



UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"

ISABELLA SUBTIL NORBERTO

INTEGRAÇÃO DE DADOS LIDAR E IMAGENS ÓPTICAS
TERRESTRES PARA A GERAÇÃO DE NUVENS DE PONTOS
MULTIESPECTRAIS



Presidente Prudente
2024

ISABELLA SUBTIL NORBERTO

**INTEGRAÇÃO DE DADOS LIDAR E IMAGENS ÓPTICAS
TERRESTRES PARA A GERAÇÃO DE NUVENS DE PONTOS
MULTIESPECTRAIS**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Ciências Cartográficas (PPGCC) da Faculdade de Ciências e Tecnologia – Universidade Estadual Paulista “Júlio de Mesquita Filho” – Presidente Prudente/SP, como requisito parcial para a concessão do título de Mestre em Ciências Cartográficas.

Área de concentração: Fotogrametria e Sensoriamento Remoto

Orientador: Prof. Dr. Antonio Maria Garcia Tommaselli

Coorientador: Prof. Dr. Milton Hirokazu Shimabukuro

Presidente Prudente
2024

FICHA CATALOGRÁFICA

N824i	Norberto, Isabella Subtil. Integração de dados LiDAR e imagens ópticas terrestres para a geração de nuvem de pontos multiespectrais / Isabella Subtil Norberto. - Presidente Prudente, 2024 83 p. : il. Dissertação (mestrado) – Universidade Estadual Paulista (UNESP), Faculdade de Ciências e Tecnologia, Presidente Prudente Orientador: Antonio Maria Garcia Tommaselli Coorientador: Milton Hirokazu Shimabukuro 1. Integração de sensores. 2. Sensor multiespectral. 3. LiDAR. 4. Fotogrametria à curta distância. 5. Nuvem de pontos multiespectrais. I. Título.
-------	---

IMPACTO POTENCIAL DESTA PESQUISA

A integração de sensores e o desenvolvimento de produtos derivados de nuvens de pontos multiespectrais para análise de vegetação aprimoram as avaliações agrícolas, fornecendo dados confiáveis sobre a saúde das culturas. Práticas automatizadas e não destrutivas elevam a eficiência, promovendo inovação (ODS 9), sustentabilidade (ODS 2) e preservação ambiental (ODS 15).

POTENTIAL IMPACT OF THIS RESEARCH

Improving agricultural assessments and providing reliable data on crop health by integrating sensors and developing products derived from multispectral point clouds for vegetation analysis. Automated and non-destructive methods increase efficiency, thereby promoting innovation (SDG 9), sustainability (SDG 2) and environmental preservation (SDG 15).

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: INTEGRAÇÃO DE DADOS LIDAR E IMAGENS ÓPTICAS TERRESTRES
PARA A GERAÇÃO DE NUVENS DE PONTOS MULTIESPECTRAIS

AUTORA: ISABELLA SUBTIL NORBERTO

ORIENTADOR: ANTONIO MARIA GARCIA TOMMASELLI

COORIENTADOR: MILTON HIROKAZU SHIMABUKURO

Aprovada como parte das exigências para obtenção do Título de Mestra em Ciências Cartográficas,
área: Aquisição, Análise e Representação de Informações Espaciais pela Comissão Examinadora:

Prof. Dr. ANTONIO MARIA GARCIA TOMMASELLI (Participação Presencial)
Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente



Prof. Dr. HENRIQUE CANDIDO DE OLIVEIRA (Participação Virtual)
Departamento de Infraestrutura e Ambiente / Universidade Estadual de Campinas

Prof. Dr. RENATO CÉSAR DOS SANTOS (Participação Presencial)
Pós-doutorando / Faculdade de Ciências e Tecnologia de Presidente Prudente



Presidente Prudente, 25 de outubro de 2024

AGRADECIMENTOS

Gostaria de expressar minha profunda gratidão a todos que contribuíram direta ou indiretamente para a realização deste trabalho e para a conclusão bem-sucedida da dissertação de mestrado. Seus esforços e apoio foram fundamentais ao longo deste processo.

O presente trabalho foi realizado com apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) – Processo 130414/2022-0. Agradeço ao CNPq pelo suporte financeiro que viabilizou a condução deste projeto.

Agradeço à FAPESP (Fundação de Amparo à Pesquisa do Estado de São Paulo) pelo suporte na obtenção de dados em Monte Carmelo – MG e apoio com equipamentos durante a coleta de dados para este trabalho, por meio do projeto temático "Sensoriamento Remoto de Alta Resolução para Agricultura de Precisão – processo 2021_06029-7".

Agradeço pela oportunidade de aprimorar meus conhecimentos e contribuir para a pesquisa na área, dentro do ambiente acadêmico proporcionado pelo Programa de Pós-Graduação em Ciências Cartográficas (PPGCC).

Agradeço sinceramente ao meu orientador, Antonio Maria Garcia Tommaselli, e ao meu coorientador, Milton Hirokazu Shimabukuro. As orientações, vastos conhecimentos e dedicação foram pilares essenciais para o desenvolvimento desta dissertação. O cuidado e a motivação que compartilharam contribuíram significativamente para fortalecer minha confiança durante o desenvolvimento e apresentação do projeto.

Aos amigos cultivados ao longo desta jornada, expresso minha profunda gratidão. Alguns colaboraram ativamente na coleta e processamento inicial de dados, enquanto outros ofereceram paciência e conselhos, auxiliando-me a superar diversos desafios. A colaboração e paciência desses amigos foram verdadeiramente inestimáveis.

Cada um de vocês, incluindo minha família, contribuíram no meu percurso acadêmico, e por isso, meu profundo agradecimento. A presença, apoio e encorajamento foram essenciais para superar desafios e celebrar conquistas.

RESUMO

A geração de nuvens de pontos multiespectrais pode ser viabilizada com a integração de sensores, combinando câmaras multiespectrais e sistemas LiDAR (*Light Detection and Ranging*). Atualmente, escâneres terrestres comerciais permitem a obtenção de nuvens de pontos coloridas em RGB. No entanto, soluções para a captura de nuvens de pontos multiespectrais com múltiplas bandas de uma câmara ainda não estão amplamente disponíveis no mercado. Nesta dissertação, foram utilizadas diferentes técnicas para criar um fluxo de processamento capaz de resultar em uma nuvem tridimensional multiespectral. A compatibilização geométrica dos dados foi realizada estabelecendo as posições da câmara em relação à nuvem por meio da fototriangulação. Após a estimação da posição e atitude das imagens, as informações foram utilizadas para a determinação do ponto de vista do observador (câmara) em relação ao objeto (nuvem de pontos). A abordagem proposta visa reduzir o custo computacional ao diminuir a densidade de pontos fora da região de interesse da imagem e minimizar os efeitos do duplo mapeamento antes da atribuição de valores multiespectrais à nuvem de pontos. O método de *culling* otimiza o processamento, descartando pontos fora do volume visível da câmara. Por outro lado, o algoritmo *Hidden Points Removal* é ideal para identificar e rotular pontos oclusos, que são obstruídos por outros pontos mais próximos ao sensor, além de mitigar o duplo mapeamento. Essas técnicas atuam de forma complementar ao restringir o cálculo das projeções espectrais exclusivamente aos pontos visíveis da nuvem de pontos, utilizando as equações de colinearidade para relacionar as coordenadas tridimensionais aos valores espectrais. Como resultado das técnicas utilizadas, a colorização revelou-se eficaz quando realizada com uma quantidade adequada de pontos de controle bem distribuídos, com múltiplas estações para mitigar distorções originadas do alinhamento das imagens, coleta do LiDAR na resolução 814 pt/m², aplicação do *culling* reduziu o custo computacional em quatorze vezes e a rotulação de pontos oclusos, localizados fora do volume de visualização da câmara. As técnicas empregadas mostraram-se operacionalmente eficientes para a colorização. Entretanto, problemas observados durante a coleta, como os movimentos causados pelo vento, podem impactar significativamente a obtenção de um produto de alta resolução espacial.

Palavras-chave: LiDAR, nuvem de pontos multiespectral, Fotogrametria à curta distância.

ABSTRACT

Multispectral point clouds can be generated by integrating sensors, combining multispectral cameras and LiDAR (Light Detection and Ranging) systems. Currently, RGB point clouds can be obtained using commercially available terrestrial scanners. However, there are not yet many solutions on the market that can capture multi-band multispectral point clouds with a single camera. This project investigated techniques to create a processing flow that would result in a three-dimensional multispectral cloud. Phototriangulation was used to determine the position and attitude of the camera relative to the LiDAR point cloud to allow the data to be made compatible. The information can be used to determine the viewpoint of the observer (camera) with respect to the object (point cloud) once the position and attitude of the images have been estimated. Before assigning multispectral values to the point cloud, the proposed approach aims to reduce the computational cost by reducing the density of points outside the region of interest of the image and minimizing the effects of double mapping. By discarding points outside the visible volume of the camera, the Culling method optimizes the processing. On the other hand, the Hidden Points Removal operator is ideal for identifying and labelling occluded points that are obscured by other points closer to the sensor, as well as mitigating double mapping. These techniques complement each other by using the collinearity equations to relate the three-dimensional coordinates to the spectral values, and by restricting the calculation of the spectral projections to the visible points of the point cloud. As a result, colorization proved effective when performed with an adequate number of well-distributed control points, multiple acquisitions to mitigate distortions from image alignment, 814 pt/m² LiDAR acquisitions, application of a culling method that reduced computational cost fourteen-fold, and removal of occluded points. The techniques used proved to be operationally efficient for colorization. However, challenges during acquisitions had a significant impact on obtaining a product with high spatial resolution.

Keywords: LiDAR, multispectral point cloud, close range.

LISTA DE FIGURAS

Figura 2.1 – Ajuste por MLS para remoção de ruídos.....	20
Figura 2.2 – Sistema de coordenadas da imagem e da nuvem LiDAR.....	26
Figura 2.3 – Esquematização do VFC (<i>frustum</i> traçado em vermelho) com: o centro da câmara, plano da imagem, o plano próximo (<i>near</i>), plano distante (<i>far</i>) e os FoVs horizontal (α) e vertical (θ).....	28
Figura 2.4 – Caixas delimitadoras (a) alinhadas ao eixo e (b) orientadas.	29
Figura 2.5 –O operador HPR apresenta a (a) construção do problema e (b) os pontos detectados pelo <i>Convex Hull</i> , sendo o desenho em azul a nuvem de pontos original e em vermelho a representação dos pontos visíveis da região convexa apresentada em (a).....	30
Figura 2.6 – Exemplos do <i>Spherical Flipping</i> para diferentes ε . A (a) nuvem de pontos bidimensional de teste e (b, c) o resultado da variação de ε para o cálculo da transformação geométrica, onde os pontos pretos representam pontos oclusos e os vermelhos os visíveis.....	34
Figura 2.7 – Interpolação bilinear.....	35
Figura 3.1 – Câmaras da Sony (a) com duas lentes, (b) com seis lentes.....	39
Figura 3.2 – Disposição dos quadrantes da câmara.....	40
Figura 3.3 – Conjunto de dados (a) no cafeeiro e (b) a disposição dos alvos na árvore e (c) a câmara Agrowing capturando uma imagem entre a sequência de imagens.....	42
Figura 3.4 – Conjunto de dados com (a) a macieira, (b) os ajustes em alvos esféricos e (c) no LiDAR.....	42
Figura 3.5 – Fluxograma	44
Figura 4.1 – (a) Orientação das imagens (banda 550 nm) no cafeeiro e a (b) distribuição dos pontos de controle e verificação.....	53
Figura 4.2 – (a) Orientação das imagens (550 nm) na macieira e (b) distribuição dos pontos de controle e verificação.....	55
Figura 4.3 – Filtragem de ruídos para o cafeeiro (a) antes e (b) depois.....	58
Figura 4.4 – Nuvem LiDAR com diferentes resoluções na coleta: (a) 102,1 pt/m ² , (b) 203,9 pt/m ² , (c) 407,8 pt/m ² e (d) 814 pt/m ²	58
Figura 4.5 – Filtragem de ruídos para a macieira (a) antes e (b) depois.....	59
Figura 4.6 – (a) Recortes usados na colorização e (b) mosaico das imagens.....	61
Figura 4.7 – Comparação entre o VFC aplicado a (a) nuvem de pontos em relação aos (b) limites da imagem.....	62

Figura 4.8 – Sistema de coordenadas da câmara no (a) Agisoft Metashape e (b) no VFC.....	63
Figura 4.9 – Análise de um ponto de vista; teste do operador na nuvem de pontos variando o parâmetro (ε) como: (a) $\varepsilon=1$, (b) $\varepsilon=2$, (c) $\varepsilon=3$ e (d) $\varepsilon=4$ para o cafeeiro.....	64
Figura 4.10 – Análise de uma pequena área da (a) imagem escolhida como ponto de vista, sendo (a) a visão da remoção de pontos oclusos e (b) os pontos oclusos de outro ponto de vista.....	64
Figura 4.11 – Subdivisão em partes menores.....	65
Figura 4.12 – Recorte do VFC com $\varepsilon = 4$ e a subtração com o VFC da macieira, representados os pontos oclusos (preto) e visíveis (cinza).....	65
Figura 4.13 – A nuvem LiDAR RGB (430 nm, 550 nm, 650 nm) para o cafeeiro.....	66
Figura 4.14 – Exemplo de alvo que mudou de posição entre as coletas do LiDAR e câmara, em (a) a imagem capturada, (b) a nuvem de pontos e (c) a colorização.....	67
Figura 4.15 – (a) Imagem original, (b) nuvem colorida com recorte do VFC e (c) com recortes menores.....	68
Figura 4.16 – Folhas colorizadas em áreas de sobreposição entre as imagens: (a) 9010 e 9016; (b) 9016 e 9024; (c) 9024 e 9049; (d) 9049 e 9059; (e) 9059 e 9057; (f) 9148 e 9100.....	68
Figura 4.17 – Nuvens multiespectrais para os quadrantes: (a) Q1, (b) Q2, (c) Q3, (d) Q4, (e) Q5 e (f) Q6.....	69
Figura 4.18 – Alvos colorizados em sobreposição entre as imagens orientadas 7345/7350 e 7375/7417, nos quadrantes: (a) Q1, (b) Q2, (c) Q3, (d) Q4, (e) Q5 e (f) Q6.....	69
Figura 4.19 – Movimento das folhas notado no topo da árvore colorizadas para os quadrantes: (a) Q1, (b) Q2, (c) Q3, (d) Q4, (e) Q5 e (f) Q6.....	70
Figura 4.20 – Folhas no topo da árvore colorizadas para os quadrantes: (a) Q1, (b) Q2, (c) Q3, (d) Q4, (e) Q5 e (f) Q6.....	70
Figura 4.21 – Modelo completo da (a) nuvem colorida (Q4) e as (b) cores com a representação da contribuição individual das imagens.....	71
Figura 4.22 – Discrepâncias entre pontos medidos nas nuvens LiDAR e óptica em um cafeeiro.....	72
Figura 4.23 – Nuvem de pontos colorizada de uma folha para os quadrantes: (a) Q1, (b) Q2, (c) Q3, (d) Q4, (e) Q5 e (f) Q6.....	73
Figura 4.24 – Exemplo de folhas para os quadrantes (a) Q2 e (b) Q6.....	74
Figura 4.25 – Discrepâncias entre pontos medidos nas nuvens LiDAR e óptica na macieira.....	74
Figura 4.26 – Deslocamento acentuado entre dois pontos de vista (p1 e p2) da nuvem de pontos para as bandas: (a) 490 nm (Q5), (b) 525 nm (Q2), (c) 550 nm (Q4), (d) 560 nm (Q6), (e) 570 nm (Q1) e (f) 850 nm (Q3).....	75

LISTA DE TABELAS

Tabela 3.1 – Especificações da câmara de quatro lentes.....	40
Tabela 3.2 – Escolha dos tempos de exposição.....	44
Tabela 4.1 – RMSE total dos pontos de controle do primeiro conjunto de dados.	54
Tabela 4.2 – Erros dos pontos de verificação do primeiro conjunto de dados para o Q4.	54
Tabela 4.3 – Teste t-student para a banda 550 nm do Q4.....	54
Tabela 4.4 – RMSE total dos pontos de controle do segundo conjunto de dados.....	56
Tabela 4.5 – Erros nos pontos de verificação do segundo conjunto de dados.....	56
Tabela 4.6 – Teste t- <i>student</i> para as bandas do segundo conjunto de dados.....	57
Tabela 4.7 – Média dos erros nos registros entre nuvens.....	60
Tabela 4.8 – RMSE das discrepâncias entre as coordenadas do LiDAR e nuvem densa das bandas no cafeeiro.....	72
Tabela 4.9 – RMSE das discrepâncias entre as coordenadas do LiDAR e nuvem densa das bandas na macieira.....	74

SUMÁRIO

1.	INTRODUÇÃO	14
1.1	Objetivos	17
1.2	Organização do documento.....	17
2.	REVISÃO DA LITERATURA.....	18
2.1	Fundamentos de LiDAR	18
2.1.1	Filtragem de pontos espúrios.....	19
2.2	Geometria das imagens ópticas.....	21
2.2.1	Orientação Interior.....	21
2.2.2	Orientação Exterior	24
2.3	Fototriangulação e Integração de Sensores	25
2.3.1	Análise da visibilidade em nuvem de pontos	26
2.3.1.1	Filtragem de pontos fora do volume de visualização da câmara (Culling)	28
2.3.2	Algoritmos para mapas de visibilidade	30
2.3.2.1	Rotulação de pontos oclusos	32
2.3.3	Atribuição de valores espectrais à nuvem de pontos.....	34
2.3.3.1	Interpolação de tons de cinza	34
2.3.4	Ajuste radiométrico	36
2.4	Avaliação da qualidade para a nuvem colorida	37
3.	MATERIAIS E MÉTODOS	39
3.1	Materiais	39
3.2	Conjunto de dados	41
3.3	Método proposto.....	43
3.3.1	Design de aquisição dos dados	44
3.3.2	Filtragem de ruídos da nuvem LiDAR.....	46
3.3.3	Fototriangulação no Agisoft Metashape	46
3.3.4	Rotulação da oclusão de nuvem de pontos	48
3.3.4.1	Subdivisão da nuvem de pontos.....	50
3.3.5	Colorização da nuvem densa	50
3.3.6	Compatibilização radiométrica.....	51
3.4	Análises dos resultados.....	52
4.	EXPERIMENTOS E RESULTADOS	53
4.1	Processamentos iniciais	53
4.1.2	Filtragem de pontos espúrios	57

4.1.3	Registro da nuvem LiDAR	59
4.2	Nuvem de pontos colorida	60
4.2.1	Recorte da nuvem de pontos	60
4.2.1.1	Orientação dos eixos	62
4.2.3	Colorização.....	66
4.2.3.1	Modelo completo	71
4.3	Discussão	71
5.	CONCLUSÕES E RECOMENDAÇÕES.....	76
	REFERÊNCIAS BIBLIOGRÁFICAS	78

1. INTRODUÇÃO

O avanço das pesquisas em agricultura digital tem sido impulsionado pelo desenvolvimento de técnicas voltadas à análise de dados agrícolas. Essa abordagem, mais ampla, envolve o uso de sensores digitais e sistemas de informação com o objetivo de auxiliar nas tomadas de decisão relacionadas à gestão agrícola (Keogh; Henry, 2016). Em um contexto mais específico, a agricultura de precisão utiliza ferramentas tecnológicas como o *Global Navigation Satellite System* (GNSS), sensores de solo e monitores de rendimento (Zhang et al., 2017). Uma das aplicações beneficiadas pelas tecnologias digitais é a fenotipagem, que realiza a análise das características fisiológicas, bioquímicas e morfológicas das plantas (Sun et al., 2022).

De acordo com Rivera et al. (2023), a agricultura digital emprega técnicas avançadas de sensoriamento remoto e análise de imagens capturadas por sensores aéreos e terrestres, para medir atributos morfológicos, como altura e área foliar. Além disso, métodos de monitoramento de culturas avaliam a saúde vegetal e a biomassa em campos agrícolas, enquanto a modelagem de árvores e arbustos permite o mapeamento e a análise detalhada de estruturas vegetais e densidade de folhagem (Rivera et al., 2023). Entretanto, a avaliação das características das plantas enfrenta desafios significativos, especialmente devido à complexidade das estruturas vegetais e à variação fenotípica ao longo do crescimento, que dificultam a obtenção de dados precisos. Aspectos como a inclinação e a deformação das folhas, bem como a interação entre a planta e a iluminação, podem comprometer a integridade das medições baseadas em imagens (Xie et al., 2023). Por outro lado, o LiDAR (*Light Detection and Ranging*) emerge como uma técnica avançada, proporcionando uma captura detalhada de informações espaciais e oferecendo soluções robustas para mitigar esses desafios na agricultura digital.

As nuvens LiDAR são reconhecidas pela alta qualidade geométrica e confiabilidade, mas carecem de informações espectrais para a descrição de superfícies tridimensionais e extração completa de características fenotípicas das plantas. Em contrapartida, o uso exclusivo de uma câmara óptica para reconstrução da superfície resulta em nuvens tridimensionais processadas com alta densidade de pontos e informações espectrais, porém sujeitas a presença de sombras e oclusões (Gharibi; Habib, 2018). Os pulsos LASER (*Light Amplification by Stimulated Emission of Radiation*) conseguem atravessar a vegetação, proporcionando visibilidade eficaz mesmo em áreas sombreadas, como o fundo da copa. Um

método comum adotado por escâneres terrestres comerciais de alto custo é a incorporação de uma câmara digital aos equipamentos, como o sensor da RIEGL VZ-400 ou o FARO Focus Premium.

A fusão da nuvem de pontos tridimensionais coletada pelo escâner LASER com informações espectrais, capturadas por uma câmara óptica, permite gerar um produto que pode ser denominado nuvem LiDAR RGB (*Red, Green, Blue*) e/ou multiespectral. Segundo Seitz e Dyer (1999), na comunidade de visão computacional, o produto é conhecido como fotorrealismo, e caracterizado por reconstruir tridimensionalmente cenas reais com as reprojeções contendo informações suficientes de cor e textura para reproduzir com precisão as imagens da cena, considerando uma ampla quantidade de pontos de vista do alvo. Existem alguns desafios para realizar a fusão de dados de diferentes sensores: a discrepância na cobertura espacial e orientação das imagens, divergência na escala de observação (tamanho do pixel vs *footprint* do LiDAR), coleta de dados não síncronos e as diferenças nas condições de aquisição (atitude e ângulo de visão), o que causa um descompasso entre a atribuição de cor (câmara óptica) e estrutura (escâner LASER) (Hudak et al., 2002; Popescu; Wynne, 2004; Mundt; Streutker; Glenn, 2006; Geerling et al., 2007; Anderson et al., 2008; Kampe et al., 2010; Packalén; Suvanto; Maltamo, 2009).

A integração de dados de diferentes sensores, por exemplo, pela combinação de dados LiDAR com sensores multiespectrais leves e com resolução espacial elevada, pode ser benéfica. Câmaras multiespectrais portáteis, como a Micasense e a Mapir Survey3W, têm-se destacado por sua capacidade de capturar imagens detalhadas em múltiplas bandas espectrais, facilitando uma análise mais abrangente das características vegetais. Outro exemplo recente é a câmara desenvolvida pela empresa Agrowing (Agrowing, 2024) com seis lentes com filtros espectrais para coletar imagens. A câmara faz o disparo sincronizado e a exposição simultânea das bandas (Tommaselli et al., 2020), possibilitando a representação dos NDs (Número Digitais) para cada banda conforme as propriedades físicas e químicas dos alvos. Atualmente, existem também escâneres multiespectrais que permitem capturar informações na superfície terrestre detalhadamente em diferentes faixas do espectro (Okhrimenko; Coburn; Hopkinson, 2018). Entretanto, a adoção destes sistemas é geralmente limitada, devido aos altos custos.

Integrar sensores para obter um produto LiDAR multiespectral, usando o LiDAR em conjunto com uma câmara multiespectral leve, é uma possibilidade viável. Um aspecto fundamental desse processamento consiste em assegurar a orientação rigorosa entre o modelo

3D e as imagens. A coleta com o LiDAR e a câmara ocorre de forma não síncrona e com pontos de apoio no ambiente. A câmara deve ser posicionada em diferentes posições planimétricas e altimétricas, assumindo múltiplas perspectivas, para abranger todo o campo de visão do LiDAR. A compatibilização geométrica definirá a posição da câmara em relação à nuvem de pontos por meio da fototriangulação, permitindo a projeção dos valores espectrais na nuvem e a atribuição dos números digitais (ND) aos pontos visíveis (Crombez; Caron; Mouaddib, 2015). Para isso, é necessário um processo de detecção de oclusões, destinado a identificar e rotular os pontos oclusos na nuvem LiDAR e não ocorrer duplo mapeamento na fusão dos dados (GHARIB e HABIB, 2018). O problema de duplo mapeamento refere-se à sobreposição ou duplicação de informações, resultando em ambiguidade na cena devido ao mesmo alvo ser mapeado a partir de diferentes perspectivas (Nielsen, 2004). O efeito fantasma emerge como consequência direta desse fenômeno, no qual o objeto é registrado em múltiplas localizações na nuvem de pontos. Esse efeito manifesta-se como contornos duplicados, criando representações semelhantes a "fantasmas" do objeto original. Em um modelo tridimensional, a presença do mesmo ponto tomado por pontos de vista diferentes compromete a fidelidade da representação. Há um grande conjunto de trabalhos sobre detecção e remoção ou rotulação de pontos oclusos com diferentes abordagens contribui para aprimorar a técnica no processamento (Appel, 1968; Catmull, 1974; Whitted, 1979; Fuchs; Kedem; Naylor, 1980; Directmodel, 1990; Blinn, 1993; Cohen-Or et al., 2003; Katz; Tal; Basri, 2007).

Dentro deste contexto, o presente projeto de pesquisa visou investigar e desenvolver uma sequência de processamento para a fusão da nuvem LiDAR terrestre com imagens multiespectrais. A abordagem proposta assemelha-se em partes ao roteiro de Crombez et al. (2015) que destaca a estimativa da posição da câmara como fundamental para a criação de uma nuvem de pontos LiDAR colorida, de modo a permitir a projeção dos NDs na nuvem de pontos com aplicação em patrimônios arquitetônicos. Além disso, o método proposto permite a projeção eficiente das informações espectrais nos pontos da nuvem 3D, reduzindo o custo computacional e evitando a duplicação de dados no mapeamento. O resultado é a geração de uma nuvem de pontos multiespectral. Esses dados são essenciais para estudos voltados à melhoria da produtividade agrícola, à detecção de doenças em culturas e à otimização da nutrição das plantas.

1.1 Objetivos

O objetivo principal deste projeto de pesquisa é desenvolver uma estratégia para atribuir valores espectrais aos pontos visíveis da nuvem tridimensional coletada por um sensor LiDAR. A abordagem visa avaliar o fluxo de processamento para a geração de uma nuvem de pontos multiespectral.

Os objetivos específicos do projeto de pesquisa são:

- Compatibilizar geometricamente dados LiDAR e as imagens de uma câmara multiespectral;
- Implementar técnicas para otimizar o fluxo de processamento e reduzir o custo computacional;
- Mitigar o problema de duplo mapeamento e rotular pontos oclusos na nuvem tridimensional;
- Avaliar fatores que afetam a qualidade da nuvem de pontos com atributos multiespectrais.

1.2 Organização do documento

O documento inicia com uma introdução ao projeto, seguida de cinco seções estruturadas. A Seção 2 apresenta a Revisão de Literatura, abrangendo temas fundamentais para a pesquisa, como as bases teóricas e aplicações do LiDAR e câmaras, além das técnicas aplicadas de fototriangulação de imagens, recorte da nuvem LiDAR utilizando o volume de visualização da câmara, detecção de pontos oclusos, colorização e compatibilização radiométrica dos dados. A Seção 3 aborda a metodologia e os métodos adotados, detalhando os dados coletados, os processos de aquisição e a implementação dos algoritmos, com ênfase nas técnicas de *Viewing Frustum Culling*, *Hidden Points Removal* e na colorização baseada em modelos matemáticos de Fotogrametria. A Seção 4 apresenta os experimentos realizados, as métricas utilizadas para avaliação, e a discussão dos resultados obtidos. A Seção 5 finaliza com as conclusões do estudo.

2. REVISÃO DA LITERATURA

A Seção 2 aborda os fundamentos do LiDAR e a geometria das imagens ópticas. A Subseção 2.1 trata dos conceitos básicos de LiDAR, incluindo a filtragem de pontos espúrios (Seção 2.1.1). Em seguida, a Seção 2.2 apresenta a geometria das imagens, destacando a orientação interior (Seção 2.2.1) e exterior (Seção 2.2.2). A Seção 2.3 explora a fototriangulação e a integração de sensores, incluindo a análise de visibilidade (Seção 2.3.1), rotulação de pontos fora do volume de visualização (Seção 2.3.1.1), algoritmos para mapas de visibilidade (Seção 2.3.2), rotulação de pontos oclusos (Seção 2.3.2.1), atribuição de valores espectrais (Seção 2.3.3), interpolação de tons de cinza (Seção 2.3.3.1) e o ajuste radiométrico (Seção 2.3.4).

2.1 Fundamentos de LiDAR

O LiDAR tem como fonte de energia os feixes de LASER, emitidos em direção à superfície alvo, sendo parte do sinal refletido para o sensor. A coleta dos dados compreende a medida do intervalo de tempo transcorrido, desde a emissão do pulso até o retorno pela reflexão do alvo, sendo a medida empregada no cálculo da distância entre o sensor e o objeto, sendo também medida a intensidade do sinal refletido (Baltsavias, 1999).

O LiDAR é um sensor remoto ativo capaz de emitir pulsos LASER e receber os sinais de retorno. Em conjunto com um sistema de varredura e decodificadores de ângulos digitais, permite o cálculo das coordenadas cartesianas dos pontos, obtendo-se uma nuvem de pontos 3D (Tommaselli, 2003). É comum chamar os sistemas de varredura a LASER, tanto aéreos como terrestres e móveis, apenas de LiDAR. Segundo Rivera et al. (2023), os sistemas aéreos (ALS – *Airborne Laser Scanner*) são montados em veículos aéreos, podendo ser tripulados ou não tripulados. Por outro lado, o terrestre (TLS – *Terrestrial Laser Scanner*) depende de um suporte estacionário e requer várias varreduras em posições diferentes para reconstruir uma nuvem de pontos completa. Os sistemas terrestres móveis (*Mobile Laser Scanner*) podem ser instalados em uma variedade de veículos, desde tratores até mochilas.

2.1.1 Filtragem de pontos espúrios

Segundo Hu et al. (2022), o levantamento de campo com equipamentos TLS é frequentemente afetado por ruídos provenientes de vários fatores, como poeira no ar, movimentação de pessoas, insetos e efeitos naturais como o vento, podendo resultar em deformações na representação do objeto. Além disso, ao aumentar a resolução do LiDAR em uma coleta ao ar livre e com vento, a movimentação de feições não estáticas pode resultar na ocorrência de *outliers*, devido ao acúmulo de múltiplas medições em um único ponto. A filtragem de pontos espúrios, como ruídos e *outliers*, torna-se necessária para aprimorar a qualidade dos dados. Os ruídos são variações aleatórias e os *outliers* são valores extremos, significativamente diferentes dos demais. Nesse contexto, técnicas de reconstrução de superfície podem ser usadas na remoção de pontos espúrios, como, por exemplo: funções implícitas, que são capazes de definir superfícies ou curvas no espaço tridimensional; triangulação de Delaunay; *Statistical Learning* e *Moving Least Squares*.

Hoppe et al. (1992) estudaram a possibilidade de representar superfícies por meio de funções implícitas. O método consiste em duas etapas: primeiro, estimam-se as normais locais usando análise de componentes principais e ajustam-se suas orientações usando um grafo de vizinhança para garantir consistência. Basicamente, os nós vizinhos são conectados por arestas, formando uma rede que analisa as relações locais na orientação das normais durante a reconstrução de superfícies. Em seguida, aplica-se o algoritmo de *Marching Cubes* (Lorensen; Cline, 1998) para reconstruir a superfície, criando uma malha triangular a partir de uma *Signed Distance Function* (SFD) definida pelas normais ajustadas. O SFD é uma função que fornece a menor distância de um ponto a uma superfície, com um sinal indicando se o ponto está dentro (valor negativo) ou fora (valor positivo) da superfície. Assim, a combinação destes métodos contribui para a suavização dos ruídos.


Amenta et al. (1998) introduziram o uso da técnica de Delaunay para reconstrução de superfícies, baseado na reconstrução topológica para recuperar a estrutura geométrica e conexões entre elementos. No entanto, a abordagem é sensível a ruídos. Mederos et al. (2005) aprimoraram a metodologia ao filtrar ruídos por meio da densidade mínima de amostragem e no tamanho local das características.

Diebel et al. (2006) sugerem aplicar modelos de *Statistical Learning*. O método estabelece uma estrutura bayesiana para reconstruir malhas triangulares ruidosas. A reconstrução assume que os ruídos no processo de reconstrução da malha seguem a distribuição

gaussiana. O modelo é ajustado a partir das características da superfície, com o objetivo de otimizar e maximizar a probabilidade de uma reconstrução fiel aos dados originais.

A técnica *Moving Least Squares* (MLS), têm se destacado na literatura para o processamento de nuvens de pontos coletadas em ambiente de vegetação. O MLS é reconhecido por sua capacidade de suavizar localmente os dados, preservando características irregulares (Alexa et al., 2003; Fleishman; Cohen-Or; Silva, 2005; Shen; O'Brien; Shewchuk, 2004). O filtro estatístico MLS ajusta uma superfície utilizando um operador de projeção, o qual é uma função matemática capaz de suavizar e estimar a superfície a partir dos pontos da nuvem tridimensional. No processo de ajuste, *outliers* são removidos e a superfície é suavemente segmentada localmente (Jenke et al., 2006). A Figura 2.1 apresenta como funciona a técnica.

Figura 2.1 – Ajuste por MLS para remoção de ruídos.



Fonte: Alexa et al. (2003)

Segundo Alexa et al. (2003) o procedimento de projeção MLS pode ser descrito da seguinte forma: inicialmente, para o ponto r (ponto roxo) cria-se um plano de referência local (H). O plano H é definido a partir de pontos vizinhos p_i , a vizinhança considera o conjunto de pontos que minimiza a soma ponderada das distâncias quadradas desses pontos ao plano. A projeção de r sobre o plano, calculada a partir da normal (n), resulta em q (ponto vermelho). Em seguida, uma superfície polinomial local g é calculada, ajustando as alturas dos pontos p_i em relação ao plano H . Neste ajustamento, cada ponto p_i recebe um peso em função da distância em relação a q , de modo que a projeção final de r sobre a curva g resulte no ponto azul, obtido a partir da superfície polinomial ajustada. Os pontos mais distantes recebem pesos mais baixos, assim, estes são considerados ruídos. Além disso, também é possível definir um limite de

influência dos pontos, baseado em uma certa distância. Com os pontos filtrados, haverá uma melhora na interpretação dos dados coletados, especialmente quando combinada com informações espectrais das imagens ópticas.

2.2 Geometria das imagens ópticas

As imagens capturadas por câmaras digitais são definidas por propriedades radiométricas e geométricas. As características radiométricas englobam a resposta da câmara em termos de intensidade de pixel e contraste, enquanto as características geométricas envolvem a projeção perspectiva e as distorções ópticas. Essas distorções incluem aberrações e distorções das lentes, as quais devem ser compensadas para assegurar a fidelidade dos dados capturados. O estudo sobre a geometria das imagens ópticas é essencial no processamento das imagens, permitindo a correção das distorções e a determinação precisa dos Parâmetros de Orientação Interior (POIs) no processo de calibração das câmaras.

2.2.1 *Orientação Interior*

Segundo Andrade (1998), a Orientação Interior (OI) ou interna refere-se à operação relativa à recuperação da posição da imagem em relação ao Centro Perspectivo (CP) da câmara. O procedimento consiste na reconstrução dos feixes de raios no momento da aquisição da fotografia.

Os POIs são geralmente determinados no processo de calibração de câmara, empregando a técnica de ajustamento por Método dos Mínimos Quadrados (MMQ) para a estimativa dos parâmetros responsáveis por descrever as características geométricas e ópticas da câmara: distância focal (f); coordenadas do ponto principal (x_0, y_0); coeficientes de distorção radial simétrica (k_1, k_2 e k_3) e de distorção descentrada (P_1 e P_2).

A mudança na origem do sistema imagem (coluna, linha) para um sistema intermediário ocorre por meio da translação nos eixos e reflexão do eixo y , resultando em um sistema de coordenadas com a origem no centro da imagem. Em seguida, a escala é ajustada através da conversão na unidade de medida de pixels para milímetros. A translação do sistema imagem para o intermediário inicia-se com o cálculo do centro geométrico da imagem (C_x, C_y)

(Equações 2.1 e 2.2). As Equações 2.3 e 2.4 descrevem a transformação para o sistema fotogramétrico, considerando a redução para o ponto principal (pp) (origem), cujos valores são determinados após o processo de calibração da câmara e representam a projeção ortogonal do CP sobre o plano da imagem.

$$C_x = \frac{N_c - 1}{2} \quad (2.1)$$

$$C_y = \frac{N_l - 1}{2} \quad (2.2)$$

sendo:

N_c e N_l representam a quantidade de colunas e linhas da imagem, respectivamente.

$$x = (Col - C_x) \text{ tam}_{\text{pixel}} - x_0 \quad (2.3)$$

$$y = -(\text{Lin} - C_y) \text{ tam}_{\text{pixel}} - y_0 \quad (2.4)$$

em que:

x, y são as coordenadas da imagem no sistema fotogramétrico;

$\text{tam}_{\text{pixel}}$ é o tamanho do pixel;

Col, Lin representa as coordenadas dos pontos medidos na imagem;

x_0 e y_0 são as coordenadas do ponto principal.

Após a redução ao ponto principal, os erros sistemáticos causados pelas distorções radial simétrica e descentrada devem ser corrigidos. A distorção radial simétrica resulta em desvios nos raios de luz ao atravessarem a lente, impactando uniformemente os pontos na imagem a partir do ponto principal de simetria. Em contrapartida, a distorção descentrada tem origem no processo de fabricação das lentes e decorre do desalinhamento dos eixos ópticos (Galo; Tommaselli, 2011).

O efeito da distorção radial simétrica é calculado (Equações 2.5 e 2.6) baseado nos modelos desenvolvidos por Conrady (1919) e Brown (1966). As influências derivadas da distorção descentrada podem ser estimadas com as Equações 2.8 e 2.9. Por fim, o refinamento das coordenadas é efetuado por intermédio das Equações 2.10 e 2.11.

$$\Delta_x = x (k_1 r^2 + k_2 r^4 + k_3 r^6) \quad (2.5)$$

$$\Delta_y = y (k_1 r^2 + k_2 r^4 + k_3 r^6) \quad (2.6)$$

em que:

Δ_x e Δ_y representam o deslocamento radial de um ponto qualquer de coordenadas (x,y);

k_1, k_2, k_3 são os coeficientes da distorção radial simétrica.

O parâmetro r representa a distância entre o ponto (x,y) e o ponto principal (x_0, y_0), conforme a representação da Equação 2.7. As Equações 2.10 e 2.11 são as coordenadas corrigidas no sistema fotogramétrico.

$$r = \sqrt{\Delta x^2 + \Delta y^2} \quad (2.7)$$

$$\delta_x = P_1(r^2 + 2x^2) + 2P_2xy \quad (2.8)$$

$$\delta_y = P_2(r^2 + 2y^2) + 2P_1xy \quad (2.9)$$

sendo:

δ_x e δ_y efeito da distorção descentrada em x e y;

P_1, P_2 são os coeficientes da distorção.

$$x_f = x - \Delta_x - \delta_x \quad (2.10)$$

$$y_f = y - \Delta_y - \delta_y \quad (2.11)$$

sendo:

x_f e y_f as coordenadas fotogramétricas após as devidas correções.

Segundo Galo e Tommaselli (2011), existem outros fatores inerentes ao sistema óptico passíveis de correção. Os fatores englobam: os parâmetros de afinidade, deformações relacionadas à planura do sensor, bem como no plano imagem. Lugnani (1987) destaca a adição do componente de refração atmosférica. Entretanto, a refração provoca efeitos pequenos e praticamente desprezíveis para imagens de curta distância.

2.2.2 Orientação Exterior

A Orientação Exterior (OE) define a posição e atitude da câmara associadas a cada imagem, em relação a um referencial terrestre (Andrade, 1998). A relação entre a posição da câmara com o terreno é estabelecida com o conhecimento de seis parâmetros: os ângulos de Euler (ω , φ e κ), responsáveis por descrever os movimentos angulares da plataforma da câmara, juntamente com três coordenadas do CP (X_0 , Y_0 e Z_0), referente às translações em relação ao sistema de referência terrestre. A determinação dos Parâmetros de Orientação Exterior (POEs) é fundamentada na condição de colinearidade, que relaciona as coordenadas de um ponto no espaço objeto e espaço imagem (Galo e Tommaselli, 2011).

Andrade (1998) descreve um processo de determinação da orientação exterior em dois estágios interdependentes: Orientação Relativa (OR) e Orientação Absoluta (OA). A OR estabelece a orientação espacial de uma imagem em relação a outra, com base na posição e atitude, sem referenciar o sistema terrestre. Em contrapartida, a OA define a posição, escala e atitude da imagem em relação ao sistema de coordenadas terrestre. Na Orientação Integrada ou Simultânea, os cálculos são realizados simultaneamente, resultando na fototriangulação.

A fototriangulação é descrita por Lugnani (1987) como o processo de determinação indireta da posição e orientação dos feixes de raios presentes nas imagens, em conjunto com as precisões obtidas no ajuste em bloco pelo MMQ, baseado nas informações dos pontos de controle e equações de colinearidade. As equações de colinearidade (Equações 2.12 e 2.13) permitem determinar as coordenadas do ponto na imagem, com os dados de OI e OE. As equações de colinearidade na forma inversa permitem calcular as coordenadas (X,Y) no terreno, com base nas coordenadas da imagem (Equações 2.14 e 2.15) e da coordenada Z do ponto.

$$x = -f \frac{m_{11}(X-X_0) + m_{12}(Y-Y_0) + m_{13}(Z-Z_0)}{m_{31}(X-X_0) + m_{32}(Y-Y_0) + m_{33}(Z-Z_0)} \quad (2.12)$$

$$y = -f \frac{m_{21}(X-X_0) + m_{22}(Y-Y_0) + m_{23}(Z-Z_0)}{m_{31}(X-X_0) + m_{32}(Y-Y_0) + m_{33}(Z-Z_0)} \quad (2.13)$$

sendo:

x e y são as coordenadas dos pontos na imagem no referencial fotogramétrico;

f é a distância focal da câmara;

X, Y e Z são as coordenadas do ponto no terreno;

m_{ij} são os elementos da matriz de rotação passiva;

X_0 , Y_0 e Z_0 são as coordenadas do CP no referencial cartesiano do espaço objeto.

$$X = X_0 + (Z - Z_0) \frac{m_{11} x + m_{21} y - m_{31} f}{m_{13} x + m_{23} y - m_{33} f} \quad (2.14)$$

$$Y = Y_0 + (Z - Z_0) \frac{m_{12} x + m_{22} y - m_{32} f}{m_{13} x + m_{23} y - m_{33} f} \quad (2.15)$$


Os elementos da matriz de rotação passiva (m_{ij}) podem ser definidos por uma sequência $R_Z(\kappa)R_Y(\varphi)R_X(\omega)$ resultando em:

$$\begin{aligned} m_{11} &= \cos\varphi \cos\kappa \\ m_{12} &= \cos\omega \sin\kappa + \sin\omega \sin\varphi \cos\kappa \\ m_{13} &= \sin\omega \sin\kappa - \cos\omega \sin\varphi \cos\kappa \\ m_{21} &= -\cos\varphi \sin\kappa \\ m_{22} &= \cos\omega \cos\kappa - \sin\omega \sin\varphi \sin\kappa \\ m_{23} &= \sin\omega \cos\kappa + \cos\omega \sin\varphi \sin\kappa \\ m_{31} &= \sin\varphi \\ m_{32} &= -\sin\omega \cos\varphi \\ m_{33} &= \cos\omega \cos\varphi \end{aligned}$$

2.3 Fototriangulação e Integração de Sensores

A integração dos sensores (câmara e LiDAR) requer a compatibilização dos dados em um mesmo referencial. A fototriangulação apresenta-se como um método que permitiria esta concatenação dos dados, garantindo o mesmo referencial para ambos os sensores. Na Figura 2.2, o (CP) representa o centro perspectivo da câmara, (pp) o ponto principal, (o) a origem do sistema de coordenadas da nuvem de pontos, (p) o ponto de interesse da imagem projetado na nuvem 3D (P) e os dois sistemas de coordenadas (X,Y,Z) da nuvem de pontos e (x,y,z) da foto.

Figura 2.2 – Sistema de coordenadas da imagem e da nuvem LiDAR.



Antes de atribuir valores espectrais a nuvem de pontos LiDAR, deve-se evitar o duplo mapeamento. Deste modo, é necessária uma etapa prévia para rotular os pontos oclusos na nuvem LiDAR. O tema é explorado nas próximas seções com métodos de detecção de pontos oclusos, a partir de análises da visibilidade de nuvem de pontos.

2.3.1 *Análise da visibilidade em nuvem de pontos*

A projeção dos valores espectrais de uma imagem para uma nuvem de pontos requer posição e orientação rigorosas do observador (definidas pela Orientação Exterior das imagens) em relação à nuvem 3D. Para cada posição em que a imagem é adquirida, a nuvem de pontos é avaliada. Os elementos da nuvem de pontos dentro do campo de visão da câmara são considerados visíveis, enquanto aqueles fora desse limite não aparecem na imagem e são descartados. Além disso, alguns pontos dentro do campo de visão podem estar ocultos por outros elementos na cena devido ao ponto de vista da câmara, exigindo um processo de identificação e rotulagem desses pontos oclusos. Assim, garante-se a consistência na representação tridimensional e integridade dos dados, ao evitar sobreposição de informações capturadas de múltiplas perspectivas. Um ponto será visível a partir de um determinado ponto de vista quando não há obstruções de outros pontos ou objetos. Em Computação Gráfica, o cálculo da visibilidade torna-se complexo em cenas com múltiplos objetos (Ghosh, 2007). O

mesmo problema é discutido em áreas como Visão Computacional, Fotogrametria, Robótica e Arquitetura.

A determinação de superfícies ocultas é estudada na Computação Gráfica devido à necessidade de renderizar imagens de forma eficaz, garantindo que objetos obstruídos por outros à frente, não sejam visualizados. As técnicas de visibilidade podem ser estendidas a aplicações em nuvens de pontos. O problema é abordado por meio de métodos de *pipeline* gráfico ou de renderização (Bittner; Wonka, 2003), os quais envolvem múltiplas etapas.

A definição de um sistema de coordenadas é a primeira etapa. Embora seja estabelecido um sistema de coordenadas arbitrário durante a aquisição das nuvens de pontos LiDAR, o processamento não garante automaticamente um perfeito alinhamento entre todas as varreduras. Os desalinhamentos exigem processos adicionais de registro ou ajuste para garantir uma representação unificada da nuvem de pontos em um referencial único. Na segunda etapa, a posição do observador em relação à cena 3D é estimada o que implica em definir as coordenadas do centro perspectivo e a orientação da câmara.

Após a definição da posição do observador (posição e orientação da câmara), os pontos são projetados do espaço imagem para o espaço objeto. Essa projeção prepara os dados para a aplicação de técnicas que detectam o conteúdo não visível do ponto de vista da câmara. Esse processo viabiliza o uso de métodos como *Viewing Frustum Culling* (Seção 2.4.1.1), responsável por eliminar objetos fora do campo de visão, *Backface Culling* (Blinn, 1993), utilizado para descartar superfície voltadas para o lado oposto à câmara, e *Occlusion Culling* (Cohen-Or et al., 2003), empregado para ocultar pontos bloqueados por outros mais próximos. O resultado acelera processos subsequentes. Por fim, a última etapa inclui a geração de um mapa de visibilidade.


A seção seguinte apresentará o algoritmo *culling* utilizado no presente trabalho, responsável por determinar quais primitivas devem ser aceitas ou rejeitadas antes da visualização (Bittner; Wonka, 2003). As primitivas representam os elementos que formam o desenho ou objeto 3D, por exemplo, vértices, arestas, faces e polígonos. Além disso, serão abordados algoritmos relacionados à criação de mapas de visibilidade (Seção 2.4.2) e um algoritmo específico para rotulação de pontos oclusos (Seção 2.4.2.1).

2.3.1.1 Filtragem de pontos fora do volume de visualização da câmara (Culling)

Os algoritmos de *Viewing Frustum Culling* (VFC) descartam pontos fora do volume visível da câmara (Figura 2.3), delimitado por seis planos que definem o campo de visão (Assarsson; Moller, 2000). Embora conceitualmente descrito como remoção, esse processo consiste em rotular os pontos como oclusos para o ponto de vista específico da câmara, sem excluí-los permanentemente da nuvem de dados. Essa abordagem reduz o custo computacional ao restringir o processamento apenas aos pontos dentro do volume de interesse.

A forma tridimensional gerada por um algoritmo de VFC é composta por seis planos, dois dos quais são paralelos entre si e normais ao eixo óptico, conforme ilustrado na Figura 2.3. O *frustum*, pode ter uma representação geométrica ortogonal (formato de caixa) ou em perspectiva (formato de pirâmide truncada), que representa o volume de visão de uma câmara em um espaço 3D. De acordo com Pallister (2005), com o ângulo de visão (*Field of View* – FoV) horizontal e vertical, e as distâncias *near* e *far*, é possível obter os valores limitantes da câmara (esquerda, direita, cima e baixo). Além disso, deve-se informar a posição da câmara (X,Y,Z), com origem no CP. No âmbito da Fotogrametria, o eixo Z é representado como a altura da câmara. Por outro lado, na Visão Computacional, o eixo Z é representado como a profundidade.

Figura 2.3 – Esquematização do VFC (*frustum* traçado em vermelho) com: o centro da câmara, plano da imagem, o plano próximo (*near*), o plano distante (*far*) e os FoVs horizontal (α) e vertical (θ).




Fonte: Adaptado de Shi et al. (2018).

De acordo com Assarson e Möller (2000), um algoritmo VFC elimina nós do grafo da cena, que é uma estrutura hierárquica, construída em forma de árvore, e serve para organizar dados em modelos tridimensionais para Computação Gráfica. A árvore é composta por nós e arestas, formando um grafo dirigido e acíclico (DAG – *Directed Acyclic Graph*). O termo “dirigido” indica relações pai-filho unidirecionais, enquanto o “acíclico” impede a formação de ciclos fechados. O nó raiz (pai) é a base da estrutura (agrupa todos os objetos do ambiente) e os nós inferiores (filhos) organizam a geometria dos objetos (Akenine-Möller; Haines; Hoffman, 2008). Com a adição de mais nós inferiores na árvore do grafo de cena, uma representação mais detalhada da cena é alcançada. Cada nó inferior representa um objeto contendo um volume delimitador (*Bounding Volume* – BV). O BV do nó é testado em relação à interseção com o *frustum*: se estiverem totalmente dentro, são desenhados na renderização, se estiverem totalmente fora são descartados (Assarsson; Moller, 2000).

Os principais algoritmos de *Viewing Frustum Culling* (VFC) descritos na literatura são os de Bishop et al. (1998) e DirectModel (1990). A técnica de *culling* por *bounding volume* é abordada de duas formas para resolver o problema. Na primeira abordagem, calculam-se as matrizes de visualização e projeção da transformação em perspectiva (Equação 2.16) para os volumes delimitadores (*Bounding Volume* - BVs), definidos por caixas delimitadoras alinhadas ao eixo (AABB – *Axis Aligned Bounding Box*) ou orientadas (OBB – *Oriented Bounding Box*) (Figura 2.4).

Figura 2.4 – Caixas delimitadoras (a) alinhadas ao eixo e (b) orientadas.



Em seguida, são realizados testes para determinar se os BVs estão dentro do *frustum* de visualização. A segunda abordagem envolve o teste direto do BV contra os seis planos do *frustum*, realizando testes de aceitação ou rejeição. Caso o teste de interseção falhe, tornam-se necessários testes mais complexos.

$$s \begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = \begin{bmatrix} f_x & 0 & c_x & 0 \\ 0 & f_y & c_y & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} R & T \\ 0 & 1 \end{bmatrix} \begin{bmatrix} X \\ Y \\ Z \\ 1 \end{bmatrix} \quad (2.16)$$

em que:

s corresponde ao fator de escala;

u, v as coordenadas homogêneas da projeção 2D no plano da imagem;

f_x, f_y são valores correspondentes às distâncias focais. Como o pixel é quadrado, esses valores são iguais;

c_x, c_y as coordenadas do ponto principal (x_0, y_0) ;

R é a matriz de rotação;

X, Y, Z são as coordenadas homogêneas do ponto 3D no espaço objeto;

T são as translações, considerando a origem do sistema de terreno em relação ao sistema fotogramétrico, sendo:

$$\begin{bmatrix} T_x \\ T_y \\ T_z \end{bmatrix} = -R * \begin{bmatrix} X_0 \\ Y_0 \\ Z_0 \end{bmatrix} \quad (2.17)$$

O teste de interseção usual para verificar a visibilidade, baseado na primeira abordagem e amplamente utilizado na biblioteca PCL (Krishnan, 2023), envolve os vetores representados pelas direções dos eixos: *forward* (Z), *right* (X) e *up* (Y) (Figura 2.3). Inicialmente, testa-se o vetor *forward* nos limites *near* e *far*. Em seguida, verifica-se o vetor *right* para determinar a visibilidade à esquerda e à direita da câmara. Por fim, o vetor *up* é testado para verificar a visibilidade nas partes superior e inferior. Os pontos fora do campo de visão são descartados.

2.3.2 Algoritmos para mapas de visibilidade

Os algoritmos para criação de mapas de visibilidade, também conhecidos como métodos para remoção ou rotulação de superfícies ocultas, eliminam superfícies ou partes delas a partir de um determinado ponto de vista (centro perspectivo da imagem). Entre as técnicas frequentemente utilizadas estão *Z-Buffering*, *Binary Space Partitioning* (BSP), *Ray Casting*, *Ray Tracing* e *Hidden Points Removal* (HPR).

Catmull (1974) propôs o algoritmo de *Z-Buffering*, destinado a comparar o valor de profundidade de cada ponto em relação a um centro de projeção. Pontos em posições posteriores a outros são descartados; caso contrário, a posição é considerada visível e registrada na matriz *Z-Buffer*. Esse método é implementado no *hardware* das placas gráficas, necessitando apenas

de ativação. Quando duas superfícies ou objetos estão com valores de profundidade muito próximos o algoritmo tem dificuldade em determinar qual superfície deve ser renderizada na frente da outra, devido à limitação da quantidade bits para representar a profundidade, fenômeno denominado *Z-Fighting*.

Fuchs et al. (1980) propuseram o BSP para subdividir espaços em regiões convexas por meio de uma subdivisão recursiva. Essa técnica gera uma árvore representativa do espaço. A árvore BSP organiza os polígonos por profundidade e percorre-os, exigindo a especificação do ponto de vista. Cada nó da árvore possui dois filhos: o filho esquerdo contém os polígonos à frente, enquanto o filho direito abriga os polígonos atrás do plano de corte. A interseção entre o plano e o polígono divide-o em dois. No entanto, uma desvantagem dessa abordagem é o custo computacional para construir a árvore, além da limitação ao tratar com cenas dinâmicas.


Por fim, o método de *Ray Casting*, introduzido por Appel (1968), emprega raios emitidos a partir do centro de projeção. No campo da Computação Gráfica, esse método é usado como um passo para a geração de imagens foto-realísticas. O algoritmo utiliza um raio por pixel e busca o primeiro objeto interceptado por esse raio. Dessa forma, determina-se o sombreamento do objeto conforme as características das luzes da cena. Whitted (1979) apresentou o *Ray Tracing*, no qual os raios são traçados e interceptam os objetos da cena para coletar informações sobre a contribuição de cada fonte de luz. Além disso, o algoritmo considera raios recursivos para simular reflexões, refrações e sombreamentos em cada ponto interceptado. A recursão continua até que a contribuição se torne insignificante. Esses métodos resolvem implicitamente o problema de remoção ou rotulação de superfícies ocultas.

Todas as abordagens mencionadas anteriormente referem-se ao uso de técnicas para renderização, com a maioria presumindo que, no caso de nuvens de pontos, há uma amostragem adequada ou informações para estimar as normais. No entanto, o operador HPR consegue contornar esse problema de visibilidade sem precisar recorrer à renderização ou a informações adicionais da nuvem densa, além de oferecer garantias matemáticas sobre o algoritmo, conforme apresentado por Katz et al. (2007). Por esse motivo, o HPR foi escolhido para realização de testes em nuvens de pontos com vegetação.

2.3.2.1 Rotulação de pontos oclusos

Segundo Katz et al. (2007), o operador HPR pode determinar eficientemente os pontos visíveis ao extrair pontos localizados no *Convex Hull* (Fecho Convexo). A base teórica considera um conjunto de pontos P , sendo uma amostragem da superfície contínua (S) no ponto de vista (C). Deste modo, o operador determina se o ponto (p_i), $\forall p_i \in P$, é visível por C (observador/posição da câmara), em duas etapas. Na Figura 2.4.a tem-se a representação da nuvem de pontos (desenho azul — Figura 2.5.a) circunscrita por uma esfera de raio R (desenho de círculo verde — Figura 2.5.a) definido na primeira etapa.

Figura 2.5 – O operador HPR apresenta a (a) construção do problema e (b) os pontos detectados pelo *Convex Hull*, sendo o desenho em azul a nuvem de pontos original e em vermelho a representação dos pontos visíveis da região convexa apresentada em (a).



Fonte: Katz et al. (2007).

A primeira etapa é aplicar um espelhamento inverso, intitulado *Spherical Flipping*; assim, todos os pontos têm uma projeção invertida (linha vermelha — Figura 2.5.a) em relação à esfera ao longo do raio R , com a nova posição definida, proporcionalmente, pela distância de C a p_i . A operação é descrita por meio da Equação 2.18, e as novas coordenadas são chamadas de coordenadas transformadas. Na Figura 2.5.b indica-se a nuvem 3D original (linha azul) e os pontos considerados visíveis (linha vermelha).

$$f(\hat{p}_i) = p_i + 2(R - \|p_i\|) \frac{p_i}{\|p_i\|} \quad (2.18)$$

na qual:

p_i é a representação dos pontos da nuvem de pontos;

R é o raio da esfera;

$\|p_i\|$ é a norma dos pontos da nuvem.


O *Spherical Flipping* envolve o cálculo da norma ($\|p_i\|$) do vetor posição de todos os pontos da nuvem 3D (distância do ponto ao centro de projeção). O raio (R) é determinado com base no maior valor da norma dos pontos, que representa assim o ponto mais distante do centro. Além disso, R é ampliado por um parâmetro (ϵ) variando de zero a infinito, utilizado na Equação 2.19. A transformação inversa é calculada considerando-se que os pontos estejam em uma ordem de visibilidade válida para um determinado ponto de vista da nuvem de pontos.

$$R = \max \|p_i\| * 10^\epsilon \quad (2.19)$$

A transformação geométrica da Equação 2.18 realiza a subtração entre o raio e a norma do ponto ($R - \|p_i\|$) determinando a distância do ponto à superfície da esfera. Assim, ao multiplicar por dois amplia-se o efeito da transformação, uma vez que a magnitude de deslocamento é proporcional a essa diferença. A divisão $\left(\frac{p_i}{\|p_i\|}\right)$, resulta em um vetor unitário indicador da direção de deslocamento do ponto. Por fim, é somado o vetor calculado com o ponto original (p_i) para obter o ponto transformado ($\hat{p}_i$).

A Figura 2.6 demonstra dois exemplos realizados com coordenadas bidimensionais (x,y) com representação visual no *software* GeoGebra. A Figura 2.6.a, contém a nuvem de pontos idealizada e a posição do observador. O cálculo do *Spherical Flipping* considerando o valor *default* ($\epsilon = 0$) indicado pelos autores Katz et al. (2007), para nuvens esparsas pode ser visto na Figura 2.6.b. Um valor de ϵ maior é ideal para nuvens densas (Figura 2.6.c), uma vez que o aumento do raio faz os pontos da nuvem 3D serem projetados mais distantes, deixando-os na posição convexa na esfera. Nas Figuras 2.6.b e 2.6.c, os pontos pretos representam os pontos oclusos e em vermelho os pontos visíveis; esse critério é definido pelo *Convex Hull* (Seção 3.2.2), aplicado como segunda etapa do processo. O *Convex Hull* representa o menor conjunto convexo contendo todos os pontos de um conjunto no espaço. Geometricamente, corresponde ao polígono convexo externo, formado por um subconjunto dos pontos de entrada, com os demais localizados no interior ou sobre o limite. Ainda assim, podem ocorrer pequenas imprecisões no operador HPR, como considerar visíveis pontos na região côncava ou eliminar pontos na região convexa (Figura 2.6.b).

Figura 2.6 – Exemplos do *Spherical Flipping* para diferentes ε , com o observador a esquerda. A (a) nuvem de pontos bidimensional de teste e (b, c) o resultado da variação de ε para o cálculo da transformação geométrica, onde os pontos pretos representam pontos oclusos e os vermelhos os visíveis.



A implementação do operador é realizada em seis etapas (Seção 3.2.2): (1) transformar os pontos da nuvem de pontos para o sistema de referência do ponto de vista (câmara); (2) calcular o valor de norma dos pontos; (3) definir o raio da esfera; (4) fazer a transformação dos pontos por *Spherical Flipping*; (5) definir o *Convex Hull*; e, (6) com os índices do *Convex Hull*, salvar os pontos considerados visíveis (Katz et al., 2007).

2.3.3 Atribuição de valores espectrais à nuvem de pontos

A atribuição dos valores espectrais à nuvem de pontos tem início com a obtenção dos dados das imagens, que incluem a orientação interior, exterior, o tamanho do quadro (altura e largura) e os pontos visíveis no espaço objeto, determinados a partir do ponto de vista. Dado um ponto com coordenadas (X,Y,Z) , calcula-se a posição do ponto (x,y) utilizando a equação de colinearidade (Seção 2.2.2). Em seguida, aplica-se o processo inverso do cálculo da orientação interior (Seção 2.2.1) para obter as coordenadas de imagem (c,l) , com a adição das distorções das lentes. Por fim, realiza-se a interpolação bilinear (Seção 2.4.3.1) com base nas coordenadas dos pixels (c,l) para associar o valor de ND às coordenadas dos pontos.

2.3.3.1 Interpolação de tons de cinza


A interpolação emprega dados conhecidos para estimar valores em pontos desconhecidos, como, por exemplo, os valores de intensidade de pixels nas imagens (Gonzalez;

Woods, 2009). A técnica é fundamental em diversos métodos de reamostragem de imagens. Destaca-se, especialmente, os métodos do vizinho mais próximo e da interpolação bilinear, embora existam outras técnicas, como, a interpolação cúbica e a interpolação por *splines*.

Na interpolação pelo vizinho mais próximo, o valor de ND na imagem é determinado com base no valor do pixel conhecido mais próximo. A técnica exige menos recursos computacionais, resultando em um menor custo de processamento. No entanto, em alguns casos, os valores de cinza podem aparecer deslocados de sua correta posição em até meio pixel, gerando o efeito serrilhado (Kraus, 1993).

A interpolação bilinear é uma técnica mais sofisticada em comparação com a do vizinho mais próximo. Para estimar o valor de ND, são utilizados os valores de quatro pixels vizinhos, resultando em um maior custo computacional. A técnica oferece a vantagem de criar transições mais suaves e evitar o deslocamento de pixels, embora reduza o contraste da imagem (Kraus, 1993). O cálculo é descrito em Galo (2019), conforme ilustrado na Figura 2.7 e descrito na Equação 2.20.

Figura 2.7 – Interpolação bilinear.



Fonte: GALO (2019).

$$R_{i',j'} = (1 - d_x)(1 - d_y) E_{i,j} + d_x(1 - d_y) E_{i+1,j} + d_y(1 - d_x) E_{i,j+1} + d_x d_y E_{i+1,j+1} \quad (2.20)$$

em que:

$E_{i,j}$, $E_{i+1,j}$, $E_{i,j+1}$ e $E_{i+1,j+1}$ representam os valores de ND dos pixels vizinhos;

d_x e d_y indicam as frações de diferenças nas direções x e y, respectivamente, com valores limitados entre 0 e 1.

O método emprega interpolação linear nas direções x e y , através das diferenças d_x e d_y , juntamente com os quatro valores de intensidade dos pixels vizinhos. O cálculo determina o valor de ND do novo pixel de saída ($R_{i',j'}$), o qual pode ser então incorporado em um espaço de cores RGB em outra imagem ou em uma nuvem tridimensional.

As componentes do vermelho (R), verde (G) e azul (B) da imagem podem ser associadas a cada posição em outra imagem ou nuvem de pontos. Consequentemente, o resultado consistirá em três imagens reamostradas de tamanho idêntico, cada uma representando a matriz de tons de cinza para cada componente RGB. No caso das nuvens de pontos, essa representação será dada pela matriz de pontos (X, Y, Z) e as colunas indicando os valores de ND para cada comprimento de onda do visível (RGB) e/ou infravermelho.

2.3.4 Ajuste radiométrico

O ajuste radiométrico tem sido amplamente pesquisado ao longo dos anos, inicialmente para imagens de satélite, para mosaicos aéreos e, mais recentemente, para imagens terrestres. As clássicas abordagens para o caso aéreo, baseiam-se em ajuste de histograma utilizando funções lineares, bem como a modificação do contraste e brilho das imagens (Gehrke, 2012). Além disso, alguns estudos combinam modelos de correções atmosféricas e/ou BRDF (*Bidirectional Reflectance Distribution Function*) (Chandelier; Martinoty, 2009; González-Piqueras et al., 2010; Pros et al., 2013). A BRDF é particularmente eficaz para descrever superfícies isotrópicas e envolve a consideração de parâmetros como a distância entre a fonte de luz e o objeto, bem como o ângulo formado entre as direções da luz incidente e da observação.

Apesar da escassez de pesquisas relacionadas ao ajuste radiométrico de imagens de curta distância, Xie et al. (2023) apresentaram estudos promissores sobre o uso da BRDF em imagens terrestres. Segundo Liu et al. (2018), a integração dos dados de imagens e LiDAR apresenta uma precisão relativamente baixa, atribuída à complexidade da fusão de dados e aos efeitos da iluminação. Esse processo enfrenta desafios significativos, especialmente nas áreas de sobreposição, devido aos diferentes ângulos de visão dos quadros individuais e à dificuldade de registrá-los diretamente no modelo completo (Xie et al., 2023). Após a geração do produto, a sua qualidade pode ser avaliada (Seção 2.4).

2.4 Avaliação da qualidade para a nuvem colorida

No contexto da Cartografia, o controle de qualidade é entendido como uma etapa de avaliação de produtos cartográficos, assegurando a definição precisa da acurácia posicional e a correta interpretação e utilização das informações espaciais, em consonância com padrões pré-estabelecidos por legislação. A avaliação dos resíduos nos pontos de controle e de verificação fornece uma análise preliminar dos dados na fototriangulação, identificando erros e permitindo o aprimoramento da solução para sua minimização. Preliminarmente, é avaliada a consistência dos erros para os pontos de controle e verificação comparando o tamanho do pixel no espaço objeto - PSOSU (*Pixel Size in Object Space Units*) em relação aos RMSEs obtidos. Considera-se empiricamente que os resultados são satisfatórios quando o RMSE dos pontos de verificação permanece abaixo de duas vezes o PSOSU na componente planimétrica e três vezes na componente de profundidade (GRAHAM e KOH, 2002). Após a análise, o processo de fototriangulação pode ser finalizado, caso os critérios sejam atendidos e, posteriormente, realizar testes adicionais de tendência e precisão. Além deste critério empírico, definido por Graham e Koh (2002), é possível utilizar a legislação cartográfica, utilizando-se uma fração do EP (Erro Padrão) final admitido para o produto cartográfico final. Entretanto, estas normas são difícil adaptação para o caso deste trabalho, sendo usadas apenas as análises de tendência.

Segundo Galo e Camargo (1994), a análise de tendência baseia-se no cálculo das discrepâncias entre as coordenadas medidas no produto final e as consideradas verdadeiras (Equação 2.21). O processo envolve, primeiramente, o cálculo das discrepâncias individuais para cada componente, conforme apresentado na Equação 2.21. Posteriormente, essas discrepâncias são sintetizadas através do cálculo da média (Equação 2.22) e do desvio padrão correspondente (Equação 2.23), oferecendo uma medida da dispersão em torno da média.

$$\Delta X_i = X_i - X_i^r \quad (2.21)$$

$$\Delta \bar{X} = \frac{1}{n} \sum_{i=1}^n \Delta X_i \quad (2.22)$$

$$S_{\Delta \bar{X}} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (\Delta X_i - \Delta \bar{X})^2} \quad (2.23)$$

em que:

$\Delta \bar{X}$ é a média amostral;

$S_{\Delta \bar{X}}$ é o desvio padrão amostral.

O teste de tendência fundamenta-se na distribuição *T-Student*, aplicado por meio de um teste de hipóteses. A hipótese nula (H_0) pressupõe a nulidade da média das discrepâncias, enquanto a hipótese alternativa (H_1) propõe a não nulidade dessa média, sugerindo a existência de tendência nos dados.

$$H_0: \Delta\bar{X} = 0$$

$$H_1: \Delta\bar{X} \neq 0$$

Para avaliar a presença ou ausência de tendência, procede-se ao cálculo da estatística amostral t_x , de acordo com a Equação 2.24. Esse valor é comparado ao valor tabelado obtido da distribuição *T-Student*, ajustado pelo nível de significância estabelecido (α) e pelos graus de liberdade (número de pontos menos um), conforme descrito na Equação 2.25. A aceitação da hipótese nula, indica que as discrepâncias observadas resultam do acaso, permitindo considerar o produto como isento de tendências sistemáticas.

$$t_x = \frac{\Delta\bar{X}}{S_{\Delta\bar{X}}} \sqrt{n} \quad (2.24)$$

$$|t_x| < t_{(n-1, \frac{\alpha}{2})} \quad (2.25)$$

O teste de tendência avalia a etapa de fototriangulação das imagens. Outra métrica relevante envolve a comparação entre os resultados obtidos e o erro de distância inerente do equipamento FARO, comparando-o aos erros gerados pela fototriangulação nos pontos de verificação. A variação no erro de distância do equipamento é de ± 1 mm, caracterizando-se como um erro sistemático para distâncias entre 10 e 25 metros. No entanto, como a coleta ocorreu a uma distância aproximada de 2 metros, o erro esperado é inferior a 1 mm. Quanto ao erro de medição angular, avaliado em 19" este gera um erro linear de 0,18 mm, para a distância de 2 m, valor inferior ao PSOSU das imagens capturadas.

3. MATERIAIS E MÉTODOS

As subseções seguintes descrevem os equipamentos e a metodologia adotada, incluindo o processamento em diferentes *software*. As imagens multiespectrais foram coletadas pela câmara da Agrowing e a nuvem LiDAR pelo scanner FARO (Seção 3.1). Após os dados serem transformados para o mesmo referencial (Seção 3.2.1), foram aplicados os métodos de rotulação de pontos ocultos (Seção 3.2.2). Em seguida, realizou-se a tonalização da nuvem densa (Seção 3.2.3). Os passos executados são descritos na Seção 3.3.

3.1 Materiais

A empresa israelense Agrowing (Agrowing, 2024) adaptou câmaras comerciais profissionais com filtros e suportes para lentes múltiplas e multiespectrais nos sensores do modelo Sony Alpha 7 IVR (ILCE-7RM4A). A Figura 3.1 apresenta dois tipos de objetivas: uma com duas lentes (Figura 3.1.a) e outra com seis lentes (Figura 3.1.b).

Figura 3.1 – Câmaras da Sony (a) com duas lentes, (b) com seis lentes.



As câmaras com duas lentes conseguem coletar imagens em quatro bandas espectrais, enquanto as com seis lentes capturam em quatorze bandas espectrais (Tabela 3.1). O redirecionamento dos feixes de luz pelas lentes, conforme o esquema de montagem, permite obter as bandas simultaneamente no momento da captura da foto. As bandas espectrais são obtidas pela combinação do filtro de Bayer e dos filtros personalizados das lentes (Tommaselli et al., 2020). Além disso, cada lente possui uma distância focal diferente.

Tabela 3.1 – Especificações da câmara de seis lentes.

Campo de visão	25° Horizontal e Vertical
Faixas espectrais para lente NDVI	405; 430; 450; 490; 525; 550; 560; 570; 630; 650; 685; 710; 735; 850 nm
Largura das bandas	30 nm
Distorção da lente	<1%
Distância focal nominal	21,6 mm
Abertura	f/5.6 (fixo)
Tamanho do quadro para o recorte da imagem	2600 x 2600 pixels (9,63 x 9,63 mm)
Tamanho do pixel	0,0037 mm

A definição das disposições das bandas em quadrantes foi determinada pelas especificações do *software* da Agrowing, abrangendo faixas espectrais próximas ao RGB (405, 430, 450, 490, 525, 550, 560, 570, 630, 650 e 685 nm), ao Infravermelho (850 nm) e/ou *Red Edge* (710 e 735 nm). Para simplificar o manuseio das bandas, são atribuídos valores de posição às lentes, chamados de quadrantes (Q) (Figura 3.2), iniciando-se do canto superior direito e seguindo para a esquerda (Q1 a Q3), e em seguida do canto inferior esquerdo para a direita (Q4 a Q6).

Figura 3.2 – Disposição dos quadrantes da câmara e faixas espectrais relacionadas a cada quadrante.



Os quadrantes estão dispostos em: Q1 – 405 (azul), 570 (verde), 710 (*Red Edge*); Q2 – 525 (verde), 630 (azul); Q3 – 850 (infravermelho); Q4 – 430 (azul), 550 (verde), 650

(vermelho); Q5 – 490 (azul), 735 (*Red Edge*); Q6 – 450 (azul), 560 (verde), 685 (vermelho). As bandas espectrais podem ser separadas a partir da imagem original e extraídas conforme a faixa espectral. A empresa israelense Agrowing disponibiliza um *software* próprio para recorte e extração automática das bandas.


A nuvem de pontos LiDAR pode ser adquirida por escaners terrestres, como o TLS FARO. As características do sensor FARO Focus Premium são: FoV de 360° (Horizontal) x 300° (Vertical), com divergência do feixe de 0,3 mrad, duração de pulso de aproximadamente 4 ns, comprimento de onda de 1553,5 nm, projetado para digitalizar objetos com 0,5 a 70, 150 ou 350 m de distância. Além disso, permite colorir a nuvem densa em cores RGB. Os dados do FARO Focus Premium podem ser obtidos usando o aplicativo próprio do sistema e como dados de saída tem-se a escaneamento da nuvem de pontos com intensidade e as imagens tomadas. O processamento é realizado no *software* SCENE, onde é gerada a nuvem densa.

O computador empregado no processamento dos dados (LiDAR e câmara) utiliza o sistema operacional Windows 11Pro, com o processador 11th Gen Intel® Core™ i9-11900KF CPU 3.50 GHz, RAM de 64 GB, 64 bits e com capacidade de processar grandes arquivos e executar os *softwares* presentes na pesquisa, como o Agisoft Metashape, a plataforma de programação Matlab R2023 e o IDE (IDE (*Integrated Development Environment*, Ambiente de Desenvolvimento Integrado) Visual Studio 2019, com construção no CMake e biblioteca do *Point Cloud Library* (Rusu; Cousins, 2011).

3.2 Conjunto de dados


O primeiro conjunto de dados foi adquirido na plantação de café da Universidade Federal de Uberlândia, MG, no campus de Monte Carmelo. Alguns alvos, como esferas e etiquetas, foram distribuídos sobre os cafeeiros e no solo (Figura 3.3.a,b). Assim, com o LiDAR ocupando uma posição frontal à árvore (Figura 3.3.a), foi realizada uma varredura única. As imagens foram capturadas em diferentes estações, variando em altura, base planimétrica e convergência (Figura 3.3.c).

Figura 3.3 – Conjunto de dados (a) no cafeeiro e (b) a disposição dos alvos na árvore e (c) a câmara Agrowing capturando uma imagem entre a sequência de imagens.



O segundo conjunto de dados foi adquirido no campus da FCT/UNESP em Presidente Prudente/SP, no terraço do LATOGEO (Laboratório de Astronomia, Topografia e Geodésia) (Figura 3.4). Os equipamentos, escâner Faro e câmara, foram movimentados em um formato de círculo de 360° em torno da macieira, com uma distância aproximada de 2 metros.

Figura 3.4 – Conjunto de dados com (a) a macieira, (b) os ajustes em alvos esféricos e (c) no LiDAR.



No ambiente havia alvos ARUCO fixados na parede e no chão (Figura 3.4), posteriormente utilizados como pontos de controle e apoio (Seção 4.1). Além disso, também foram posicionadas esferas (Figura 3.4.b) para realizar o registro entre as varreduras das nuvens de pontos em um ambiente externo, onde a influência do vento era acentuada, simulando a situação das árvores no cafeeiro. A vantagem de transportar a vegetação e realizar a coleta em um local com vários alvos é garantir consistência na geometria e fornecer mais pontos de


controle para o georreferenciamento dos dados. Assim, os erros de orientação da câmara, em relação à nuvem LiDAR, podem ser minimizados. Os resultados do conjunto de dados permitiram analisar os parâmetros da varredura a LASER, portanto, a metodologia aplicada ao primeiro conjunto de dados pode ser reproduzida para o segundo.

3.3 Método proposto

A sequência de procedimentos para a colorização da nuvem de pontos é representada graficamente por meio de um fluxograma mostrado na Figura 3.5. A primeira etapa, após a coleta dos dados em campo, é a geração da nuvem LiDAR a partir dos dados brutos de um escâner, neste caso o FARO, e a extração das quatorze bandas espectrais no *software* da Agrowing. Em seguida, os ruídos da nuvem LiDAR são removidos com a técnica *Moving Least Squares*. Os processos seguintes envolvem a integração dos dados. Primeiramente, são identificados alvos pré-sinalizados ou naturais na nuvem LiDAR com o *software* CloudCompare, e as coordenadas são medidas manualmente no referencial arbitrário da nuvem de pontos. Na etapa seguinte, essas coordenadas servem de pontos de apoio para a fototriangulação de cada banda multiespectral no *software* Agisoft Metashape. Os valores dos POEs são estimados na fototriangulação e, através da calibração em serviço, também os POIs. Os POEs das imagens garantem que os dados LiDAR e ópticos estejam no mesmo referencial.

Após a compatibilização dos sensores, é realizada a etapa de atribuição de valores espectrais à nuvem de pontos a partir das imagens. Entretanto, a imagem cobre apenas parte da nuvem de pontos e ocorre oclusões do ponto de vista da imagem. Deste modo, é aplicado o algoritmo de *culling*, VFC, para manter apenas os pontos presentes no plano de visão da imagem selecionada (implementado em C/C++). Posteriormente, os pontos oclusos são removidos com a técnica de HPR (implementado no Matlab) utilizando o POE das imagens. A última etapa diz respeito à colorização da nuvem de pontos, onde os pontos da nuvem 3D recebem os NDs de todas as bandas (implementado no Matlab).

Figura 3.5 – Fluxograma do processamento.



3.3.1 Design de aquisição dos dados

A coleta em campo envolve as seguintes etapas: (1) definir o local onde os alvos codificados serão colocados para servir como pontos de controle; (2) configurar a câmara; (3) planejar e executar o trajeto que a câmara deve percorrer; (4) realizar uma varredura frontal da planta com o LiDAR.

A coleta dos dados do cafeeiro, começou pelo posicionamento de alvos no solo e outros fixados em galhos (Figura 3.3). No entanto, a dificuldade para medir alvos esféricos levou à sua eliminação no processo de georreferenciamento. Dessa forma, algumas folhas e galhos foram considerados estáticos, mesmo que essas feições não apresentem esse comportamento ao longo do levantamento. Em seguida, a câmara foi configurada com diferentes tempos de exposição para adaptar-se às condições de iluminação. O dia estava ensolarado, e o tempo de exposição variou entre 1/160, 1/200, 1/320 e 1/400. As bandas com

maiores comprimentos de onda podem ser superexpostas com tempos de exposição mais longos, enquanto as bandas com menores comprimentos de onda podem perder qualidade e apresentar ruído com tempos de exposição mais curtos.

No total, foram capturadas 150 imagens ao longo do trajeto, com os tempos de exposição mais adequados para cada banda, sendo selecionadas 50 imagens por bloco triangulado. As bandas espectrais foram extraídas com o *software* AwBasic (Agrowing, 2024). No total, sete bandas (490 nm, 525 nm, 550 nm, 560 nm, 570 nm, 735 nm e 850 nm) foram processadas no *software* Agisoft Metashape. Optou-se por empregar as bandas do comprimento de onda verde (bandas centrais) devido ao benefício do filtro de Bayer, capaz de melhorar a qualidade radiométrica da imagem. Ainda assim, as imagens apresentaram-se com baixa luminosidade. Para melhorar o aspecto visual, aplica-se um auto-ajuste de cores no *software* Irfanview para a banda do azul e na banda do verde as correções de: 61 de contraste, 10 de brilho e 2,15 na correção gama. A escolha do tempo de exposição para cada banda pode ser vista na Tabela 3.2.

Tabela 3.2 – Escolha dos tempos de exposição.

Quadrante	Bandas do R Tempo de exposição	Bandas do G Tempo de exposição	Bandas do B Tempo de exposição
Q1	405 nm 1/200	570 nm 1/200	710 nm 1/200
Q2	X	525 nm 1/200	630 nm 1/200
Q3	X	X	850 nm 1/400
Q4	430 nm 1/200	550 nm 1/200	650 nm 1/200
Q5	490 nm 1/200	X	735 nm 1/200
Q6	450 nm 1/200	560 nm 1/200	685 nm 1/200

Os dados brutos do LiDAR passaram por um processamento inicial no *software* FARO SCENE para a geração da nuvem de pontos, tendo como resultado as coordenadas dos pontos e a intensidade. Posteriormente, a nuvem de pontos foi recortada para a área de interesse utilizando o *software* CloudCompare. No segundo conjunto de dados, referente à macieira, seguiu-se o mesmo procedimento, considerando diferentes resoluções nas nuvens 3D coletadas. Além do registro entre as quatro estações em diferentes posições para a coleta da macieira completa. Devido à forte influência do vento, ambos os conjuntos de dados exigiram a aplicação de um filtro estatístico para remoção de ruídos (Seção 3.3.2), a fim de aprimorar a visualização.

A coleta com a câmara multiespectral na macieira, envolveu 35 imagens capturadas em duas voltas de 360°, com o tempo de exposição fixado em 1/500 para todas as bandas. As correções de baixa luminosidade para as bandas azul e verde foram realizadas no Irfanview, com ajustes semelhantes ao primeiro conjunto de dados, exceto a aplicação de brilho.

3.3.2 Filtragem de ruídos da nuvem LiDAR

A remoção de ruído ocorreu pelo método estatístico MLS implementado na PCL (*Point Cloud Library*) (Rusu; Cousins, 2011). Como visto na Seção 2.1.1, Jenke et al. (2006) definem MLS como um processo de suavização sobre uma nuvem de pontos, ajustando localmente polinômios a pontos individuais enquanto calculam simultaneamente a normal para cada ponto suavizado.

Os parâmetros utilizados correspondem a aplicar o método de polinômios de segunda ordem para suavização dos dados e realizar a pesquisa por meio da KD-Tree para otimização das buscas. O raio utilizado para suavização da superfície foi ajustado para 1,8 mm, definido empiricamente. Esse valor está próximo ao valor do *footprint* das coletas. Considerando aproximadamente 2 metros de distância entre o equipamento e o objeto, o valor do *footprint* seria de 1,2 mm. A biblioteca PCL 1.14.1-dev permite utilizar a classe *pcl::MovingLeastSquares* para configurar os parâmetros: grau do polinômio, determinação da normal, opção pelo método em árvore e definição do raio. Após a remoção de ruídos, a nuvem LiDAR é utilizada para medir os pontos de controle, essenciais na fototriangulação do bloco fotogramétrico para obter os POEs.

3.3.3 Fototriangulação no Agisoft Metashape

O sistema de coordenadas arbitrário da nuvem LiDAR é empregado para referenciar as imagens multiespectrais, garantindo que ambos os conjuntos de dados compartilhem o mesmo sistema de referência. No processamento do bloco de imagens, o software Agisoft Metashape utiliza a técnica de *Structure From Motion* (SfM). Segundo Shervais (2017), o SfM utiliza um conjunto de imagens do mesmo objeto para realizar a modelagem tridimensional (com coordenadas X, Y, Z), por meio da correspondência entre pontos comuns nas imagens. O software emprega algoritmos de correspondência baseados em feições, como o SIFT (*Scale*

Invariant Feature Transform), o qual é invariante à escala, rotação, iluminação e ponto de vista 3D da câmara. Essa correspondência entre os pares de imagens permite recuperar a posição da câmara e a geometria da cena.

A técnica SfM permite estimar a posição e atitude das imagens, seguindo as etapas: seleção do par de imagens, orientação relativa, triangulação para cálculo de pontos tridimensionais e otimização dos parâmetros de orientação interior. O manual do Agisoft Metashape (AGISOFT METASHAPE, 2024), descreve as etapas de processamento:

Fototriangulação: Inicialmente, são inseridos o tamanho do pixel das imagens e outros dados de orientação interior, quando disponíveis. Esta etapa determina a posição e a atitude da câmara no momento da captura da imagem em relação ao referencial da nuvem LiDAR. A partir dos dados iniciais de POE, o alinhamento ajusta um bloco de imagens usando as equações de colinearidade para obter valores estimados da orientação exterior por meio da correspondência entre pontos extraídos nas imagens.

Para configurar a precisão do alinhamento, o *software* oferece modos de alta e baixa precisão das estimativas de posição. No modo de alta precisão, as imagens são processadas em tamanho original. À medida que a precisão é reduzida, as imagens são redimensionadas. Durante o processo de alinhamento, especialmente em baixa precisão, podem surgir pontos incorretos que podem ser filtrados e removidos.

Georreferenciamento por pontos de apoio: as imagens podem ser orientadas somente por uma orientação relativa (sem referência terrestre), por georreferenciamento direto (referência terrestre pela orientação exterior das imagens), orientação absoluta (referência terrestre dos pontos de controle) ou a combinação dos dois últimos;

Otimização da câmara (calibração em serviço): permite estimar os parâmetros do modelo clássico de distorção das lentes conforme Conrady (1919) e Brown (1966), refinando a: distância focal, posição do ponto principal, coeficientes de distorção radial e os coeficientes de distorção descentrada.

Os valores de posição da câmara, bem como a orientação interior refinada pela calibração em serviço, são utilizados para o cálculo das coordenadas de pontos na imagem pelas equações de colinearidade. A equação constitui o principal modelo matemático deste projeto, por possibilitar o cálculo que buscará os valores espectrais na imagem correspondentes aos

pontos na nuvem LiDAR. No entanto, para evitar duplo mapeamento, deve-se realizar uma etapa anterior para remover pontos oclusos na nuvem de pontos LiDAR.

3.3.4 Rotulação da oclusão de nuvem de pontos

Os tons de cinza dos pontos LiDAR projetados nas imagens devem ser interpolados para recuperar o valor de ND mais consistente com a fotografia e relacioná-lo à nuvem 3D. O processo requer uma técnica capaz de eliminar os pontos oclusos da nuvem LiDAR, em relação a determinado ponto de vista, que é o centro perspectivo associado a cada imagem.

Os métodos adotados são o VFC e HPR. No VFC é necessário inserir os valores dos FoV vertical e horizontal, as distâncias próximas e distantes do plano de corte, os ângulos de rotação e de translação da câmara (POEs). A biblioteca PCL 1.13.1-dev permite utilizar a classe `pcl::FrustumCulling` e os métodos públicos: `setCameraPose`, `setHorizontalFOV`, `setVerticalFOV`, `setNearPlaneDistance`, `setFarPlaneDistance` (Krishnan, 2023). A implementação do algoritmo é de Argueta (2022), com adaptações na etapa para definir a orientação da câmara, na variável `camera_pose`, para estar no sistema de coordenadas dos dados gerados no Agisoft Metashape.

Segundo Krishnan (2023), a distância mais próxima (*near*) igual a zero irá gerar uma pirâmide retangular ao invés de um *frustum*; valores maiores geram o formato do *frustum*. A rotação está adaptada para criar a matriz de rotação no formato $R(\kappa)R(\varphi)R(\omega)$. Por fim, a matriz homogênea (Seção 2.2.1) responsável por determinar a posição da câmara é criada.

Realizado o *clipping* da nuvem de pontos com base no *frustum*, agora está possui pontos presentes no volume do VFC, baseado no FoV da câmara. Aplicar a técnica HPR (Algoritmo 3.1) garante a criação de um mapa de visibilidade, no qual apenas os pontos visíveis são mantidos. O Matlab e o IDE PyCharm (Python) possuem uma função para processar os dados com estes algoritmos. Neste projeto, o algoritmo foi implementado como disponibilizado pelos autores Katz et al. (2007).

Algoritmo 3.1. Hidden Points Removal em Matlab

Dados de entrada: Nuvem LiDAR delimitada pelo VFC, OE

Dados de saída: Pontos visíveis a partir do CP da câmara

```

1: [numPts,dim] = size(pointcloud);
2: [X, Y, Z] = [p(1:numPts,1), p(1:numPts,2), p(1:numPts,3)];
3: [Cx, Cy, Cz] = []; %Centro Perspectivo da imagem (ponto de vista)
4: for i = 1:numPts %Mover para origem
5:   pX(i) = X(i) - Cx;
6:   pY(i) = Y(i) - Cy;
7:   pZ(i) = Z(i) - Cz;
8:   p = [pX' pY' pZ'];
9: end
10: normp = sqrt(sum(p.^2,2)); %Calcular a norma dos pontos da nuvem 3D
11: param = 0;
12: R = max(normp)*(10^param); %Raio da esfera
13: p = p+2*(R-normp).*(p./normp); %Spherical Flipping
14: vispts = unique(convhull ([p; zeros(1,2)])); %Índice dos pontos visíveis no convexhull
15: vispts(vispts==numPts+1) = [];
16: coord_vis = [X(vispts) Y(vispts) Z(vispts)] %Coordenadas dos pontos visíveis

```

O HPR consegue remover os pontos oclusos da nuvem LiDAR, considerando que todos os pontos no *Convex Hull* são os visíveis. O conceito matemático *Convex Hull* surgiu de uma releitura do algoritmo *Quick Hull*, em conjunto com o algoritmo de Beneath-Beyond, (Barber; Dobkin; Huhdanpaa, 1996) e adaptado pelos engenheiros do Matlab em forma de função. O *Convex Hull* de um conjunto de pontos é representado como o menor polígono convexo, caso todos os pontos não estejam em uma posição considerada côncava.

Segundo o tutorial do Mathworks (2023), o *software* Matlab permite calcular o *Convex Hull* com diferentes funções: *convhull*, *convexHull* ou a versão do *alphashape*. Entre os dois primeiros, o comando *convhull* é considerado mais robusto e de melhor desempenho. Ambos produzem como resultado o índice dos pontos que estão no limite do *Convex Hull*. Já o método *convexHull* está contido na classe do *delaunayTriangulation*, mas é considerada inferior às outras e assegura-se maior confiabilidade quando utilizado em um conjunto de dados com triangulação existente. A diferença do *alphashape* para os demais está na possibilidade de definir o raio (α) como infinito, sendo que o valor do raio determina o quanto a forma envolve o conjunto de pontos.

O método *convhull* mostrou-se mais eficiente ao ser aplicado em cenários com aquisição de dados a partir de uma única varredura frontal, como observado no primeiro

conjunto (Mathworks, 2023). Em situações envolvendo múltiplas varreduras ou quando a geometria dos galhos e troncos apresenta irregularidades, torna-se necessário adotar técnicas complementares de segmentação, dividindo a nuvem de pontos em subpartes menores (Seção 3.3.4.1), conforme identificado no segundo conjunto de dados. Assim, o operador HPR será mais eficiente.

3.3.4.1 Subdivisão da nuvem de pontos

A metodologia adotada para a segmentação da nuvem de pontos em partes menores envolve uma abordagem iterativa segmentando o conjunto de dados com base na proximidade espacial entre os pontos. Inicialmente, a nuvem 3D é carregada, e define-se um raio de busca junto a uma distância máxima admissível entre pontos, estabelecendo um critério de quantidade mínima de vizinhos para determinar as vizinhanças. Esses parâmetros são ajustados conforme as características da nuvem de pontos analisada e de forma empírica.

A cada iteração, seleciona-se um ponto de referência, calculam-se as distâncias euclidianas entre esse ponto e os demais presentes na nuvem de pontos, e os pontos localizados dentro do raio e da distância máxima são considerados vizinhos potenciais. Ao longo do processo, a nuvem de pontos é gradualmente reduzida, removendo-se os vizinhos distantes identificados em cada iteração. Esse procedimento garante uma segmentação eficiente, isolando grupos de pontos pela proximidade espacial, promovendo uma análise local e sem sobreposição entre as regiões processadas. Os critérios usados foram de: raio de busca igual a 1 m; distância máxima entre pontos de 0,3 m; e, quantidade mínima de vizinho de 50.

3.3.5 Colorização da nuvem densa

A última etapa corresponde à atribuição de valores espectrais à nuvem LiDAR. O algoritmo visa atribuir os valores de ND da imagem aos pontos da nuvem LiDAR, utilizando as equações de colinearidade. Neste processo a coordenada de terreno (X,Y,Z) de cada ponto na nuvem 3D é projetada como coordenadas fotogramétricas (x,y), sendo transformadas para o sistema de imagem (c,l) com o cálculo de orientação interior inversa (Equações 3.2 e 3.3), com iterações, para todos os pontos na nuvem LiDAR.

$$c = \frac{x_f + x_0 + \Delta_x + \delta_x}{\text{tam}_{\text{pixel}}} + C_x \quad (3.2)$$

$$l = -\frac{y_f + y_0 + \Delta_y + \delta_y}{\text{tam}_{\text{pixel}}} + C_y \quad (3.3)$$

A orientação interior inversa passa por iterações no cálculo das distorções das lentes, permitindo refinar as distorções radial simétrica e descentrada antes do cálculo das coordenadas imagem, devido ao argumento de entrada ser o raio calculado com as coordenadas distorcidas. Caso as estimativas dos POIs forem pouco precisas, pode optar-se por diminuir o tamanho dos recortes da nuvem LiDAR, baseado em segmentações menores (Seção 3.3.4.1). Dessa forma, o recorte será restringido à área central da imagem, onde o efeito da distorção radial simétrica é menor. A última etapa é realizar a interpolação bilinear para garantir a interpolação dos valores de ND para todas as coordenadas presentes nos limites da imagem (largura e altura), baseado na vizinhança do pixel.

3.3.6 Compatibilização radiométrica

Segundo Xie et al. (2023), as variações na incidência luminosa causadas pelos diferentes ângulos de captura dos quadros obtidos com a câmara óptica resultam em discrepâncias nos valores de ND, em áreas de sobreposição. Essas discrepâncias tornam difícil a integração direta dos valores de ND em um modelo completo da nuvem de pontos, tornando o ajuste radiométrico uma etapa essencial para garantir a consistência espectral necessária na construção da nuvem de pontos multiespectral final.

O processo de geração da nuvem de pontos multiespectral começa com o recorte da nuvem de pontos utilizando o método VFC e, posteriormente, a rotulação de pontos oclusos com o operador HPR. Em seguida, cada segmento da nuvem 3D é colorizado com base na imagem correspondente ao ponto de vista. Quando ocorre sobreposição entre diferentes pontos de vista, o *software* CloudCompare foi empregado para remover essas áreas sobrepostas, evitando a necessidade de ajustar os valores de ND dos diferentes pontos de vista.

Entretanto, no segundo conjunto de dados, que envolve uma coleta de 360° ao redor de uma árvore, a sobreposição é significativamente maior e complexa de ser identificada. Nesse cenário, o recorte simples não é suficiente para garantir a integração adequada dos pontos de vista. Portanto, é necessário realizar um ajuste radiométrico para ajustar os valores de ND dos

diferentes pontos de vista e gerar um modelo de nuvem multiespectral completo. Esta etapa não foi implementada, sendo uma sugestão para trabalhos futuros.

3.4 Análises dos resultados

O LiDAR multiespectral, resultante do processamento proposto neste trabalho, proporciona visualização detalhada do ambiente e uma compreensão abrangente das características presentes na vegetação. A avaliação desse produto requer uma análise comparativa. Técnicas empregadas para o processamento da nuvem de pontos multiespectral são validadas predominantemente através de análises visuais, com foco na eficácia dos métodos aplicados.


O método VFC, responsável por recortar a nuvem de pontos para corresponder ao tamanho da imagem, é validado por comparações visuais dos recortes, assegurando a redução de pontos fora do volume de visualização da câmara. No caso do operador HPR, utilizado para identificar pontos visíveis, pode ser avaliado por meio da subtração do resultado processado da nuvem 3D original, permitindo uma comparação visual direta e a identificação de discrepâncias. No processo de colorização, análises de deslocamento permite verificar a combinação entre quadrantes. A técnica envolve a medição das coordenadas nas nuvens densas geradas pelo *software* Agisoft Metashape e devem ser comparadas as coordenadas medidas com a nuvem LiDAR, além da sobreposição entre imagens com diferentes orientações.

4. EXPERIMENTOS E RESULTADOS

4.1 Processamentos iniciais

O processo de fototriangulação, de cada banda de referência, para compatibilizar os dados de diferentes sensores, resultou na estimativa da posição e atitude da câmara para cada lente, usando a banda de referência de cada quadrante, para o primeiro e segundo conjunto de dados. O primeiro conjunto de dados, obtido com a câmara direcionada para um cafeeiro (Figura 4.1.a – posição das imagens em azul) e distância de aproximadamente 1,80 m, apresenta um PSOSU médio de 0,3 mm. Doze pontos de controle foram distribuídos entre alvos na árvore e no solo (Pontos 1-8, 11 e 12), com medições adicionais em galhos e folhas (Pontos 9 e 10) (Figura 4.1.b).

Figura 4.1 – (a) Orientação das imagens (banda 550 nm) no cafeeiro e a (b) distribuição dos pontos de controle e verificação.



O RMSE (*Root Mean Square Deviation*) total dos pontos de controle (Tabela 4.1) para as bandas centrais de cada quadrante superaram quatorze vezes o valor do PSOSU. Consequentemente, as estimativas de orientação das imagens foram afetadas com a baixa precisão dos pontos em comparação com PSOSU. Devido à falta de alvos e feições estáticas no ambiente, o resultado permaneceu insatisfatório para gerar uma nuvem de pontos multiespectral com todas as bandas, após uma análise visual da nuvem colorida. Entretanto, o quadrante 4, com os comprimentos de onda 430, 550 650 nm, pôde ser utilizado, pois os valores de orientação exterior permitiram a geração de imagens coerentes na colorização.

Tabela 4.1 – RMSE total dos pontos de controle do primeiro conjunto de dados.

Quadrante	X (mm)	Y (mm)	Z (mm)	Total (mm)
Q1 (570 nm)	2,56	1,64	1,23	3,28
Q2 (525 nm)	2,51	2,19	2,17	3,98
Q3 (850 nm)	1,37	2,88	3,12	4,46
Q4 (550 nm)	1,59	2,06	1,13	2,84
Q5 (490 nm)	2,32	2,93	2,76	4,65
Q6 (560 nm)	2,22	1,89	2,60	3,91

A nuvem de pontos colorida para o primeiro conjunto de dados (cafeeiro) foi gerada apenas nas bandas RGB (430, 550 e 650 nm) do Q4. Três pontos de controle foram utilizados como pontos de verificação (Tabela 4.2) independentes para as análises estatísticas posteriores, com o teste *t-student* (Tabela 4.3). Os pontos de verificação foram escolhidos próximos aos pontos de controle, evitando aqueles localizados nas extremidades da árvore.

Tabela 4.2 – Erros dos pontos de verificação do primeiro conjunto de dados para o Q4.

Banda	Pontos	X (mm)	Y (mm)	Z (mm)
550 nm (Q4)	P3	-1,95	3,21	-0,29
	P9	0,56	-4,74	1,53
	P11	1,34	0,98	0,58
RMSE		1,40	3,35	0,95
Média		-0,01	-0,18	0,60
Desvio-padrão		1,71	4,10	0,91

Nas componentes planimétricas, observa-se que todos os pontos de verificação apresentam erros superiores a 1 mm, sendo o maior erro (componente Y do P9) até quatro vezes ao erro de distância do equipamento Faro, vinte vezes maior do que o efeito do erro angular e mais de dez vezes o valor do PSOSU das imagens. O ponto P9, em particular, exibe um erro significativamente elevado na altimetria, excedendo o erro intrínseco ao equipamento utilizado. Na Tabela 4.3 é analisado a hipótese de tendência nas coordenadas.


Tabela 4.3 – Teste *t-student* para a banda 550 nm do Q4.

Elementos	X	Y	Z
t_x	0,017	0,076	1,159
$t_{(2;0,1/2)}$	2,920		
Conclusão	A hipótese nula não é rejeitada. Logo sem tendência.	A hipótese nula não é rejeitada. Logo, sem tendência.	A hipótese nula não é rejeitada. Logo, sem tendência.

A análise estatística dos pontos de verificação das imagens capturadas no cafeeiro revelou ausência de tendência nas componentes planimétricas e altimétrica. A componente altimétrica apresentou os valores mais elevados na estatística amostral t_x , em relação às componentes planimétricas, indicando uma variação mais acentuada. Esse comportamento sugere uma maior sensibilidade da altimetria a possíveis erros sistemáticos ou imprecisões durante o processo de fototriangulação, exigindo maior rigor nos ajustes verticais. Entretanto, aprimorar os resultados significa aumentar a medição de pontos de controle. No segundo conjunto de dados foi possível medir mais pontos em alvos estatísticos na cena.

No segundo conjunto de dados (macieira), as imagens capturadas em volta da planta (Figura 4.2.a) com uma distância câmara-objeto de aproximadamente 2 metros, apresenta um PSOSU de 0,35 mm. Foram medidos quarenta e quatro pontos de controle e quatro de verificação, dos quais, quarenta pontos foram medidos nos alvos ARUCO fixados nas paredes e solo (Pontos 4 – 32, 35 – 43, 45 – 48) e seis pontos medidos nos alvos (padrão Agisoft Metashape) fixados no vaso da planta (Pontos 1, 2, 3, 33, 34 e 44) (Figura 4.2.b). Entretanto, optou-se por não medir pontos na região Sul da Figura 4.2.b (região posterior do vaso) devido à sua distância em relação a planta.

Figura 4.2 – (a) Orientação das imagens (550 nm) na macieira e (b) distribuição dos pontos de controle e verificação.



O RMSE nos pontos de controle (Tabela 4.4) para as bandas centrais de cada quadrante, varia entre 1,8 – 2,4 vezes o PSOSU para as coordenadas planimétricas, enquanto para a componente altimétrica varia de 1,3 – 2 vezes o PSOSU. Além disso, o RMSE total não ultrapassa quatro vezes o PSOSU. Portanto, em comparação com o primeiro conjunto de dados,

a fototriangulação do segundo conjunto demonstra uma precisão superior dos pontos em função do PSOSU planimétrico e altimétrico.

Tabela 4.4 – RMSE total dos pontos de controle do segundo conjunto de dados.

Quadrante	X (mm)	Y (mm)	Z (mm)	Total (mm)
Q1 (570 nm)	0,70	0,84	0,53	1,22
Q2 (525 nm)	0,65	0,84	0,67	1,25
Q3 (850 nm)	0,80	0,75	0,58	1,24
Q4 (550 nm)	0,68	0,85	0,67	1,28
Q5 (490 nm)	0,84	0,63	0,70	1,26
Q6 (560 nm)	0,82	0,87	0,45	1,28

Nenhum quadrante apresentou RMSEs em cada componente planimétrica e altimétrica superiores ao erro de distância do equipamento Faro, mas ficaram acima do efeito erro angular em até quatro vezes para os pontos de controle. Os pontos de verificação (Tabela 4.5) foram medidos nas extremidades da nuvem de pontos e não foram incluídos no ajustamento aplicado aos pontos de controle. No total, quatro pontos foram medidos em cada quadrante, utilizando as bandas centrais como referência.

Tabela 4.5 – Erros nos pontos de verificação do segundo conjunto de dados.

(continua)

Banda	Pontos	X (mm)	Y (mm)	Z (mm)		Banda	Pontos	X (mm)	Y (mm)	Z (mm)
490 nm (Q5)	P45	-0,23	1,83	-0,15		560 nm (Q6)	P45	1,55	0,04	0,04
	P46	0,42	-0,71	-0,03			P46	-0,07	-0,07	0,02
	P47	1,09	1,12	-0,90			P47	-1,58	-0,76	1,01
	P48	-0,25	0,54	-0,05			P48	0,46	-0,83	0,01
RMSE		0,61	1,16	0,46		RMSE		1,13	0,56	0,50
525 nm (Q2)	P45	-0,55	0,55	1,04		570 nm (Q1)	P45	1,08	-0,11	-0,04
	P46	0,02	-1,51	0,001			P46	0,23	-1,89	-0,30
	P47	0,70	0,30	-0,11			P47	-1,18	-0,80	-0,18
	P48	-0,04	0,26	-0,47			P48	-0,07	0,49	-0,17
RMSE		0,44	0,83	0,57		RMSE		0,81	1,05	0,19
550 nm (Q4)	P45	-0,55	0,73	-1,63		850 nm (Q3)	P45	-0,79	-0,21	0,12
	P46	-0,04	1,42	-0,01			P46	-0,02	-0,73	0,04
	P47	-0,48	0,17	-0,20			P47	1,22	0,98	-0,23
	P48	0,38	-0,79	-0,11			P48	0,33	-0,39	-0,26
RMSE		0,41	0,89	0,82		RMSE		0,74	0,65	0,18

Os erros em alguns pontos de verificação superaram o erro de distância do Faro, sendo notado principalmente em componentes planimétricas do P45 e P47 na banda 490 nm (Q5), a altimetria do P45 e planimetria do P46 da banda 525 nm (Q2) e 550 nm (Q4), planimetria e altimetria do P45 e P47 da banda 560 nm (Q6), a planimetria do P45, P46 e P47 da banda 570 nm (Q1) e planimetria do P47 da banda 850 nm (Q3). O P48 foi o único ponto a não apresentar erros superiores ao erro de distância do equipamento. Em relação a comparação com o efeito do erro angular, houve uma variação entre 0,005 (P46 em Z, da banda 525 nm) – 10,5 (P46 em Y, da banda 570 nm). O teste estatístico *T-student* é apresentado na Tabela 4.6.

Tabela 4.6 – Teste *t-student* para as bandas do segundo conjunto de dados.

Bandas	Elementos	X	Y	Z
490 nm (Q5)	t_x	0,800	1,289	1,378
525 nm (Q2)		0,117	0,205	0,351
550 nm (Q4)		0,807	0,821	1,285
560 nm (Q6)		0,139	1,788	1,123
570 nm (Q1)		0,032	1,131	3,317
850 nm (Q3)		0,439	0,237	0,826
	$t_{(3;0,1/2)}$	2,353		
	Conclusão	A hipótese nula não é rejeitada. Logo sem tendência.	A hipótese nula não é rejeitada. Logo, sem tendência.	A hipótese nula não é rejeitada. Logo, sem tendência. Exceto para o Q1.


A análise estatística dos pontos de verificação das imagens capturadas no segundo experimento revelou ausência de tendência nas componentes planimétrica e altimétrica, com exceção da banda de 570 nm (Q1), observando-se tendência na componente altimétrica. O ponto P46, na banda de 570 nm, apresentou o maior RMSE na coordenada Y, impactando o controle de qualidade no teste *t-student*. Os resultados foram considerados satisfatórios para a geração da nuvem de pontos multiespectral.

4.1.2 Filtragem de pontos espúrios

A filtragem de pontos espúrios nos dados melhora os resultados obtidos na geração da nuvem de pontos multiespectral. O primeiro conjunto de dados, coletado em um ambiente com vento intenso (Figura 4.3), apresentou pontos espúrios principalmente devido a essa


condição. O movimento das folhas aumentou o número de pontos (Figura 4.3 – zoom nas folhas), agravado pela configuração do equipamento, ajustado para a resolução mais alta de 814 pt/m².

Figura 4.3 – Filtragem de pontos espúrios para o cafeeiro (a) antes e (b) depois.



Os dados do cafeeiro apresentaram elevado nível de pontos espúrios devido ao vento. Com base nas observações, realizou-se uma avaliação para verificar se uma coleta com menor resolução poderia reduzir a frequência de pontos espúrios, mas mantendo uma boa representação da vegetação. Assim, no segundo conjunto de dados, variaram-se as configurações do LiDAR em quatro resoluções diferentes (Figura 4.4).


Figura 4.4 – Nuvem LiDAR com diferentes resoluções na coleta: (a) 102,1 pt/m², (b) 203,9 pt/m², (c) 407,8 pt/m² e (d) 814 pt/m².



A maior resolução (Figura 4.4.d) resultou na duplicação da posição das folhas no processo de registro entre as nuvens de pontos, enquanto as resoluções menores (Figura 4.4.a,b,c) não capturaram adequadamente os galhos mais finos da árvore. A diferença principal

entre as duas maiores resoluções (Figura 4.4.c,d) foi a capacidade de reconstrução tridimensional dos galhos finos. A resolução de 407,8 pt/m² (Figura 4.4.c) ofereceu a melhor descrição das folhas, com menor impacto do vento e redução dos ruídos. Entretanto, a resolução escolhida para as próximas etapas foi a mais elevada de 814 pt/m², por reconstruir os galhos menores (Figura 4.5).

Figura 4.5 – Filtragem de ruídos para a macieira (a) antes e (b) depois.



A duplicação das folhas também pode ser atribuída a possíveis erros de registro (Seção 4.1.3). Embora a duplicação das folhas tenha ocorrido, a aplicação do filtro de pontos espúrios MLS eliminou os pontos duplicados (Figura 4.5). Contudo, o filtro não elimina totalmente os ruídos provocados pelo vento e as folhas foram severamente afetadas, resultando numa reconstrução inferior à do cafeeiro (Figura 4.5.a). Além disso, apesar das feições representativas das folhas manterem-se satisfatórias, a qualidade geral pode ser impactada dependendo do contexto de aplicação.

4.1.3 Registro da nuvem LiDAR

Na Tabela 4.7, são apresentados os erros de registro das nuvens de pontos adquiridas com diferentes resoluções. Esta análise permite avaliar a precisão do alinhamento entre as varreduras, fornecendo subsídios para a compreensão da qualidade dos dados e a explicação de possíveis discrepâncias detectadas em etapas anteriores. Os erros reportados referem-se à média

dos erros nas correspondências entre nuvens de pontos, considerando o erro horizontal (XY) e erro vertical (Z).

Tabela 4.7 – Média dos erros nos registros entre nuvens de pontos.

Resolução (pt/m²)	Média XY (mm)	Média Z (mm)
102,1	4,8	1,3
203,9	3,5	1,1
407,8	4,6	0,6
814	2,0	0,4


Observa-se que o aumento na densidade de pontos impacta diretamente a etapa de registro. Com uma densidade maior, há um número maior de pontos em locais estáveis, como paredes, chão e outros objetos rígidos, em relação a alvos menores e mais complexos, como as folhas da planta. Assim, a média dos erros se torna menor devido aos pontos em locais estáveis. Além disso, a alta densidade de pontos aprimora significativamente a visualização de feições de menor escala, conforme exemplificado na seção anterior. No entanto, apesar dos menores erros observados no registro para a resolução mais alta, não é possível afirmar se a duplicação de folhas verificada nessa configuração é atribuível ao processo de registro, uma vez que os erros foram os mais baixos entre todas as resoluções analisadas. Por fim, com os dados preparados, o fluxo de processamento para a colorização é descrito nas próximas seções.

4.2 Nuvem de pontos colorida

4.2.1 Recorte da nuvem de pontos


No primeiro conjunto de dados, as imagens ópticas capturadas do cafeeiro cobrem um volume estreito da árvore. Em contraste, as imagens do segundo conjunto abrangem a macieira do topo ao solo e geram aproximadamente 700 mil pontos. O algoritmo *Viewing Frustum Culling* foi utilizado para recortar a nuvem de pontos do cafeeiro, reduzindo-a de 5 milhões para cerca de 800 mil pontos por imagem, diminuindo assim o custo computacional. Embora as 35 imagens ofereçam a sobreposição ideal para a fototriangulação, apenas 8 foram necessárias para a colorização completa do modelo (Figura 4.6).

Figura 4.6 – (a) Recortes usados na colorização e (b) mosaico das imagens.



A orientação exterior das imagens na banda de 550 nm (Q4) confirmou o bom alinhamento entre a posição e atitude das fotos e a posição do observador (Figura 4.7). O algoritmo gerou resultados consistentes para os outros quadrantes da câmara, apresentando variações mínimas entre os recortes, causados possivelmente pela paralaxe entre quadrantes. Esses resultados indicam uma boa definição da OE dos pontos, mesmo com um número reduzido de pontos de controle. Entretanto, os outros quadrantes foram descartados, devido a OE não estar confiável para a geração dos resultados, sendo necessário melhorar a coleta dos dados.

Figura 4.7 – Comparação entre o VFC aplicado a (a) nuvem de pontos em relação aos (b) limites da imagem.




Na Figura 4.7.a, observa-se o recorte adequado do algoritmo VFC para uma imagem do conjunto de dados. No entanto, a divergência na escala de observação e a dificuldade em distinguir entre o fundo da copa e as folhas impedem a correta associação das feições nos resultados. A próxima etapa envolve a criação de um mapa de visibilidade para a nuvem de pontos, com o custo computacional reduzido de, aproximadamente, 5 horas para apenas 21 minutos (redução em 14 vezes), devido a menor quantidade de pontos.

4.2.1.1 Orientação dos eixos

As orientações dos eixos de coordenadas dos sistemas adotados devem ser compatíveis. No caso do VFC, desenvolvido na área de Computação, os alinhamentos diferem daqueles comumente utilizados em Fotogrametria. Se os eixos não estiverem corretamente alinhados, os ângulos de Euler obtidos na fototriangulação não poderão ser usados nas etapas seguintes. A Figura 4.8 apresenta a disposição dos eixos de coordenadas conforme o manual do Agisoft Metashape (Figura 4.8.a) e conforme a documentação de Krishnan (2023) (Figura 4.8.b).

Figura 4.8 – Sistema de coordenadas da câmara no (a) Agisoft Metashape e (b) no VFC.



Os eixos de coordenadas utilizados no VFC não são compatíveis com o sistema utilizado no Agisoft Metashape, impactando diretamente os ângulos de Euler responsáveis pela orientação das imagens. Para corrigir essa discrepância, torna-se necessário ajustar a rotação em 90° no sentido horário para φ (rotação m torno do eixo y), garantindo o alinhamento correto dos sistemas de coordenadas.

4.2.2 Rotulação de pontos oclusos

Após a aplicação do VFC, ainda permanecem pontos oclusos na imagem em relação à nuvem LiDAR, resultantes de áreas não visíveis a partir da perspectiva do sensor óptico. Esses pontos oclusos podem ser identificados e rotulados como oclusos utilizando um mapa de visibilidade, com o operador *Hidden Points Removal*. No caso do cafeeiro, os dados foram coletados sem variação de inclinação, com folhas e galhos situados em planos próximos. O parâmetro (ϵ) para este cenário foi testado e alguns resultados são mostrados na Figura 4.9 e detalhada a escolha na Figura 4.10, sendo pontos em preto considerados oclusos e em cinza os visíveis.

Figura 4.9 – Análise de um ponto de vista; teste do operador na nuvem de pontos variando o parâmetro (ϵ) como:

(a) $\epsilon = 1$, (b) $\epsilon = 2$, (c) $\epsilon = 3$ e (d) $\epsilon = 4$ para o cafeeiro.





Figura 4.10 – Análise de uma pequena área da (a) imagem escolhida como ponto de vista, sendo (a) a visão da rotulação de pontos oclusos e (b) os pontos oclusos de outro ponto de vista.



Embora o parâmetro $\epsilon = 4$ tenha demonstrado eficácia na rotulação de pontos oclusos (seta vermelha da Figura 4.10.c, é o galho escondido da Figura 4.10.a), alguns pontos visíveis foram classificados como oclusos (círculos vermelhos da Figura 4.10.b). É possível futuramente explorar outras técnicas, como Aprendizado Profundo para melhorar estes resultados (Kirgo et al., 2023). Entretanto, esta análise das oclusões, baseada exclusivamente na observação visual das imagens de referência, resulta em uma avaliação subjetiva, não

permitindo a quantificação precisa das oclusões. A folha da Figura 4.10.a foi desenhada na Figura 4.10.b para melhor identificação dos alvos.

O processamento realizado no primeiro conjunto de dados foi replicado para o segundo. Para a coleta variou-se a inclinação nas sequências de fotografias. A planta analisada apresenta crescimento irregular, o que contrasta com a uniformidade observada no primeiro conjunto de dados. Com a variação do ponto de vista, tornaram-se evidentes os diferentes planos das feições (galhos, folhas e vaso) da nuvem de pontos, optando-se por subdividir em partes menores (Seção 3.3.4.1), através da aplicação da identificação da vizinhança dos pontos com base em critérios de distância e número mínimo de vizinhos (Figura 4.11). Caso as imagens fossem tomadas a uma distância câmara-objeto menor, o uso da técnica VFC poderia substituir a técnica de subdivisão (Seção 3.3.4.1) e contornar o problema dos dados irregulares. Os resultados para o HPR aplicado aos dados são apresentados na Figura 4.12.

Figura 4.11– Subdivisão em partes menores.





Figura 4.12 – Recorte do VFC com $\epsilon = 4$ e a subtração com o VFC da macieira, representados os pontos oclusos (preto) e visíveis (cinza).



Na Figura 4.12, o sistema de coordenadas da câmara refere-se aos dados de OE, baseado no *software* Agisoft Metashape (Seção 4.2.1.1), e o da nuvem de pontos em um sistema de coordenadas arbitrário. O parâmetro ideal (ϵ) permaneceu inalterado no segundo conjunto de dados, sugerindo uma escolha condicionada ao volume de dados em vez da estrutura específica dos elementos analisados. Entretanto, alguns pontos visíveis da vegetação foram considerados oclusos, como ocorreu no primeiro conjunto de dados. No vaso, que é delimitado por faces regulares, a ocorrência de pontos visíveis considerados oclusos apresentou-se menor. Ao remover os pontos oclusos, as nuvens de pontos dos conjuntos de dados podem ser colorizadas.

4.2.3 Colorização


Para atribuir valores espectrais aos pontos da nuvem LiDAR, é necessário projetar os pontos da nuvem 3D para as imagens e interpolar os valores de ND. A nuvem de pontos RGB (Figura 4.13), gerada a partir dos dados do cafeeiro, recebeu a colorização com base em oito imagens do quadrante Q4. Observa-se uma alta sobreposição entre as nuvens de pontos recortadas pelo algoritmo VFC.

Figura 4.13 – A nuvem LiDAR RGB (430 nm, 550 nm, 650 nm) para o cafeeiro.




Alguns alvos deslocaram-se durante o intervalo entre as coletas do LiDAR e da câmara, sendo possível visualizar a diferença de posição na nuvem 3D colorizada (Figura 4.14). Esses alvos foram excluídos do processo de fototriangulação. Os pequenos deslocamentos nas folhas podem ser atribuídos ao movimento causado pelo vento, considerando os tempos de coleta da câmara e LiDAR distintos (não síncronos).

Figura 4.14 – Exemplo de alvo que mudou de posição entre as coletas do LiDAR e câmara, em (a) a imagem capturada, (b) a nuvem de pontos e (c) a colorização.



Na Figura 4.14.a comparando-se com a Figura 4.14.b nota-se o alvo um pouco mais inclinado para baixo, resultando no deslocamento encontrado na Figura 4.14.c. A discrepância observada na colorização pode ser objeto de investigação em trabalhos futuros, visando a identificação de métodos para mitigá-los. Para aprimorar a colorização, testou-se a redução do recorte, como descrito na Seção 4.2.2 para a macieira. A Figura 4.15 apresenta uma imagem (Figura 4.15.a) utilizada na colorização de um recorte VFC (Figura 4.15.b), juntamente com a versão de recortes menores (Figura 4.15.c).

Figura 4.15 – (a) Imagem original, (b) nuvem 3D colorida com recorte do VFC e (c) com recortes menores.




Os resultados indicam inconsistências. Na Figura 4.15.a, a seta 1 sinaliza uma possível sobreposição de uma folha sobre a outra, provavelmente devido a erros de orientação das imagens. No entanto, a área da folha inferior, onde ocorre a sobreposição, não foi totalmente reconstruída pela varredura com o TLS, devido a oclusão, mas aparece na colorização da Figura 4.15.b. Ao realizar a segmentação da nuvem de pontos em partes menores, o resultado da colorização revelou mais manchas de cor salmão, também visíveis na imagem original (seta 2).

Ainda há um leve desalinhamento no resultado: a seta vermelha na Figura 4.15.c sugere que a mancha deveria estar mais próxima da extremidade da folha, mas está deslocada.


Isso pode ter sido causado pela determinação da orientação interior, o que foi parcialmente mitigado ao subdividir a nuvem de pontos em seções menores. Contudo, deslocamentos ainda são perceptíveis nas extremidades das folhas, possivelmente devido a problemas no processo de fototriangulação (orientação exterior) e à interferência do vento. Além disso, a inconsistência na sobreposição dos valores atribuídos de ND comprometeu a concatenação eficiente dos dados, impedindo a realização de um ajuste radiométrico. A Figura 4.16 ilustra uma folha de cada imagem utilizada na colorização.

Figura 4.16 – Folhas colorizadas em áreas de sobreposição entre as imagens: (a) 9010 e 9016; (b) 9016 e 9024; (c) 9024 e 9049; (d) 9049 e 9059; (e) 9059 e 9057; (f) 9148 e 9100.




A sobreposição das fotos resultou em deslocamentos geométricos e divergências radiométricas acentuados dos NDs, exceto nos exemplos apresentados nas Figura 4.16.a sendo o menos afetado. Para adequar os resultados, os deslocamentos geométricos deveriam ser minimizados e a radiometria ser suavizada através de um ajuste radiométrico. O segundo conjunto de dados proporcionou uma colorização de melhor qualidade (Figura 4.17), devido à maior quantidade de pontos de apoio medidos, permitindo a obtenção de parâmetros de OE de melhor qualidade com RMSEs menores nos pontos de verificação.

Figura 4.17 – Nuvens 3D multiespectrais para os quadrantes: (a) Q1, (b) Q2, (c) Q3, (d) Q4, (e) Q5 e (f) Q6.



A análise visual dos resultados confirma a correta colorização dos pontos em todos os casos. Entretanto, o controle de qualidade indicou uma tendência na componente altimétrica da banda Q1 (570 nm), cuja influência não apresentou desvios significativos no resultado final, mantendo a integridade do processamento. Portanto, a avaliação da orientação das imagens em sobreposição é fundamental para identificar potenciais problemas (Figura 4.18).


Figura 4.18 – Alvos colorizados em sobreposição entre as imagens orientadas 7345/7350 e 7375/7417, nos quadrantes: (a) Q1, (b) Q2, (c) Q3, (d) Q4, (e) Q5 e (f) Q6.



Na Figura 4.18.a, 4.18.c, e 4.18.f, observam-se variações no deslocamento das feições na área de sobreposição entre as nuvens de pontos, com maior magnitude em comparação aos quadrantes centrais Q2 (525 nm) e Q5 (490 nm), e quadrante inferior esquerdo Q4 (550 nm). Entretanto, o Q3 (850 nm) (Figura 4.18.c) e o Q6 (560 nm) (Figura 4.18.f) não


apresentou problemas no controle de qualidade, conforme análise estatística. Destaca-se o Q4 (550 nm) como o melhor resultado para uma nuvem de pontos espectral, resultado consistente com o primeiro conjunto de dados. Além disso, devido ao ambiente dinâmico, a posição das folhas no topo da árvore foi a mais afetada na colorização (Figura 4.19).

Figura 4.19 – Movimento das folhas notado no topo da árvore colorizadas para os quadrantes: (a) Q1, (b) Q2, (c) Q3, (d) Q4, (e) Q5 e (f) Q6.



As cores vibrantes do Q1 (Figura 4.19.a) e Q5 (Figura 4.19.e) demonstram uma forte influência das bandas 710 nm e 735 nm, respectivamente, tornando mais evidente o movimento das folhas, devido à saturação da cor. A tonalidade observada indica que foi atribuída as cores do céu (azul é dominante). A possível movimentação das folhas é indicada pela ausência desse fenômeno em outros pontos de vista, conforme observado na Figura 4.20.

Figura 4.20 – Folhas no topo da árvore colorizadas para os quadrantes: (a) Q1, (b) Q2, (c) Q3, (d) Q4, (e) Q5 e (f) Q6.




Além disso, devido à influência do vento e à presença de folhas de pequeno porte na planta, a reconstrução tridimensional com dados LiDAR apresentou resultados inferiores em comparação ao primeiro conjunto de dados. A densidade reduzida de pontos nas folhas resultou na incapacidade de capturar detalhes finos da superfície, como variações sutis de elevação e rugosidade, comprometendo a reprodução da textura da planta. Para melhorar a qualidade da reconstrução seria necessário evitar fortes ventos.

4.2.3.1 Modelo completo

A construção do modelo completo idealmente inclui um ajuste radiométrico dos dados. Contudo, como evidenciado na Figura 4.16, há um deslocamento significativo nos NDs durante a sobreposição das nuvens de pontos coloridas. Para mitigar esse problema, é possível recortar as áreas de sobreposição (Figura 4.21.a), preservando parcialmente a contribuição individual das imagens (Figura 4.21.b), representado por cores diferentes.

Figura 4.21 – Modelo completo da (a) nuvem de pontos colorida (Q4) e as (b) cores com a representação da contribuição individual das imagens.



A abordagem é viável apenas para o primeiro conjunto de dados devido à metodologia de coleta. Em cafeeiros, as árvores são plantadas em fileiras contínuas, impossibilitando a coleta de dados com variação de posição da câmara em 360°, abordagem utilizada no caso da macieira isolada em vaso. Em contrapartida, no segundo conjunto, torna-se necessário aplicar um ajuste radiométrico para a criação de um modelo completo, sendo uma recomendação para trabalhos futuros.

4.3 Discussão

No primeiro conjunto de dados, a nuvem de pontos LiDAR resultou em uma nuvem de pontos RGB, devido à disponibilidades de poucas bandas com qualidade compatível com o processo. Um dos principais desafios foi identificar a causa da falha na orientação exterior das imagens, apesar desta orientação ter sido adequada para a geração dos recortes (VFC). A hipótese predominante é a imprecisão na determinação das orientações interior e exterior das imagens, decorrente da calibração realizada em serviço, com poucos pontos de apoio. Para investigar esta hipótese, compararam-se as nuvens densas geradas pelo Agisoft Metashape com a nuvem LiDAR para verificar se o deslocamento observado na colorização também se manifestava nas comparações entre as nuvens densas. As medições dos pontos de controle P3,

P9 e P11 foram empregadas como referência, juntamente com um ponto central adicional medido na nuvem LiDAR, para assegurar uma distribuição adequada na análise de deslocamentos (Figura 4.22 e Tabela 4.8).

Figura 4.22 – Discrepâncias entre pontos medidos nas nuvens LiDAR e óptica em um cafeeiro.





Tabela 4.8 – RMSE das discrepâncias entre as coordenadas do LiDAR e nuvem densa das bandas no cafeeiro.

Banda	RMSE em X (mm)	RMSE em Y (mm)	RMSE em Z (mm)
490 nm	5,5	8,3	4,7
525 nm	4,5	25,6	5,9
550 nm	5,1	5,8	2,1
560 nm	9,2	18,3	4,8
570 nm	9,7	9,9	4,8
850 nm	28,6	17,3	5,6


A banda de 550 nm (Q4) exibiu a menor discrepância nas componentes planimétricas e altimétricas, enquanto as demais bandas apresentaram deslocamentos significativos em uma ou ambas as componentes. A OE do Q4, ainda que pouca precisa, permitiu a colorização satisfatória da nuvem de pontos. Esses resultados corroboram a hipótese de a orientação interior influenciar significativamente a colorização e a obtenção completa da nuvem multiespectral para o cafeeiro. O resultado obtido com a colorização de outros quadrantes é apresentado na Figura 4.23.

Figura 4.23 – Nuvem de pontos colorizada de uma folha para os quadrantes: (a) Q1, (b) Q2, (c) Q3, (d) Q4, (e) Q5 e (f) Q6.



Devido aos erros na OE do Q3 (850 nm) (Figura 4.23.c) ocorreu a ausência da folha no campo de visão da imagem. Os quadrantes Q2 (525 nm), Q4 (550 nm) e Q6 (560 nm) apresentaram resultados semelhantes (Figura 4.23.b, 4.23.d e 4.23.f). No entanto, no Q6 ainda são perceptíveis distorções na sombra projetada (seta em branco), enquanto Q2 e Q4 mostram-se compatíveis (Figura 4.23.b e 4.23.d). Contudo, apenas o Q4 permitiu a colorização da nuvem de pontos, baseado no ponto de vista de 8 imagens, resultando em um modelo completo. A Figura 4.24 ilustra a folha de outro recorte sequencial realizado pelo VFC para os quadrantes Q2 (Figura 4.24.a) e Q6 (Figura 4.24.b). Caso uma das imagens seja omitida, a base entre as imagens não sustenta a formação de um modelo completo, resultando na ausência de partes da nuvem 3D.

Figura 4.24 – Exemplo de folhas para os quadrantes (a) Q2 e (b) Q6.



Ao usar as imagens do Q2 foi possível fazer a colorização para seis estações e com o Q6 para quatro estações. Todas as outras sofrem o efeito da orientação imprecisa das imagens. A seta da Figura 4.24.a e Figura 4.24.b representam o deslocamento dos valores de ND e, possivelmente, o fundo da copa da árvore preenche o espaço onde deveria ser ocupado pela folha. O problema pode ser atribuído, principalmente, à orientação interior, determinada em serviço, bem como a falta de pontos de controle para uma orientação exterior mais adequada.

As avaliações foram estendidas ao segundo conjunto de dados, primeiramente, analisando as nuvens densas geradas pelo Agisoft Metashape (Figura 4.25 e Tabela 4.9).

Figura 4.25 – Discrepâncias entre pontos medidos nas nuvens LiDAR e óptica na macieira.





Tabela 4.9 – RMSE das discrepâncias entre as coordenadas do LiDAR e nuvem densa das bandas na macieira.

Banda	RMSE em X (mm)	RMSE em Y (mm)	RMSE em Z (mm)
490 nm	5,8	2,9	1,4
525 nm	4,0	2,7	2,5
550 nm	3,5	2,7	1,9
560 nm	4,3	2,9	2,8
570 nm	4,1	0,6	1,7
850 nm	6,3	6,5	5,0

As medições realizadas nas nuvens de pontos da macieira (LiDAR e óptica) revelaram deslocamentos milimétricos. Conforme ilustrado na Figura 4.25, as maiores discrepâncias concentraram-se na região posterior do vaso, demonstrando possíveis erros sistemáticos. Conforme ilustrado e discutido na Figura 4.2 (Seção 4.1), para minimizar a inclusão de pontos muito distantes do alvo principal, evitou-se a medição na região posterior do vaso. As análises apresentadas demonstram, assim, que a visualização da nuvem de pontos multiespectral no *software* CloudCompare deve ser restrita a cada quadrante individualmente, pois a combinação entre as bandas resulta em uma representação imprecisa das posições dos

números digitais. Além disso, uma das imagens selecionadas para a colorização, contemplando a região posterior do vaso, apresentou deslocamentos acentuados quando sobreposta a outro ponto de vista, de uma nuvem colorida (Figura 4.26). Assim como foi comparado na Figura 4.18.

Figura 4.26 – Deslocamento acentuado entre dois pontos de vista (p1 e p2) da nuvem de pontos para as bandas: (a) 490 nm (Q5), (b) 525 nm (Q2), (c) 550 nm (Q4), (d) 560 nm (Q6), (e) 570 nm (Q1) e (f) 850 nm (Q3).



O efeito, visto no ponto de vista p2, pode ser causado por problemas de alinhamento entre as imagens (orientação das imagens), resultando na sobreposição incorreta entre nuvens de pontos, com diferentes pontos de vista. O problema pode indicar falhas na orientação das imagens, decorrentes de pouca sobreposição entre as imagens, pequeno número de pontos de apoio e problemas na estimação da orientação interior. A seta na Figura 4.26.d indica onde aparece a colorização da parede amarela ao fundo da imagem, provando o deslocamento dos valores espectrais. As imagens utilizadas na densificação da nuvem densa no Agisoft, para a parte posterior, indicavam previamente discrepâncias de coordenadas significativas em relação a referência (LiDAR), conforme discutido na Figura 4.21. Portanto, a colorização da nuvem de pontos com essa imagem foi descartada. Assim, optou-se por utilizar a imagem capturada na mesma posição durante a segunda coleta de 360° com uma leve variação na inclinação. Observou-se que algumas imagens apresentaram erros durante o alinhamento. No entanto, a colorização naquela posição foi recuperada utilizando outra imagem, com uma base menor, para substituir o local afetado.

5. CONCLUSÕES E RECOMENDAÇÕES

Nesta dissertação, foi desenvolvida e avaliada uma metodologia para a colorização de nuvens LiDAR terrestres, integrando dados tridimensionais com informações espectrais para criar um modelo multiespectral. A técnica proposta enfrenta os desafios associados à fusão de dados de diferentes sensores. O fluxo de processamento calcula a projeção de um ponto da nuvem LiDAR na e atribui o correspondente ND a este ponto utilizando o operador HPR para minimizar a duplicação de dados; emprega o método VFC para otimizar a performance computacional, alcançando uma melhoria de quatorze vezes em comparação ao processamento sem segmentações menores. Os resultados obtidos nos dois conjuntos de dados foram significativamente afetados pelas condições de coleta, devido à forte influência do vento. Ainda assim, apresentaram resultados relevantes para a geração de nuvens de pontos multiespectrais.

A coleta do primeiro conjunto de dados enfrentou desafios significativos, particularmente devido à insuficiência de pontos de controle, comprometendo a precisão da orientação das imagens. Apenas o quadrante Q4 não sofreu com os efeitos da orientação interior inadequada. Pequenos deslocamentos dos alvos utilizados como pontos de controle, resultantes de interferência humana ou fatores naturais, também contribuíram para a redução da precisão. A decisão de evitar o uso de esferas como pontos de controle demonstrou-se benéfica, mitigando problemas adicionais. Entretanto, a sobreposição entre as imagens, embora substancial, revelou-se insuficiente para substituir aquelas com orientações incorretas ou distorções. Quanto à coleta com o LiDAR, mesmo com a interferência do vento, as folhas e galhos foram capturados de modo eficaz, garantindo uma descrição geométrica completa. Diante dos problemas identificados na primeira coleta, realizou-se uma segunda coleta, com o intuito de contornar as limitações e explorar soluções mais eficazes.

No segundo conjunto de dados, embora melhorias tenham sido observadas em relação às deficiências do primeiro conjunto, persistem desafios, especialmente na coleta de dados LiDAR. A intensa influência do vento e o tamanho reduzido das folhas resultaram em uma reconstrução LiDAR menos detalhada, comprometendo a captura de variações sutis na superfície, como pequenas elevações e rugosidades, e afetando a precisão na representação da textura. A aplicação do operador HPR exigiu a subdivisão dos dados em partes menores devido à irregularidade das folhas e galhos, ao contrário do primeiro conjunto, onde a geometria apresentava maior uniformidade. A redução da distância entre a câmara e o objeto teria possibilitado a utilização do método VFC, realizando uma segmentação prévia dos dados

correspondente ao tamanho da imagem e eliminando a necessidade de uma etapa adicional. Esses fatores ressaltam a importância de ajustes na configuração de coleta para otimizar a qualidade dos modelos gerados. A coleta de dados, entretanto, revelou-se a mais adequada para a geração da nuvem de pontos multiespectral.

A ausência de calibração prévia da câmara destacou-se como um fator crítico, evidenciando a importância de adotar estratégias robustas para garantir a qualidade dos dados, especialmente em cenários com escassez de pontos de controle. Implementar a calibração antes da coleta é recomendado como prática universal, considerando a inviabilidade da presença abundante de pontos estáticos em ambientes de vegetação, desde que se garanta que a câmara permaneça estável mecanicamente desde o momento da calibração até a coleta. Uma exceção ao uso de pontos de controle ocorre quando a câmara está fixada ao TLS, sendo necessário determinar a orientação relativa entre os sensores, procedimento realizado juntamente com a calibração. Além disso, discrepâncias nas colorizações observadas em algumas nuvens de pontos, possivelmente causadas pelos erros na etapa de fototriangulação no *software* Agisoft Metashape, sugerem a necessidade de um maior entendimento sobre a coleta de dados em 360°, para investigações adicionais e aperfeiçoamento da técnica. A coleta com maior sobreposição entre imagens, ou a repetição do processo em 360° ao redor da planta, pode oferecer soluções aos problemas de discrepâncias nas imagens, sendo uma opção para ambos os conjuntos de dados analisados. Para futuros experimentos, recomenda-se: calibração prévia da câmara, melhorar a distribuição geométrica dos pontos de controle, aumento da sobreposição entre as imagens ou repetição da coleta com pequenas variações de inclinação, utilização da maior resolução do LiDAR, mesmo com a alta presença de pontos espúrios, e a aplicação do VFC como ferramenta para reduzir o custo computacional em grandes conjuntos de dados.

O estudo introduziu um fluxo de processamento para integração de dados de diferentes sensores utilizando uma câmara multiespectral e integrando dados tridimensionais para gerar nuvens de pontos multiespectrais. Um desafio futuro envolve o ajuste radiométrico necessário para alcançar um modelo completo, o que exige garantir deslocamentos mínimos entre as imagens, demonstrado com sucesso no segundo conjunto de dados e apresentado como modelo ideal de coleta. Além disso, explorar técnicas mais avançadas de ajuste radiométrico, como uso da BRDF (Seção 2.3.4) para obter o modelo completo e gerar um produto. Será necessária uma etapa adicional de aplicação da linha empírica para transformação dos valores de ND, assegurando uma representação mais próxima da resposta espectral dos alvos.

REFERÊNCIAS BIBLIOGRÁFICAS

- AGISOFT METASHAPE. Disponível em: <<https://www.agisoft.com/>>. Acesso em: 20 jan. 2024.
- AGROWING. Disponível em: <<https://agrowing.com/>>. Acesso em: 20 jan. 2024.
- AKENINE-MÖLLER, T.; HAINES, E.; HOFFMAN, N. Real-time rendering 3rd edn. **AK Peters, Natick**, p. 658-680, 2008.
- ALEXA, M.; BEHR, J.; COHEN-OR, D.; FLEISHMAN, S.; LEVIN, D.; SILVA, C. T. Computing and rendering point set surfaces. **IEEE Transactions on Visualization and Computer Graphics**, v. 9, n. 1, p. 3–15, 2003. <https://doi.org/10.1109/TVCG.2003.1175093>.
- AMENTA, N.; BERN, M.; KAMVYSSELIS, M. A new Voronoi-based surface reconstruction algorithm. **Proceedings of the 25th annual conference on Computer graphics and interactive techniques - SIGGRAPH '98**, p. 415–421, 1998. <https://doi.org/10.1145/280814.280947>.
- ANDERSON, J. E.; PLOURDE, L. C.; MARTIN, M. E.; BRASWELL, B. H.; SMITH, M.-L.; DUBAYAH, R. O.; HOFTON, M. A.; BLAIR, J. B. Integrating waveform lidar with hyperspectral imagery for inventory of a northern temperate forest. **Remote Sensing of Environment**, v. 112, n. 4, p. 1856–1870, 2008.
- ANDRADE, J. **Fotogrametria**. 1º edição ed. [s.l.] SBEE, 1998.
- APPEL, A. Some techniques for shading machine renderings of solids. **Proceedings of the April 30–May 2, 1968, spring joint computer conference**, p. 37–45, 1968.
- ARGUETA, C. Filtering a Point Cloud to Match the Field of View of the Camera. Disponível em: <<https://medium.com/@kidargueta/filtering-a-point-cloud-to-match-the-field-of-view-of-the-camera-ccab0d189b58>>. Acesso em: 20 jan. 2024.
- ASSARSSON, U.; MOLLER, T. Optimized view frustum culling algorithms for bounding boxes. **Journal of graphics tools**, v. 5, n. 1, p. 9–22, 2000.
- BALTSAVIAS, E. P. Airborne laser scanning: basic relations and formulas. **ISPRS Journal of photogrammetry and remote sensing**, v. 54, n. 2–3, p. 199–214, 1999.
- BARBER, C. B.; DOBKIN, D. P.; HUHDANPAA, H. The quickhull algorithm for convex hulls. **ACM Transactions on Mathematical Software (TOMS)**, v. 22, n. 4, p. 469–483, 1996.
- BISHOP, L.; EBERLY, D.; WHITTED, T.; FINCH, M.; SHANTZ, M. Designing a PC game engine. **IEEE Computer Graphics and Applications**, v. 18, n. 1, p. 46–53, 1998.
- BITTNER, J.; WONKA, P. Visibility in computer graphics. **Environment and Planning B: Planning and Design**, v. 30, n. 5, p. 729–755, 2003.
- BLINN, J. F. Backface culling snags (rendering algorithm). **IEEE Computer Graphics and Applications**, v. 13, n. 6, p. 94–97, 1993.

BROWN, D. C. Decentering distortion of lenses. **Photogrammetric Engineering and Remote Sensing**, 1966.

CATMULL, E. E. A subdivision algorithm for computer display of curved surfaces. **World Journal of Mechanics**, 1974.

CHANDELIER, L.; MARTINOTY, G. Radiometric aerial triangulation for the equalization of digital aerial images and orthoimages. **Photogramm. Eng. Remote Sens**, v. 75, n. 2, p. 193–200, 2009.

COHEN-OR, D.; CHRYSANTHOU, Y. L.; SILVA, C. T.; DURAND, F. A survey of visibility for walkthrough applications. **IEEE Transactions on Visualization and Computer Graphics**, v. 9, n. 3, p. 412–431, 2003.

CONRADY, A. E. Lens-systems, decentered. **Monthly notices of the royal astronomical society**, v. 79, p. 384–390, 1919.

CROMBEZ, N.; CARON, G.; MOUADDIB, E. 3D point cloud model colorization by dense registration of digital images. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 40, p. 123–130, 2015.

DIEBEL, J. R.; THRUN, S.; BRÜNIG, M. A Bayesian method for probable surface reconstruction and decimation. **ACM Transactions on Graphics**, v. 25, n. 1, p. 39–59, 2006. <https://doi.org/10.1145/1122501.1122504>.

DIRECTMODEL. DirectModel: 1.0 Specification. Corvalis: Hewlett Packard Company, 1990.

FLEISHMAN, S.; COHEN-OR, D.; SILVA, C. T. Robust moving least-squares fitting with sharp features. **ACM Transactions on Graphics**, v. 24, n. 3, p. 544–552, 2005. <https://doi.org/10.1145/1073204.1073227>.

FUCHS, H.; KEDEM, Z. M.; NAYLOR, B. F. On visible surface generation by a priori tree structures. **Proceedings of the 7th annual conference on Computer graphics and interactive techniques**, p. 124–133, 1980.

GALO, M. **Processamento Digital de Imagens: Transformações e Reamostragem**. [s.l.] Universidade Estadual Paulista, Presidente Prudente. Notas de aula. Processamento Digital de Imagens – Engenharia Cartográfica e de Agrimensura, 2019.

GALO, M.; CAMARGO, P. DE O. Utilização do GPS no controle de qualidade de cartas. **Congresso Brasileiro de Cadastro Técnico Multifinalitário**, v. 1, p. 41–8, 1994.

GALO, M.; TOMMASELLI, A. **Calibração de Câmaras**. [s.l.] Gráfica Viena, 2011. <https://doi.org/10.13140/2.1.2759.7764>.

GEERLING, G. W.; LABRADOR-GARCIA, M.; CLEVERS, J.; RAGAS, A. M. J.; SMITS, A. J. M. Classification of floodplain vegetation by data fusion of spectral (CASI) and LiDAR data. **International Journal of Remote Sensing**, v. 28, n. 19, p. 4263–4284, 2007.

GEHRKE, S. COMBINED GEOMETRIC/RADIOMETRIC POINT CLOUD MATCHING FOR SHEAR ANALYSIS. **The International Archives of the Photogrammetry, Remote**

Sensing and Spatial Information Sciences, v. XXXIX-B3, p. 103–108, 2012. <https://doi.org/10.5194/isprsarchives-XXXIX-B3-103-2012>.

GHARIBI, H.; HABIB, A. True orthophoto generation from aerial frame images and LiDAR data: An update. **Remote Sensing**, v. 10, n. 4, p. 581, 2018.

GHOSH, S. K. **Visibility algorithms in the plane**. [s.l.] Cambridge university press, 2007.

GONZALEZ, R. C.; WOODS, R. C. **Processamento digital de imagens**. [s.l.] Pearson Educación, 2009.

GONZÁLEZ-PIQUERAS, J.; HERNÁNDEZ, D.; FELIPE, B.; ODI, M.; BELMAR, S.; VILLA, G.; DOMENECH, E. Radiometric aerial triangulation approach. A caase study for the Z/I DMC. **Proceedings of the EuroCOW; Castelldefels, Spain**, 2010.

GRAHAM, R.; KOH, A. **Digital Aerial Survey: Theory and Practice**. [s.l.] CRC Press, 2002.

HOPPE, H.; DEROSE, T.; DUCHAMP, T.; MCDONALD, J.; STUETZLE, W. Surface reconstruction from unorganized points. **SIGGRAPH**, 1992. <https://doi.org/10.1145/133994.134011>.

HUDAK, A. T.; LEFSKY, M. A.; COHEN, W. B.; BERTERRETCHE, M. Integration of lidar and Landsat ETM+ data for estimating and mapping forest canopy height. **Remote sensing of Environment**, v. 82, n. 2–3, p. 397–416, 2002.

JENKE, P.; WAND, M.; BOKELOH, M.; SCHILLING, A.; STRASSER, W. Bayesian Point Cloud Reconstruction. **Computer Graphics Forum**, v. 25, n. 3, p. 379–388, 2006. <https://doi.org/10.1111/j.1467-8659.2006.00957.x>.

KAMPE, T. U.; JOHNSON, B. R.; KUESTER, M. A.; KELLER, M. NEON: the first continental-scale ecological observatory with airborne remote sensing of vegetation canopy biochemistry and structure. **Journal of Applied Remote Sensing**, v. 4, n. 1, p. 043510, 2010. <https://doi.org/10.1117/1.3361375>.

KATZ, S.; TAL, A.; BASRI, R. Direct visibility of point sets. **ACM SIGGRAPH 2007 papers, SIGGRAPH '07**. p. 24– es, 2007. <https://doi.org/10.1145/1275808.1276407>.

KEOGH, M.; HENRY, M. The Implications of Digital Agriculture and Big Data for Australian Agriculture. . Em: RESEARCH REPORT. Australian Farm Institute, Sydney,; 2016.

KIRGO, M.; TERRASSE, G.; THIBAUT, G.; OVSJANIKOV, M. ReVISOR: ResUNets with visibility and intensity for structured outlier removal. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 202, p. 184–204, 2023.

KRAUS, K. **Photogrammetry, Vol. 1: Fundamentals and Standard Processes**. Bonn: Dümmlers, 1993.

KRISHNAN, A. Point Cloud Library (PCL). Disponível em: <https://pointclouds.org/documentation/frustum__culling_8h_source.html>. Acesso em: 20 jan. 2024.

LIU, H.; LEE, S.-H.; CHAHL, J. S. Registration of multispectral 3D points for plant inspection. **Precision Agriculture**, v. 19, n. 3, p. 513–536, 2018. <https://doi.org/10.1007/s11119-017-9536-3>.

LORENSEN, W. E.; CLINE, H. E. Marching cubes: a high resolution 3D surface construction algorithm. Em: **Seminal graphics: pioneering efforts that shaped the field, Volume 1**. New York, NY, USA: Association for Computing Machinery, 1998. v. Volume 1p. 347–353.

LUGNANI, J. B. **Introdução à fototriangulação**. Curitiba: UFPR, 1987: [s.n.].

MATHWORKS. Computing the Convex Hull - MATLAB & Simulink. Disponível em: <<https://www.mathworks.com/help/matlab/math/computing-the-convex-hull.html>>. Acesso em: 21 jan. 2024.

MEDEROS, B.; AMENTA, N.; VELHO, L.; DE FIGUEIREDO, L. H. Surface Reconstruction for Noisy Point Clouds. **Symposium on Geometry Processing**, p. 53–62, 2005.

MUNDT, J. T.; STREUTKER, D. R.; GLENN, N. F. Mapping Sagebrush Distribution Using Fusion of Hyperspectral and Lidar Classifications. **Photogrammetric Engineering & Remote Sensing**, v. 72, n. 1, p. 47–54, 2006. <https://doi.org/10.14358/PERS.72.1.47>.

NIELSEN, M. Ø. **True orthophoto generation**. Master's Thesis—[s.l.] Technical University of Denmark, DTU, DK-2800 Kgs. Lyngby, Denmark, 2004.

OKHRIMENKO, M.; COBURN, C.; HOPKINSON, C. Investigating Multi-Spectral Lidar Radiometry: An Overview of the Experimental Framework. **IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium**, p. 8745–8748, 2018. <https://doi.org/10.1109/IGARSS.2018.8517922>.

PACKALÉN, P.; SUVANTO, A.; MALTAMO, M. A Two Stage Method to Estimate Species-specific Growing Stock. **Photogrammetric Engineering & Remote Sensing**, v. 75, n. 12, p. 1451–1460, 2009. <https://doi.org/10.14358/PERS.75.12.1451>.

PALLISTER, K. Game Programming Gems 2. **Charles River Media**, v. 5, p. 65–76, 2005. <https://doi.org/10.5555/516343>.

POPESCU, S.; WYNNE, R. Seeing the Trees in the Forest: Using Lidar and Multispectral Data Fusion with Local Filtering and Variable Window Size for Estimating Tree Height. **Photogrammetric Engineering and Remote Sensing**, v. 70, p. 589–604, 2004. <https://doi.org/10.14358/PERS.70.5.589>.

PROS, A.; COLOMINA, I.; NAVARRO, J. A.; ANTEQUERA, R.; ANDRINAL, P. Radiometric block adjustment and digital radiometric model generation. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 40, p. 293–298, 2013.

RIVERA, G.; PORRAS, R.; FLORENCIA, R.; SÁNCHEZ-SOLÍS, J. P. LiDAR applications in precision agriculture for cultivating crops: a review of recent advances. **Computers and Electronics in Agriculture**, v. 207, p. 107737, 2023.

RUSU, R. B.; COUSINS, S. 3D is here: Point Cloud Library (PCL). **2011 IEEE International Conference on Robotics and Automation**, p. 1–4, 2011. <https://doi.org/10.1109/ICRA.2011.5980567>.

SEITZ, S. M.; DYER, C. R. Photorealistic Scene Reconstruction by Voxel Coloring. **International Journal of Computer Vision**, v. 35, n. 2, p. 151–173, 1999. <https://doi.org/10.1023/A:1008176507526>.

SHEN, C.; O'BRIEN, J. F.; SHEWCHUK, J. R. Interpolating and approximating implicit surfaces from polygon soup. : SIGGRAPH '04. Association for Computing Machinery, 2004. <https://doi.org/10.1145/1186562.1015816>.

SHERVAIS, K. SfM Field Methods Manual for Students. Disponível em: <<https://serc.carleton.edu/details/files/96125.html>>. Acesso em: 20 jan. 2024.

SHI, W.; LI, J.; LIU, Y.; ZHU, D.; YANG, D.; ZHANG, X. Dynamic Obstacles Rejection for 3D Map Simultaneous Updating. **IEEE Access**, v. 6, p. 37715–37724, 2018. <https://doi.org/10.1109/ACCESS.2018.2836192>.

SUN, D.; ROBBINS, K.; MORALES, N.; SHU, Q.; CEN, H. Advances in optical phenotyping of cereal crops. **Trends in Plant Science**, v. 27, n. 2, p. 191–208, 2022. <https://doi.org/10.1016/j.tplants.2021.07.015>.

TOMMASELLI, A. Um Estudo sobre as Técnicas de Varredura a Laser e Fotogrametria para Levantamentos 3d a curta Distância. **Geodésia On line**, 2003.

TOMMASELLI, A. M. G.; BERVEGLIERI, A.; IMAI, N. N.; SANTOS, G. H.; MORIYA, E. A. S.; WATANABE, F. S. Y.; NETO, L. S. Geometric performance of a camera with single sensor and multiple heads. **The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 43, p. 389–396, 2020.

WHITTED, T. An improved illumination model for shaded display. **Proceedings of the 6th annual conference on Computer graphics and interactive techniques**, SIGGRAPH '79. p. 14, 1979. <https://doi.org/10.1145/800249.807419>.

XIE, P.; DU, R.; MA, Z.; CEN, H. Generating 3D Multispectral Point Clouds of Plants with Fusion of Snapshot Spectral and RGB-D Images. **Plant Phenomics**, v. 5, p. 0040, 2023.

ZHANG, A.; BAKER, I.; JAKKU, E.; LLEWELLYN, R. **Accelerating precision agriculture to decision agriculture: the needs and drivers for the present and future of digital agriculture in Australia**. [s.l.] Commonwealth Scientific and Industrial Research Organisation Cotton Research and Development Corporation, 2017.

DADOS CURRICULARES

IDENTIFICAÇÃO	
	Isabella Subtil Norberto 28/04/1996
Nacionalidade	brasileira
Nome em citações bibliográficas:	Norberto, Isabella Subtil Norberto, I. S.
Currículo Lattes	http://lattes.cnpq.br/8943349773958357
ORCID	https://orcid.org/0000-0002-4354-5428
FORMAÇÃO ACADÊMICA	
02/2022	Engenharia Cartográfica e de Agrimensura (Bacharel) Universidade Estadual Paulista Júlio de Mesquita Filho, UNESP, Brasil.
10/2024	Ciências Cartográficas (Mestre) Universidade Estadual Paulista Júlio de Mesquita Filho, UNESP, Brasil.

PRODUÇÃO BIBLIOGRÁFICA

NORBERTO, I. S.; FARIA JUNIOR, C. S.; TOMMASELLI, A. M. G.; SHIMABUKURO, M. H.; MARTINS-NETO, R. P.; IMAI, N. N.; DA SILVA, M. F. Leaf Identification in High-Density LiDAR-RGB Data. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, v. X-3-2024, p. 269-276, 2024.

NORBERTO, I. S.; TOMMASELLI, A. M. G.; SHIMABUKURO, M. H.; DA SILVA, M. F. Geração de mapas de visibilidade na fusão de dados ópticos e lidar terrestre na agricultura. In: XIII Colóquio Brasileiro de Ciências Geodésicas, 2024, Curitiba. XIII Colóquio Brasileiro de Ciências Geodésicas (XIIICBCG), 2024.

CASTANHEIRO, L. F.; TOMMASELLI, A. M. G.; MACHADO, M. V.; SANTOS, G. H.; NORBERTO, I. S.; REIS, T. T. The use of a wide FoV laser scanning system and a slam algorithm for mobile applications. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, v. XLIII-B1-2022, p. 181-187, 2022.

NORBERTO, I. S.; TOMMASELLI, A. M. G. Avaliação do comportamento radiométrico de um sensor multiespectral de quatro lentes. In: Congresso de Iniciação Científica (1º fase), 2021, Presidente Prudente. 33ª - Congresso de Iniciação Científica da UNESP, 2021.

NORBERTO, I. S.; TOMMASELLI, A. M. G.; GARCIA, T. A. C. Comparação de métodos para restrição de profundidade de imagens omnidirecionais. In: Congresso de Iniciação Científica (1º e 2º fase), 2020, Presidente Prudente. 32ª - Congresso de Iniciação Científica da UNESP, 2020.

NORBERTO, I. S.; TOMMASELLI, A. M. G.; CAMPOS, M. B. Efeitos da correção por retificação em recortes de imagens omnidirecionais na correspondência de imagens. In: Congresso de Iniciação Científica (1º fase), 2019, Presidente Prudente. 31ª - Congresso de Iniciação Científica da UNESP, 2019.

NORBERTO, I. S.; Tommaselli, A. M. G.; CAMPOS, M. B.; CASTANHEIRO, L. F. Análise comparativa de métodos de correspondência de imagens omnidirecionais. In: Congresso de Iniciação Científica (1º fase), 2018, Presidente Prudente. 30ª - Congresso de Iniciação Científica da UNESP, 2018.

PARTICIPAÇÃO EM EVENTOS CIENTÍFICOS

2º Seminário de Progresso: Sensoriamento Remoto de Alta Resolução Para Agricultura Digital. 2024. (Presidente Prudente). Integração de dados LIDAR e imagens ópticas terrestres para a geração de nuvens de pontos multiespectrais. 2024 (Seminário).

1º Seminário de Progresso: Sensoriamento Remoto de Alta Resolução Para Agricultura Digital. 2023. (Presidente Prudente). Demonstração de aquisição com o Ouster, processamento no WebSlam. 2023 (Seminário).

XXXII Congresso de Iniciação Científica da UNESP (1º fase). 2020. (Presidente Prudente). Comparação de métodos para restrição de profundidade em correspondência de imagens omnidirecionais. 2020. (Congresso).

XXXII Congresso de Iniciação Científica da UNESP (2º fase). 2020. (Presidente Prudente). Comparação de métodos para restrição de profundidade em correspondência de imagens omnidirecionais. 2020. (Congresso).

XXXI Congresso de Iniciação Científica Unesp. 2019. (Presidente Prudente). Efeitos da correção por retificação em recortes de imagens omnidirecionais na correspondência de imagens. 2019. (Congresso).

XXX Congresso de Iniciação Científica Unesp. 2018. (Presidente Prudente). Uma técnica para determinação de linhas epipolares conjugadas em imagens omnidirecionais. 2018. (Congresso).