneira significativa para a comunidade científica e acadêmica. A expectativa é que esta tese não apenas atenda às demandas específicas da pesquisa em questão, mas também ofereça insights valiosos que possam enriquecer o conhecimento existente e, assim, fomentar o avanço do campo de estudo. Acreditamos que os esforços empreendidos não apenas fortalecerão nossa formação como pesquisadores, mas também deixarão um legado significativo para a comunidade científica, contribuindo para o avanço do conhecimento e para a promoção de impactos positivos em diversos contextos.

ANEXO 1

Tabela: Cenários gerados em função dos pontos de controle.

CENÁRIO	GCPs utilizados
4 pontos	G43; G40; E2; G19
6 pontos	G43; G40; E2; G19; G16; E11
10 pontos	G43; G40; E2; G19; G16; E11; G32; G45; G22; E4
15 pontos	G43; G40; E2; G19; G16; E11; G32; G45; G22; E4; G24; G47; E12; E16; G61
20 pontos	G43; G40; E2; G19; G16; E11; G32; G45; G22; E4; G24; G47; E12; E16; G61; G59; G38; G57; G50; E13
25 pontos	G43; G40; E2; G19; G16; E11; G32; G45; G22; E4; G24; G47; E12; E16; G61; G59; G38; G57; G50; E13; G31; G44; G60; G20; G62
30 pontos	G43; G40; E2; G19; G16; E11; G32; G45; G22; E4; G24; G47; E12; E16; G61; G59; G38; G57; G50; E13; G31; G44; G60; G20; G62; G49, E9, G54, G35, G26
35 pontos	G43; G40; E2; G19; G16; E11; G32; G45; G22; E4; G24; G47; E12; E16; G61; G59; G38; G57; G50; E13; G31; G44; G60; G20; G62; G49, E9, G54, G35, G26; E14; G39; G42; E1-BASE; G17
40 pontos	G43; G40; E2; G19; G16; E11; G32; G45; G22; E4; G24; G47; E12; E16; G61; G59; G38; G57; G50; E13; G31; G44; G60; G20; G62; G49, E9, G54, G35, G26; E14; G39; G42; E1-BASE; G17; G30; G46; G28; G23; 0016CA
45 pontos	G43; G40; E2; G19; G16; E11; G32; G45; G22; E4; G24; G47; E12; E16; G61; G59; G38; G57; G50; E13; G31; G44; G60; G20; G62; G49, E9, G54, G35, G26; E14; G39; G42; E1-BASE; G17; G30; G46; G28; G23; 0016CA; E8; G56; G27; G29; G36
50 pontos	G43; G40; E2; G19; G16; E11; G32; G45; G22; E4; G24; G47; E12; E16; G61; G59; G38; G57; G50; E13; G31; G44; G60; G20; G62; G49, E9, G54, G35, G26; E14; G39; G42; E1-BASE; G17; G30; G46; G28; G23; 0016CA; E8; G56; G27; G29; G36; E5; G25; G48; G33; G37
55 pontos	G43; G40; E2; G19; G16; E11; G32; G45; G22; E4; G24; G47; E12; E16; G61; G59; G38; G57; G50; E13; G31; G44; G60; G20; G62; G49, E9, G54, G35, G26; E14; G39; G42; E1-BASE; G17; G30; G46; G28; G23; 0016CA; E8; G56; G27; G29; G36; E5; G25; G48; G33; G37; P6; G21; E10; G34; G41
60 pontos	G43; G40; E2; G19; G16; E11; G32; G45; G22; E4; G24; G47; E12; E16; G61; G59; G38; G57; G50; E13; G31; G44; G60; G20; G62; G49, E9, G54, G35, G26; E14; G39; G42; E1-BASE; G17; G30; G46; G28; G23; 0016CA; E8; G56; G27; G29; G36; E5; G25; G48; G33; G37; P6; G21; E10; G34; G41; g18; g55; 0016BA; 0016AA; G58