



UNESP – UNIVERSIDADE ESTADUAL PAULISTA
CAMPUS DE PRESIDENTE PRUDENTE
FACULDADE DE CIÊNCIAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS CARTOGRÁFICAS

GUILHERME GOMES PESSOA

**MITIGAÇÃO DOS PROBLEMAS DE OCLUSÃO, CAUSADOS POR VEGETAÇÃO, NA
EXTRAÇÃO DOS CONTORNOS DE TELHADOS DE EDIFICAÇÕES A PARTIR DE
NUVENS DE PONTOS FOTOGRAFAMÉTRICAS**



GUILHERME GOMES PESSOA

MITIGAÇÃO DOS PROBLEMAS DE OCLUSÃO, CAUSADOS POR VEGETAÇÃO, NA
EXTRAÇÃO DOS CONTORNOS DE TELHADOS DE EDIFICAÇÕES A PARTIR DE
NUVENS DE PONTOS FOTOGRAFAMÉTRICAS

Tese de doutorado apresentada ao Programa de Pós-Graduação em Ciências Cartográficas (PPGCC) da Universidade Estadual Paulista – Campus de Presidente Prudente, como parte dos requisitos para obtenção do título de Doutor em Ciências Cartográficas. Área de concentração: Aquisição, análise e representação de informações espaciais.

Orientadores:

Prof. Dr. Amilton Amorim (*in memoriam*)

Prof. Dr. Maurício Galo

P475m

Pessoa, Guilherme Gomes

Mitigação dos problemas de oclusão, causados por vegetação, na extração dos contornos de telhados de edificações a partir de nuvens de pontos fotogramétricas /

Guilherme Gomes Pessoa. -- Presidente Prudente, 2022

169 p. : il., tabs.

Tese (doutorado) - Universidade Estadual Paulista (Unesp), Faculdade de Ciências e Tecnologia, Presidente Prudente

Orientador: Mauricio Galo

1. Extração de contornos de edificações. 2. Detecção de contornos oclusos. 3. RPAS. 4. Nuvens de pontos fotogramétricas. 5. Classificação de nuvens de pontos fotogramétricas. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de Ciências e Tecnologia, Presidente Prudente. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

IMPACTO¹ ESPERADO DESTA PESQUISA

O tema central desta Tese se refere à extração de contornos de telhados sujeitos à oclusão, provocada por vegetação, sendo proposto e avaliado um método com esta finalidade. No âmbito da gestão pública, a metodologia proposta pode trazer ganhos na automação da aquisição de informações espaciais a partir de imagens/dados adquiridos remotamente, contribuindo para o ordenamento e o desenvolvimento urbano.

POTENTIAL IMPACT OF THIS RESEARCH

This PhD Thesis concerns to the building contour extraction subject to occlusion caused by vegetation, being proposed and evaluated a method with this aim. In the scope of public management the proposed methodology can bring gains in the automation of spatial information acquisition from remote sensing imagery/data, contributing to urban planning and development.

¹ Informação inserida de acordo com a Portaria Unesp nº 117, de 21 de dezembro de 2022.


CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: MITIGAÇÃO DOS PROBLEMAS DE OCLUSÃO, CAUSADOS POR VEGETAÇÃO, NA EXTRAÇÃO DOS CONTORNOS DE TELHADOS DE EDIFICAÇÕES A PARTIR DE NUVENS DE PONTOS FOTOGRAMÉTRICAS

AUTOR: GUILHERME GOMES PESSOA


ORIENTADOR: MAURICIO GALO

Aprovado como parte das exigências para obtenção do Título de Doutor em CIÊNCIAS CARTOGRÁFICAS, área: Aquisição, Análise e Representação de Informações Espaciais pela Comissão Examinadora:




Prof. Dr. MAURICIO GALO (Participação Presencial)
Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente


Prof. Dr. DANIEL RODRIGUES DOS SANTOS (Participação Virtual)
Seção de Engenharia Cartográfica / Instituto Militar de Engenharia



Prof. Dr. HENRIQUE CANDIDO DE OLIVEIRA (Participação Virtual)
Surveying Engineering Department / The Pennsylvania State University



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



Prof. Dr. ALUIR PORFÍRIO DAL POZ (Participação Presencial)
Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente

Presidente Prudente, 31 de agosto de 2022

DEDICATÓRIA

Dedico este trabalho aos meus pais, João Carlos e Dora Alice, e ao meu irmão Danilo, que sempre me apoiaram e deram suporte necessário para que eu buscasse a realização dos meus objetivos. Dedico ainda à minha namorada Franciele, por me apoiar no desenvolvimento da tese, contornando todas as tribulações inerentes ao processo.

AGRADECIMENTOS

Agradeço a Deus por me dar forças para superar todas as adversidades e por iluminar meus caminhos. Agradeço também ao meu orientador Amilton Amorim, a quem sou muito grato por todas as conversas e por todos os ensinamentos. O Prof. Amorim foi muito mais do que um orientador, foi um amigo, dos mais valiosos que se pode ter na vida.

Agradeço também ao meu Coorientador, Prof. Dr. Maurício Galo, que passou a ser meu orientador e assumiu o desafio de me orientar na fase final da minha tese, mesmo atualmente eu estando dividido entre a carreira acadêmica e o mercado de trabalho.

Agradeço ao Prof. Erivaldo e sua esposa Marisa pelas conversas e pela amizade. Agradeço também aos demais professores do Departamento de Cartografia e do PPGCC da Unesp pela formação de excelência, desde a graduação até o doutorado. Hoje, atuando no mercado de trabalho consigo ter a exata noção do quanto a nossa formação é diferente, por muitas vezes superando as expectativas.

Agradeço à instituição Unesp, pelo suporte ao desenvolvimento da pesquisa, disponibilizando laboratórios, equipamentos e software. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001. Agradeço à CAPES pelo suporte a este trabalho e pela oportunidade da realização de intercâmbio, por meio do projeto CAPES-COFECUB. Agradeço também à FAPESP pelo apoio financeiro para a aquisição de equipamentos e *software*, por meio de projetos de pesquisa sob responsabilidade do Prof. Amorim.

Agradeço aos meus amigos de graduação e pós-graduação, em especial Tobias, Kaneshiro, Lucas, Luiz Eduardo, Renan Furlan, Renato, Isa, André, Guilherme Cardim, Géssica e Viviane. Hoje são muito mais que amigos de pós-graduação, são amigos para a vida. Os agradecimentos se estendem aos demais amigos e colegas.

Por fim e mais importante, quero agradecer à minha família e a minha namorada Franciele, sem os quais nada disso seria possível.

RESUMO

Este trabalho trata da extração automática dos contornos de telhados de edificações a partir de nuvens de pontos fotogramétricas. O foco desta Tese se refere à extração dos contornos em situação de oclusão, causada por copas de árvores próximas às edificações. Diversos problemas estão envolvidos nos subprocessos que vão da geração das nuvens de pontos até a extração dos contornos propriamente ditos, passando pela filtragem, classificação, segmentação, detecção das oclusões, integração de nuvens de pontos e a extração de contornos. Dentre as contribuições desta Tese, a principal é a determinação de uma metodologia para extração dos contornos oclusos do ponto de vista aéreo. Nesta Tese é explorada a complementariedade de informações proporcionada por nuvens de pontos fotogramétricas tomadas a partir de dois pontos de vista, aéreo e terrestre. Como contribuições secundárias é possível citar a exploração de nuvens de pontos fotogramétricas geradas a partir de dados adquiridos por drones, a exploração da complementariedade de atributos radiométricos e geométricos extraídos de nuvem de pontos fotogramétricas para auxiliar a tarefa de classificação executada em algoritmo de aprendizado de máquina (*Random Forest*) e a detecção de oclusão por meio de análise da relação topológica entre os vértices dos contornos das edificações e das árvores. Os dados utilizados nesta Tese foram adquiridos a partir de aerolevanteamento por Drone e mapeamento terrestre utilizando Sistema de Mapeamento Móvel (SMM). Os experimentos foram realizados para uma área teste localizada em Espigão, distrito de Regente Feijó, São Paulo, Brasil. Foram realizadas análises das etapas de extração de atributos e classificação da nuvem de pontos fotogramétrica aérea, e de todas as etapas seguintes do método. As análises quantitativas dos experimentos acerca dos atributos e da classificação demonstram a potencialidade do uso combinado de atributos radiométricos e geométricos para a tarefa de classificação, mesmo estes tendo sido extraídos de nuvens de pontos fotogramétricas, as quais usualmente apresentam maior quantidade de dados espúrios se comparadas às nuvens LiDAR. A classificação apenas com atributos geométricos atingiu acurácia global de 74%, enquanto a classificação com atributos radiométricos atingiu valores de 80%, sendo os melhores resultados verificados para a classificação que utilizou ambos os atributos, atingindo valores de acurácia global de 98%. O processo de segmentação aplicado foi capaz de individualizar as edificações e aglomerados de árvores para a maioria dos casos, porém foram verificadas dificuldades na separação de edificações vizinhas

contíguas. O processo de detecção de oclusões atingiu valores de completeza e nível de acerto da ordem de 94% e 73%, respectivamente. Por fim, as análises dos contornos finais demonstram o potencial da integração de nuvens de diferentes pontos de vistas como forma de contornar problemas de oclusão aéreas, causados por árvores. Após a aplicação da metodologia, as edificações em que oclusões foram verificadas tiveram seus contornos corrigidos, impactando positivamente nas métricas utilizadas nas análises.

Palavras-chave: Extração de contornos de telhados; Nuvem de pontos fotogramétrica; Drone; e Oclusão.

ABSTRACT

This thesis deals with the automatic extraction of building roof contours from photogrammetric point clouds. The focus refers to the extraction of contours in a situation of occlusion caused by tree canopy overlapping the buildings. Several problems are involved in the subprocesses that range from the generation of point clouds to the extraction of the contours themselves, passing through filtering, classification, segmentation, occlusion detection, and point cloud integration. The main contributions of this thesis is the methodology for extracting occluded contours through the combination of photogrammetric point clouds taken from aerial and terrestrial points of view. As secondary contributions, it is possible to mention the exploration of the complementarity of radiometric and geometric attributes extracted from photogrammetric point clouds generated from data acquired by UAV. The complementarity of both radiometric and geometric attributes helps the classification task performed in a machine learning algorithm (Random Forest). In addition, this thesis explores the detection of occlusion by analyzing the topological relationship between the vertices of the contours of buildings and trees. The data used in this thesis were acquired from aerial survey using a UAV, and by terrestrial mapping using a Mobile Mapping System (SMM). The experiments were carried out in a test area located in Espigão, district of Regente Feijó, São Paulo, Brazil. There were performed analyzes of attributes extraction and classification of the aerial photogrammetric point cloud and all subsequent steps. The quantitative analysis of the experiments on attributes extraction and classification demonstrates the potential of the combined use of radiometric and geometric attributes for the classification task, even though these attributes were extracted from photogrammetric point clouds, which are generally noisier compared to LiDAR point clouds. The classification with only geometric attributes reached an overall accuracy of 74%, while the classification with radiometric attributes reached values of 80%, being the best results for classification step verified for the classification that used both attributes, reaching global accuracy values of 98%. The segmentation process applied was able to individualize the buildings and clusters of trees in most cases, but some issues were observed in the separation of adjacent buildings. The occlusion detection process reached completeness and correctness values of 94% and 73%, respectively. The analysis of the final contours demonstrates the potential of the integration of clouds from different points of view

to overcome aerial occlusion problems caused by trees. After applying the methodology, the buildings in which occlusions were verified had their contours extracted correctly, positively impacting the metrics used in the analyses.

Keywords: Building boundaries extraction; Photogrammetric point clouds; Drone; Occlusion.

LISTA DE TABELAS

Tabela 2.1 – Características das nuvens de pontos LiDAR e fotogramétrica no contexto de extração de contornos de telhados.....	24
Tabela 6.1 - Parâmetros adotados para aquisição de imagens aéreas.....	73
Tabela 6.2 - Número de pontos utilizados para treinamento e validação dos experimentos de classificação.....	83
Tabela 6.3 – Matriz de erros para o experimento de classificação considerando apenas os atributos geométricos.....	86
Tabela 6.4 – Matriz de erros para o experimento de classificação considerando apenas os atributos radiométricos.	87
Tabela 6.5 – Matriz de erros para o experimento de classificação considerando os atributos geométricos e radiométricos.....	87
Tabela 6.6 – Matriz de erros para o experimento de classificação considerando apenas os atributos radiométricos e a altura.....	87
Tabela 6.7 – Parâmetros de qualidade extraídos das matrizes de erros resultantes dos experimentos de classificação.	88
Tabela 6.8 - Quantidade de pontos eliminados em cada processo de refinamento aplicado.....	92
Tabela 6.9 - Parâmetros utilizados na segmentação.	95
Tabela 6.10 – Resultado do processo de segmentação dos pontos de edificação considerando diferentes cenários.	97
Tabela 6.11 - Resultado do processo de segmentação dos pontos de árvore considerando diferentes cenários.	101
Tabela 6.12 - Estratégias e valores de parâmetros alpha aplicados à extração de contornos.	101
Tabela 6.13 - Estatísticas extraídas sobre o conjunto de parâmetros <i>alpha</i> estimados.	105
Tabela 6.14 - Parâmetros de qualidade para detecção de oclusão considerando diferentes valores de <i>buffer</i>	109
Tabela 6.15 - Número de planos extraídos e oclusos por edificação.	112
Tabela 6.16 – Pontos selecionados por plano parcialmente ocluso.....	118

Tabela 6.17 - Métricas de qualidade (nível de acerto e completeza e F-score).....	123
Tabela 6.18 - Porcentagem de ganho relativo para o nível de acerto, completeza e F-score.....	124
Tabela 6.19 - Áreas das edificações analisadas e respectivos erros relativos.	126
Tabela 6.20 – Métrica PoLiS estimada para os contornos originais e após a aplicação do método proposto.	127

LISTA DE FIGURAS

Figura 1.1 - Contorno de telhado parcialmente ocluído por vegetação.	10
Figura 1.2 - Região com oclusão. (a) ponto de vista aéreo; (b) detalhe da edificação com o telhado parcialmente ocluído; e (c) ponto de vista terrestre da edificação.	11
Figura 2.1 – Mecanismos de varredura e os respectivos padrões de amostragem.	16
Figura 2.2 - Sistemas de coordenadas envolvidos na aquisição de dados LiDAR.	17
Figura 2.3 - Aquisição de nuvem de pontos, LiDAR versus Fotogramétrica.	22
Figura 2.4 - Amostragem de pontos. (a) nuvem de pontos LiDAR; e (b) nuvem de pontos fotogramétrica.	23
Figura 2.5 - Exemplos de pontos espúrios em uma nuvem fotogramétrica. (a) Pontos espúrios em região de sombra; e (b) pontos espúrios em região homogênea.	25
Figura 2.6 - Variação de densidade da nuvem de pontos: (a) nuvens de pontos LiDAR adquiridas em três alturas de voo diferentes; (b) nuvem de pontos fotogramétrica após eliminação de pontos espúrios; e (c) nuvem de pontos LiDAR com variação de densidade devido à sobreposição de faixas de varredura.	27
Figura 2.7 - Efeito da oclusão causada por vegetação (azul) próxima à edificação (rosa). (a) nuvens fotogramétricas; e (b) nuvens de pontos LiDAR. As imagens da esquerda apresentam uma vista perspectiva lateral inclinada, enquanto as imagens da direita apresentam a vista nadir dos pontos amostrados sobre a edificação.	28
Figura 2.8 - Dificuldade de segmentação de edificações em cena com alta complexidade devido à proximidade entre construções vizinhas. (a) vista nadir de região com alta densidade de edificações; (b) resultado do procedimento de crescimento de regiões; (c) vista inclinada, mostrando a proximidade das edificações; e (d) resultado da segmentação para as 4 edificações destacadas. .	29
Figura 3.1 - Fluxograma geral das etapas de definição de atributos, classificação da nuvem de pontos e refinamentos da classificação.	32
Figura 3.2 - Etapas de seleção de pontos sementes e geração da representação grosseira do terreno. (a) pontos semente para a geração da TIN; e (b) TIN gerada a partir dos pontos sementes.	38

Figura 3.3 - Critérios para densificação progressiva do TIN.	39
Figura 3.4 - Ilustração geométrica do ângulo formado entre os vetores normais à dois planos. Nesse caso NV_1 apresenta componente z maior ou igual a 0, enquanto NV_2 apresenta z menor que 0..	45
Figura 4.1 - Fluxograma geral das etapas de segmentação, extração de contornos e detecção de regiões oclusas.	48
Figura 4.2 – Fluxograma do crescimento de regiões, por meio da aplicação do algoritmo <i>Region Growing</i>	50
Figura 4.3 – Extração de contornos pela aplicação do algoritmo α -shape.	52
Figura 4.4 - Detecção de pontos candidatos à oclusão: (a) cluster de pontos de árvore (verde) e de telhado (rosa); (b) contorno da árvore representado pelos pontos em verde, região de influência da árvore gerada considerando um buffer de 0,50 m (pontos em amarelo) e contorno do telhado (pontos em azul); e (c) pontos detectados em região de oclusão (pontos em vermelho).	55
Figura 4.5 - Estimativa do valor de Δh para um dado ponto interno à região de influência da árvore. À direita é mostrado em destaque a área realçada à esquerda.	56
Figura 4.6 - Fluxograma do método proposto para detecção de oclusões.	58
Figura 5.1 - Fluxograma da etapa de mitigação dos contornos oclusos.	62
Figura 5.2 - Região delimitadora definida pelo conceito de <i>bounding box</i> : (a) AABB vista ortogonal; (b) AABB vista em perspectiva; (c) MOBB vista ortogonal; e (d) MOBB vista em perspectiva.	65
Figura 5.3 - Ilustração dos procedimentos para determinação da MOBB, onde são mostradas as projeções do objeto em cada um dos planos (XY, YZ e XZ).	67
Figura 6.1 - Nuvem de pontos fotogramétrica em composição falsa cor <i>Red</i> (R), <i>Green</i> (G) e <i>Blue</i> (NIR).	71
Figura 6.2 - Equipamentos utilizados no aerolevanteamento. (a) RPAS eBee da fabricante sensefly. (b) câmara Canon 110S NIR.	72
Figura 6.3 - Curvas de sensibilidade das bandas G, R e NIR (comprimento de onda x sensibilidade relativa).	72

Figura 6.4 - Equipamentos utilizados na aquisição dos dados terrestres: (a) conjunto de câmaras do SMM instalado no teto de um automóvel; e (b) unidade de controle do SMM.	74
Figura 6.5 – Nuvens fotogramétricas da edificação 304: (a) nuvem aérea (R, G, NIR); e (b) nuvem terrestre (R, G, B).	75
Figura 6.6 - Região selecionada para apresentar os resultados da extração de atributos.	77
Figura 6.7 - Atributos radiométricos extraídos.....	78
Figura 6.8 - Gráficos de média e desvio-padrão dos atributos radiométricos para as classes previstas, considerando as bandas R, G, NIR, bem como o NDVI e o <i>Minimum</i> (R,G,NIR).....	79
Figura 6.9 – Representação dos atributos geométricos extraídos da área de estudo.	81
Figura 6.10 - Gráficos de média e desvio-padrão dos atributos geométricos nas classes previstas.	82
Figura 6.11 - <i>Ranking</i> de importância dos atributos (gerados a partir da aplicação do classificador RF): (a) <i>Ranking</i> dos atributos geométricos; (b) <i>ranking</i> dos atributos radiométricos; (c) <i>ranking</i> dos atributos geométricos e radiométricos; e (d) <i>ranking</i> dos atributos radiométricos e do atributo altura.	84
Figura 6.12 - Regiões selecionadas para apresentação dos resultados da classificação.	85
Figura 6.13 - Resultados da classificação para três áreas distintas, considerando os três experimentos realizados.	85
Figura 6.14 - Exemplos do resultado de refinamento da classificação. Em (a), (c), (e) e (g) têm-se exemplo de regiões com edificações e árvores ainda com os pontos excluídos pelos refinamentos de pontos em planos verticais (pontos amarelos) e regiões de sombra (pontos vermelhos). Em (b), (d), (f) e (h) têm-se as regiões sem os pontos eliminados.	91
Figura 6.15 - Vista ortogonal dos pontos de edificação, de árvores e dos pontos eliminados nos processos de refinamento.....	92
Figura 6.16 – Exemplo dos pontos eliminados pelo refinamento de pontos em regiões plano-verticais.....	93
Figura 6.17 - Variação plano-vertical dos pontos amostrados sobre edificação e árvores.....	95
Figura 6.18 - Região urbana complexa e resultados da segmentação das edificações: (a) imagem RGB da região; (b) resultado da segmentação por crescimento de regiões; e (c) refinamento manual.	96

Figura 6.19 - Resultados das segmentações aplicadas aos pontos de edificação: (a) segmentação aplicada aos pontos oriundos da classificação; (b) segmentação aplicada aos pontos após refinamento dos pontos de sombra; (c) segmentação aplicada aos pontos após refinamento dos pontos em planos verticais; e (d) segmentação manual.....	97
Figura 6.20 – Regiões complexas para o processo de segmentação aplicado aos pontos de edificações contíguas. Na figura são apresentadas duas regiões (I e II) complexas para a segmentação.....	99
Figura 6.21 - Resultado da segmentação aplicada aos pontos de árvores: (a) segmentação aplicada aos pontos oriundos da classificação; e (b) segmentação aplicada aos pontos após refinamento dos pontos de sombra.	100
Figura 6.22 - Resultados da extração de contornos de árvores.	102
Figura 6.23 - Edificações selecionadas para apresentar os resultados da extração de contornos iniciais.....	103
Figura 6.24 - Resultados da extração de contornos sobre edificações para as diferentes estratégias de estimativa do parâmetro alpha.	104
Figura 6.25 - Oclusões detectadas a partir de diferentes valores de <i>buffer</i>	107
Figura 6.26 - Oclusões erroneamente detectadas a partir de diferentes valores de <i>buffer</i>	108
Figura 6.27 - Edificações selecionadas para discussão dos resultados.....	111
Figura 6.28 - Extração de planos para a edificação 279. (a) planos extraídos a partir da nuvem aérea. (b) visualização da edificação na nuvem terrestre.	113
Figura 6.29 - Planos extraídos para a edificação 304.	114
Figura 6.30 - Comparação entre as áreas definidas pela AABB (amarelo) e pela MOBB (vermelho).	115
Figura 6.31 - Pontos selecionados por cada uma das regiões de busca. Exemplo da seleção de pontos para a edificação 299, considerando a aplicação da MOBB e da região de influência da árvore. Figura da esquerda apresenta a vista ortogonal, enquanto a figura da direita apresenta vista lateral.	116
Figura 6.32 - Pontos selecionados com e sem a restrição pela área de busca. (a) e (d) vista superior e perspectiva da edificação 299. (b) e (e) vista superior e perspectiva dos pontos selecionados sem	

considerar restrição na área de busca. (c) e (f) vista superior e perspectiva dos pontos selecionados considerando a restrição na área de busca.	117
Figura 6.33 - Planos parcialmente oclusos e pontos selecionados pelo método.	120
Figura 6.34 - Resultados da extração de contornos oclusos. As linhas pretas representam os contornos de referência, as linhas laranjas os contornos originais, prévios à integração da nuvem terrestre e as linhas amarelas os contornos finais.	122

SUMÁRIO

CAPÍTULO 1

1.1	Considerações iniciais	1
1.2	Caracterização do problema a partir do estado da arte.....	3
1.3	Relevância do tema	8
1.4	Delineamento do problema e hipótese de pesquisa.....	9
1.5	Objetivos	11
1.6	Estrutura da Tese	12

CAPÍTULO 2

2.1	Sistema de varredura a LASER aerotransportado.....	15
2.2	Nuvem de pontos fotogramétrica	18
2.3	Comparação entre nuvem de pontos LiDAR e nuvem de pontos fotogramétrica.....	21
2.4	Fatores que influenciam a extração de contornos de telhados em nuvens fotogramétricas	24

CAPÍTULO 3

3.1	Descrição dos atributos utilizados na classificação.....	33
3.1.1	Atributos radiométricos.....	33
3.1.2	Atributos geométricos baseados nos autovalores.....	34
3.1.3	Atributo altura, calculado a partir do Modelo Digital de Terreno	37
3.2	Classificação de nuvem de pontos.....	39
3.2.1	Random Forest	40
3.3	Refinamento dos resultados de classificação para as classes telhados e árvores	42

CAPÍTULO 4

4.1	Segmentação.....	49
4.2	Extração de contornos das edificações e árvores	51
4.3	Detecção das regiões de oclusão	54
4.3.1	Avaliação de qualidade da etapa de detecção de oclusão	58

CAPÍTULO 5

5.1	Extração de planos por meio do algoritmo RANSAC	62
5.2	Definição da região de influência e seleção dos pontos na nuvem terrestre	64
5.3	Extração do contorno final e avaliação de qualidade	67
5.3.1	Avaliação de qualidade dos contornos finais	68

CAPÍTULO 6

6.1	Descrição dos dados e da área de estudo.....	70
6.2	Resultados da classificação da nuvem de pontos fotogramétrica aérea (Cap. 3)	75
6.2.1	Atributos extraídos	75
6.2.2	Classificação	83
6.2.3	Refinamento	89
6.3	Resultados da detecção de contornos oclusos (Cap. 4).....	93
6.3.1	Segmentação	94
6.3.2	Detecção de contornos iniciais.....	101
6.3.3	Detecção de oclusão	105
6.4	Resultados da mitigação dos contornos oclusos (Cap. 5)	110
6.4.1	Extração de planos	112
6.4.2	Definição da região de busca e seleção dos pontos na nuvem terrestre.....	114
6.4.3	Extração do contorno final	121

CAPÍTULO 7

7.1	Síntese do trabalho	128
7.2	Conclusões.....	129
7.2.1	Classificação de nuvem de pontos fotogramétricas em ambiente urbano.....	129
7.2.2	Detecção de regiões de oclusão em edificações, causadas por árvores	131
7.2.3	Uso combinado de nuvens de pontos para a extração dos contornos oclusos	133
7.3	Recomendações	134
REFERÊNCIAS.....		136

CAPÍTULO 1

Introdução

1.1 Considerações iniciais

A velocidade com que a urbanização e as mudanças no parcelamento e cobertura do solo ocorrem faz com que a atualização de documentos cartográficos seja cada vez mais necessária (Singh *et al.*, 2012). Informações acuradas e atualizadas sobre o ambiente urbano tem papel preponderante em diversas aplicações, como por exemplo no planejamento urbano, monitoramento ambiental, estimativa populacional, avaliação de risco etc. Nesse sentido, métodos que permitem o monitoramento e a extração de informações para a atualização de bases cartográficas, de modo automático, têm se tornado cada vez mais importantes.

Para Souza e Amorim (2015), as tarefas de aquisição, armazenamento, processamento e representação dos dados espaciais evoluíram significativamente nos últimos anos, proporcionando novas possibilidades de utilização dos dados espaciais, principalmente a partir da geração de modelos tridimensionais de objetos.

Uma das principais fontes de dados para a geração de modelos tridimensionais são as nuvens de pontos, podendo estas serem oriundas de sistemas de varredura a LASER (*Light Amplification by Stimulated Emission of Radiation*) ou de processamentos fotogramétricos. Para a geração de modelos tridimensionais de edificações é primordial que a nuvem seja filtrada e que as edificações presentes na cena sejam detectadas, a fim de separá-las dos demais alvos. Awrangjeb, Ravanbakhsh e Fraser (2010) e Awrangjeb, Fraser e Lu, (2015) afirmam que os trabalhos de detecção de edificações podem ser divididos em três categorias, de acordo com os dados utilizados: (i) trabalhos que utilizam apenas de imagens (Jin e Davis, 2005; Bertan, Gokmen e Moreau, 2006; Lin *et al.*, 2019; Liu *et al.*, 2018, 2020; Abdollahi *et al.*, 2020); (ii) trabalhos que utilizam dados obtidos por Light Detection and Ranging (LiDAR) (Chen *et al.*, 2014; Xu, Wan e Yao, 2010; Yu,

Liu e Buckles, 2011; Mahphood e Arefi, 2020); e (iii) trabalhos que utilizam da integração de imagens e dados LiDAR (Meng *et al.*, 2012; Awrangjeb, Zhang e Fraser, 2011, 2013; Awrangjeb, Fraser, e Guojun Lua, 2013; Gilani, Awrangjeb e Lu, 2015, 2016; Lai *et al.*, 2019; Ullo *et al.*, 2020; Ojogbane *et al.*, 2021; Ywata *et al.*, 2021).

Segundo Awrangjeb, Zhang e Fraser (2013) e Ojogbane *et al.* (2021), a detecção de edificações utilizando apenas imagens ópticas pode resultar em falta de informações em locais que apresentem sombras, oclusões ou baixo contraste visual entre objetos (regiões homogêneas). Por utilizar um sistema ativo, a detecção de edificações utilizando dados LiDAR, por sua vez, não apresenta regiões de sombra, como no caso de imagens. Além disso, a determinação de coordenadas 3D é feita de forma direta, sem a necessidade de um processo de correspondência, como no caso do uso de imagens ópticas em Fotogrametria. Por outro lado, os dados LiDAR possuem menos informações semânticas quando comparados às imagens e, devido ao processo de amostragem, podem apresentar pouco detalhamento geométrico, dependendo da densidade de pontos (Fernandes e Dal Poz, 2016). Segundo os mesmos autores, devido à complementaridade dessas duas fontes de dados é esperado que objetos como edificações sejam extraídos de forma mais acurada, completa e confiável ao utilizar métodos que integrem ambas as fontes de dados.

Nos últimos anos, os avanços tecnológicos no desenvolvimento de plataformas, como os Sistemas de Aeronaves Remotamente Pilotadas (*Remotely Piloted Aircraft System – RPAS*), e de *software* e técnicas de visão computacional e processamento fotogramétrico, por exemplo o *Structure from Motion (SfM)* e o *Semi Global Matching (SGM)* (Hirschmuller, 2005, 2008), possibilitaram a geração de dados com potencial de uso para diversas aplicações, dentre elas a detecção e extração de edificações a partir de nuvens de pontos fotogramétricos (Xiong, Elberink e Vosselman, 2014; Wang, 2016).

Em função deste contexto foi realizada uma revisão dos estudos publicados em periódicos e eventos, com o intuito de apresentar o estado da arte dos trabalhos que visam a detecção e/ou extração de edificações. A partir do estado da arte é possível caracterizar os problemas relacionados à detecção/extração de edificações a partir das diferentes fontes de dados.

1.2 Caracterização do problema a partir do estado da arte

Na literatura existem diversas abordagens com vistas à detecção e extração automática de edificações. Dentre elas Jin e Davis (2005) e Bertan, Gokmen e Moreau (2006) exploram a extração de edificações diretamente sobre imagens aéreas, sem a utilização de métodos fotogramétricos que permitam a exploração de informação 3D. O primeiro trabalho realiza a extração baseada na aplicação sequencial de ferramentas de morfologia matemática para a recuperação das estruturas das edificações e de informação contextual (definição das regiões de sombras), juntamente com a informação radiométrica. O segundo artigo apresenta um método automático de reconstrução tridimensional de telhados, utilizando imagens aéreas e informações geométricas das edificações, advindas de um conhecimento arquitetônico prévio. Em ambos os trabalhos são relatados problemas devido à existência de sombras sobre as edificações, as quais, em alguns casos, impossibilitam a recuperação total da edificação.

Os trabalhos de Lin *et al.* (2019), Liu *et al.* (2018; 2020) e Li *et al.* (2022) exploram a detecção/extração de edificações sobre imagens por meio da aplicação de algoritmos de *deep learning*. Em ambos os trabalhos são explorados os modelos baseados em *Convolutional Neural Networks* (CNN). Nos trabalhos de Liu *et al.* (2018; 2020) os autores apontam limitações dos métodos de extração devido à diversidade de características possíveis para as edificações, podendo estas variarem quanto ao formato, tamanho, orientação nas imagens, material e cor. Além das dificuldades quanto à geometria das edificações e sua aparência nas imagens, os autores também apontam dificuldades relacionadas às sombras, regiões homogêneas e ocorrências de oclusões. No trabalho de Li *et al.* (2022) os autores comparam diferentes cenários, com e sem a presença de sombras, oclusões e regiões com pouco contraste. Nos cenários com sombra, oclusão e regiões com pouco contraste o método apresenta piores resultados.

No trabalho de Xu, Wan e Yao (2010) os autores apresentam um método automático de extração de bordas 3D de edificações a partir de informações obtidas por um sistema LiDAR. Tal método utiliza técnicas de filtragem, segmentação, triangulação (geração de malha irregular – *Triangular Irregular Network* – TIN) e regularização de bordas. Nesse trabalho os autores utilizam um processo de filtragem aplicado em múltiplas resoluções dos dados originais. O processo de segmentação das edificações e extração do contorno aproximado das edificações foi realizado por meio de análise sobre a malha TIN, construída apenas com os pontos classificados como edificação.

Inicialmente os autores selecionam um triângulo sem bordas longas e iniciam um processo iterativo de crescimento de regiões a partir da análise da vizinhança dos triângulos da rede TIN. Os autores relatam que a densidade da nuvem de pontos influencia diretamente no processo de segmentação e extração dos contornos iniciais.

Yu, Liu e Buckles (2011) propuseram um método para a reconstrução 3D de edificações utilizando *Minimum Bounding Rectangle* (MBR) aplicados a dados LiDAR. A classificação dos pontos de edificação é realizada com base em dois critérios: altura e distância entre os pontos candidatos. Nesse trabalho a separação entre pontos candidatos à edificação e à vegetação foi realizada com base na dispersão das coordenadas destes pontos, considerando que pontos em vegetação apresentam alta variabilidade se comparados aos pontos de edificação. A segmentação das edificações foi realizada por meio da aplicação do MBR, assumindo que as edificações sejam compostas apenas por retângulos.

Chen *et al.* (2014) propuseram uma abordagem multi-escala a partir de dados LiDAR para a detecção e reconstrução de telhados. O método interpola a nuvem de pontos LiDAR em dois conjuntos de pontos regularmente espaçados (malha). A malha em escala pequena é utilizada na detecção de pontos sementes e no refinamento das regiões sementes e a malha em escala grande é utilizada para a detecção de estruturas mais complexas. Os autores apontam problemas para a reconstrução de telhados de edificações devido à oclusão parcial causada por vegetação próxima às edificações.

A abordagem proposta por Gilani, Awrangjeb e Lu (2016) para segmentação de telhados foi realizada a partir de nuvem de pontos aérea. O método pode ser dividido em três etapas: Primeiramente os dados LiDAR são classificados: (i) em pontos de terreno e (ii) pontos de não-terreno, a partir dos quais as regiões candidatas são identificadas. Em seguida, é realizada a segmentação da nuvem de pontos, e as primitivas geométricas do telhado são extraídas de cada região candidata. Por fim, os planos criados em estruturas do tipo não-construção são removidos por um processo de refinamento, seguido de um ajustamento dos planos de telhados e aproximação dos contornos das edificações.

Buscando contornar a necessidade de métodos de filtragem para a detecção de edificações, Mahphood e Arefi (2020) propuseram um método baseado em *Virtual First and Last Pulse* (VFPLP). Com base na distância vertical entre o primeiro e o último pulso (VFP – VLP) os autores

identificam feições verticais na nuvem de pontos, sendo uma delas as faces das edificações. Uma vez detectadas, as faces das edificações são posteriormente utilizadas para a determinação de seus *footprint*. Segundo os autores o método é capaz de lidar com problemas de oclusões causados por vegetação próximas às edificações.

Santos, Habib e Galo (2022) propuseram uma abordagem baseada em CD-Spline iterativa aplicada à dados LiDAR, visando mitigar problemas de oclusão. O método consiste em detectar pontos em região de oclusão e associar a esses pontos pesos baixos, de modo a reduzir sua contribuição na geração dos contornos finais das edificações. Os autores relatam que o método proposto atinge resultados satisfatórios, mesmo para o caso de contornos curvos, os quais são negligenciados pela maior parte dos métodos.

De acordo com Yu, Liu e Buckles (2011), os trabalhos de detecção de edificações tem buscado a melhoria da acurácia a partir da integração de diferentes fontes de dados, em especial a integração de nuvens de pontos LiDAR e imagens de alta resolução. De acordo com Chen *et al.* (2014), os métodos que utilizam a integração de dados contornam as limitações de cada uma das fontes pela complementariedade de informações.

Os trabalhos de Awrangjeb, Fraser, e Guojun Lua (2013) e Awrangjeb, Zhang e Fraser (2011, 2013) fundamentam a necessidade de integração de dados LiDAR e imagens nas limitações e vantagens de cada uma das fontes de dados, para fins de reconstrução 3D. Os autores apontam que as imagens apresentam falhas na reconstrução em regiões de sombra, oclusão e pouco contraste. Eles também ressaltam melhorias na automação da reconstrução 3D a partir de dados LiDAR. No entanto, dependendo da densidade da nuvem de pontos, não é possível garantir que os pontos de borda sejam amostrados pelo sistema de varredura. Em seu trabalho, os autores utilizam informação radiométrica das imagens para detectar linhas que posteriormente são classificadas em vegetação, telhado e chão. A classificação de linhas sobre vegetação é realizada, mais uma vez, a partir da exploração de informação radiométrica advinda das imagens, neste caso o NDVI. Em seguida as linhas são utilizadas como uma aproximação inicial para o processo de extração dos planos de telhados sobre a nuvem de pontos LiDAR. Por fim os planos extraídos são agrupados para formar a edificação a partir de análise de conectividade entre planos vizinhos.

Assim como Awrangjeb, Fraser, e Guojun Lua (2013) e Awrangjeb, Zhang e Fraser (2011, 2013), Gilani, Awrangjeb e Lu (2015) apontam limitações na detecção ou extração de edificações

a partir de imagens, bem como as potencialidades no uso combinado de imagens e dados LiDAR. Os autores utilizam os dados LiDAR para a detecção inicial das edificações e geração de seus *footprints*. Em paralelo, as imagens são processadas para a geração de NDVI, cálculo da entropia e extração de linhas. Os *footprints* são então segmentados para a individualização das edificações, que posteriormente são integradas com as linhas extraídas das imagens para a detecção inicial das edificações. Por fim, é aplicado um processo de remoção de vegetação e extração de bordas para as edificações previamente selecionadas.

Lai *et al.* (2019) apresentam uma metodologia que detecta edificações a partir da fusão de dados LiDAR e atributos texturais extraídos de mapas de elevação. Nesse trabalho os mapas de elevação são produzidos a partir dos dados LiDAR. Os autores exploram diferentes atributos extraídos tanto da nuvem de pontos LiDAR quanto do mapa de elevação em um processo de classificação supervisionado.

A combinação de dados LiDAR e imagens orbitais foi explorada também por Ullo *et al.* (2020), sendo a detecção das edificações realizada a partir da aplicação sucessiva de um conjunto de limiares considerando diferentes atributos. Inicialmente os dados LiDAR foram utilizados para a produção de um MDSn da área teste, o qual foi utilizado para determinar os pontos elevados e não elevados. Em seguida um limiar foi aplicado considerando um mapa de declividade, também produzido a partir dos dados LiDAR. As áreas elevadas e com valores de declividade superiores a 30° foram consideradas candidatas a edificação. Os grupamentos de pixels candidatos a edificação com menos de 4 pixels foram removidos. Por fim, foi aplicada uma segmentação baseada em atributos radiométricos a fim de individualizar as edificações.

Ojogbane *et al.* (2021) propuseram uma abordagem baseada no uso de *deep learning* por meio da aplicação de uma CNN (*Convolutional Neural Network*) para a detecção de edificações a partir da fusão de imagens de alta resolução e MDS derivados de LiDAR. Os autores relatam limitações dos métodos de detecção de edificações em função da grande variedade geométrica dos telhados das edificações e da complexidade dos ambientes urbanos. Além disso, o conjunto de dados pode ser impactado pelo ângulo de aquisição, sombras, ocorrência de oclusões, entre outros problemas.

Ywata *et al.* (2021) apresentam uma metodologia de extração de bordas de edificação no espaço 3D a partir da integração de imagens e dados LiDAR. Na metodologia proposta pelos

autores, as imagens e os dados LiDAR são utilizados nas etapas iniciais para detectar regiões de sombra e de vegetação. Tais regiões, após detectadas, são tratadas de forma diferenciada na aplicação das equações de energia da modelagem *Snake*. A metodologia proposta busca superar três problemas comuns para as aplicações de extração de contornos de edificações, quais sejam: oclusões causadas por edificações elevadas, oclusões causadas por vegetação que se sobrepõe aos telhados das edificações, e sombras.

A partir dos diversos trabalhos voltados para a detecção/extração de edificações a partir de diferentes conjuntos de dados é possível destacar um conjunto de desafios apontados pelos autores. De modo geral, estudos que exploram a detecção/extração a partir de imagens relatam dificuldade em regiões de sombra (Jin e Davis, 2005; Bertan, Gokmen e Moreau, 2006; Liu *et al.*, 2018; 2020) e em situação de oclusão (Liu *et al.*, 2018; 2020). Estudos que utilizam de dados LiDAR apontam dificuldades nos casos de baixa densidade (Xu, Wan e Yao, 2010; Ojogbane *et al.*, 2021) e ocorrência de oclusão (Chen *et al.*, 2014; Ojogbane *et al.*, 2021).

Visando contornar algumas das limitações apontadas, alguns trabalhos voltam para a utilização combinada destas duas fontes de dados. Embora diversos estudos apontem o potencial ganho em acurácia para as tarefas de detecção e extração de edificações, a tarefa de integração de dados pode trazer restrições adicionais como redundância de informação desnecessária e necessidade de aplicação de estratégias de registro de dados, como destacam Chen *et al.* (2014, 2016). Os fatores desafiadores da integração destas duas fontes de dados são destacados também pela Sociedade Internacional de Fotogrametria e Sensoriamento Remoto – *International Society for Photogrammetry and Remote Sensing (ISPRS)*. Alternativamente à necessidade de integração de dados multifonte para a utilização de atributos geométricos e radiométricos é possível a exploração de nuvens de pontos fotogramétricas, como por exemplo nos trabalhos de Wang (2016) e Acar *et al.* (2019).

Wang (2016) utilizou tanto características geométricas quanto radiométricas das feições de interesse para a detecção das edificações, com enfoque na extração de contornos de telhados a partir de imagens aéreas de alta resolução. Nesse estudo, a nuvem de pontos da área imageada foi gerada utilizando imagens e a técnica *Semi-Global Matching* (SGM). Métodos de filtragem e de classificação foram utilizados com a finalidade de discriminar os pontos que representam as

edificações. Por fim, foram aplicados métodos de extração de bordas para a definição dos contornos das edificações.

Acar *et al.* (2019) apresentam um método para a detecção automática de edificações a partir de nuvens de pontos fotogramétricas. Neste trabalho os autores exploram a radiometria dos dados para a detecção e eliminação de pontos sobre vegetação. A detecção de vegetação é realizada utilizando o índice NDVI. Em seguida, a aplicação de um método de filtragem proporciona a separação do conjunto de dados em pontos amostrados sobre o terreno e pontos amostrados em objetos elevados, chamados de não chão. Por fim o método proposto é aplicado sobre os pontos elevados para a detecção de pontos pertencentes as edificações. Nesse trabalho o problema de oclusão e possíveis falhas na nuvem de pontos, devido a presença de sombras, não são mencionados.

Diversas são as fontes de dados exploradas para as tarefas de detecção e/ou extração de edificações. Trabalhos que exploram nuvens fotogramétricas para esta finalidade datam a partir da década de 2000, sendo esta fonte de dados ainda pouco explorada para tal finalidade. Além disso, embora existam na bibliografia diversos trabalhos voltados para a detecção e extração de edificações, e alguns deles explorem essas tarefas no contexto de oclusão (Mahphood e Arefi, 2020; Ywata *et al.*, 2021), a extração de informações em áreas oclusas ainda permanece um desafio. Neste sentido, esta Tese visa explorar a extração de informações em tais regiões, a partir da complementaridade de nuvens de pontos fotogramétricas provenientes de diferentes pontos de vista, para um mesmo objeto.

1.3 Relevância do tema

Atualmente, a Comissão 2 (*Photogrammetry*) da ISPRS (*International Society for Photogrammetry and Remote Sensing*), em seus Grupos de Trabalho 2 (*Point Cloud Generation and Processing*) e 3 (*3D Scene Reconstruction for Modeling & Mapping*), fomentam a exploração de dados provenientes de nuvem de pontos por meio de discussões e pesquisas em torno de diversos temas relacionados à filtragem, classificação, extração de informações, e reconstrução de objetos no espaço 3D.

O Grupo de Trabalho 2 (GT 2), mencionado anteriormente, traz ao menos um termo de referência relacionado ao tema desta pesquisa: Filtragem, fusão e integração de nuvens de pontos

provenientes de diferentes fontes ou sensores para a reconstrução de superfície. Neste mesmo grupo outros termos são destacados: Desenvolvimento de novas metodologias, algoritmos e aplicações para processamento de nuvem de pontos; Extração de informações a partir de nuvem de pontos, incluindo segmentação e classificação; e Processamento de nuvem de pontos para Modelagem de Informações de Edificação (*Building Information Modelling* - BIM). Por fim, o GT 3 apresenta os seguintes termos: Modelos e técnicas para extração de feições, primitivas geométricas e objetos a partir de dados adquiridos por sensores aéreos ou terrestres, incluindo reconhecimento e reconstrução de objetos 3D; Segmentação semântica de nuvem de pontos com ou sem informação radiométrica; e Exploração da complementaridade de informações advindas de diferentes pontos de vista, diferentes tipos de sensores, e diferentes dados existentes.

Além disso, dada a relevância e importância do tema para as áreas de Planejamento e Gestão Territorial, a Federação Internacional de Geômetras (FIG) trata do tema Cadastro, com ênfase especial ao Cadastro 3D, que possui um Grupo de Trabalho específico para discutir assuntos relativos ao tema, formado pelas Comissões 3 e 7. No Brasil, o decreto 8.764 (Brasil, 2016) instituiu o Sistema Nacional de Gestão de Informações Territoriais (SINTER), dispositivo que centraliza em um único banco de dados geoespacial todas as informações sobre o registro de terras e imóveis no país. Vale destacar que um imóvel, no conceito geral, não é composto apenas da parcela territorial, mas também as edificações presentes sobre a parcela. Nesse sentido, os dados tridimensionais são um importante insumo para o SINTER, com importantes implicações práticas no âmbito do cadastro e no suporte à gestão dos espaços urbanos, uma vez que tais dados apresentam informações sobre a estrutura e até mesmo sobre o padrão da edificação.

1.4 Delineamento do problema e hipótese de pesquisa

Para Awrangjeb, Ravanbakhsh e Fraser (2010) e Ojogbane *et al.* (2021), a automação completa do processo de extração de feições ainda representa uma tarefa que deve ser alvo de esforços por parte dos pesquisadores. Para Fernandes e Dal Poz (2016), as razões que apresentam desafios incluem: variadas possibilidades de configurações de telhados, complexidade de cena e ruídos nos dados de entrada. Diversos autores apontam dificuldades na extração de informações de edificações próximas a vegetações altas (Awrangjeb, Ravanbakhsh e Fraser, 2010; Awrangjeb, Zhang e Fraser, 2011, 2013; Chen *et al.*, 2014; Wang, 2016; Mahphood e Arefi, 2020; Ojogbane

et al., 2021), assim como ilustrado na Figura 1.1, onde a área destacada em verde corresponde ao telhado extraído por um determinado método e o contorno destacado em preto corresponde ao contorno correto do telhado. Esta figura mostra um exemplo claro em que a extração correta do contorno da edificação, mesmo que realizada por um operador humano, não é trivial, justamente por conta da oclusão provocada pela vegetação.


Figura 1.1 - Contorno de telhado parcialmente ocluído por vegetação.



Fonte: Chen *et al.* (2014).

Considerando os aspectos discutidos e as diferentes soluções apresentadas no estado da arte, pretende-se desenvolver um método para a mitigação de problemas causados por oclusão devido à presença de árvores próximas às edificações. Parte-se do pressuposto que a maioria das oclusões encontradas nas regiões residenciais são causadas por árvores existentes nas calçadas ou mesmo no interior das parcelas. Neste sentido, espera-se que os dados provenientes dos mapeamentos terrestres, móveis ou estáticos, integrados aos dados obtidos por aerolevantamentos, auxiliem o processo de extração de telhados a partir de nuvens de pontos fotogramétricos, permitindo a representação tridimensional das edificações de modo fidedigno. Um exemplo de caso em que o método proposto poderia permitir resultados satisfatórios está apresentado na Figura 1.2.

Figura 1.2 - Região com oclusão. (a) ponto de vista aéreo; (b) detalhe da edificação com o telhado parcialmente ocluído; e (c) ponto de vista terrestre da edificação.



Fonte: Elaborada pelo autor.

Com base no que foi discutido coloca-se a seguinte hipótese: “Os limites de telhados em regiões oclusas, decorrentes da presença de vegetação, podem ser obtidos a partir da integração das nuvens de pontos fotogramétricas aéreas e terrestres e da aplicação de técnicas de modelagem de superfícies”.

A premissa básica de que se vale a hipótese desta Tese é de que, em uma certa parte dos casos é possível a visualização dos contornos de edificações oclusos do ponto de vista aéreo a partir de dados adquiridos do ponto de vista terrestre. Essa premissa é falha para aquelas oclusões que ocorrem afastadas das vias de acesso à edificação, isto porque o mapeamento para a aquisição de dados terrestre ocorre usualmente a partir de tais vias. Ainda assim a detecção de destas áreas é relevante e traz contribuições frente aos métodos de extração de contornos de edificações que negligenciam a ocorrência de oclusões.

1.5 Objetivos

O objetivo principal desta Tese consiste em desenvolver um método para determinar os contornos de telhados oclusos do ponto de vista aéreo. Para tal, serão explorados a complementariedade de nuvens de pontos fotogramétricas obtidas a partir de dois pontos de vista, aéreo e terrestre. A nuvem aérea será utilizada nas etapas de detecção de edificação e de suas oclusões, enquanto a nuvem terrestre será utilizada para a mitigação dos contornos oclusos.

Os objetivos específicos são:

-
- Diferenciar pontos amostrados sobre árvore e edificações a partir da aplicação de um método de classificação supervisionado, considerando tanto atributos radiométricos quanto geométricos.
 - Avaliar o potencial do uso de nuvens de pontos fotogramétricas, obtidas a partir de imagens aéreas, para a detecção automática de edificações.
 - Propor e implementar um método para a mitigação dos limites dos telhados oclusos do ponto de vista aéreo.
 - Avaliar quantitativamente o resultado obtido pelo método proposto, comparando com dados de referência gerados manualmente.

1.6 Estrutura da Tese

Este trabalho está organizado em sete capítulos. No primeiro é apresentado a introdução do tema de interesse, contendo as considerações iniciais, a relevância do tema, uma caracterização do estado da arte, o delineamento do problema, a hipótese de pesquisa e os objetivos.

No segundo capítulo são apresentados conceitos sobre as duas fontes de aquisição de nuvem de pontos. Além disso, também é apresentada uma comparação entre nuvem de pontos LiDAR e fotogramétricas com foco nos processos necessários para o desenvolvimento desta Tese, destacando as vantagens e desvantagens de uma em relação a outra.

Os Capítulos 3, 4 e 5 apresentam o método proposto permeado por trechos de revisão bibliográfica sobre os temas pertinentes. O Capítulo 3 trata da extração de atributos radiométricos e geométricos, bem como da classificação da nuvem de pontos. O Capítulo 4 apresenta as etapas do método que consideram a segmentação dos grupamentos de edificações, a extração dos contornos e a detecção das regiões de oclusão. Por fim, o Capítulo 5 trata das etapas de extração dos planos das faces dos telhados, definição da região de busca e seleção de pontos, bem como da extração do contorno final.

O Capítulo 6 apresenta os resultados obtidos para cada uma das etapas do método, organizados de acordo com a divisão dos métodos em capítulos. A Seção 6.2 apresenta os resultados referentes ao Capítulo 3, a Seção 6.3 apresenta os resultados referentes ao Capítulo 4 e a Seção 6.4 apresenta os resultados referentes aos processos descritos no Capítulo 5. Por fim, no Capítulo 7 são apresentadas as considerações finais e recomendações.

Capítulo 2

Princípios e técnicas para a amostragem de superfícies no espaço tridimensional

O conjunto de pontos amostrados no espaço tridimensional, conhecido na literatura e designado neste trabalho como nuvem de pontos, consiste em pontos irregularmente espaçados em razão das características dos processos de aquisição (Shan e Toth, 2018). Esse tipo de dado tem sido aplicado para as mais variadas finalidades, tais como extração de Modelo Digital de Terreno (MDT) (Pfeifer, Köstli e Kraus, 1998; Axelsson, 2000; Sithole, 2001; Sithole e Vosselman, 2004; Chen, Gao e Li, 2021; Yan, 2021), detecção e extração de telhados (Awrangjeb, Zhang e Fraser, 2011; Wang, Gou e Sun, 2012; Gilani, Awrangjeb e Lu, 2016; Lai *et al.*, 2019; Ullo *et al.*, 2020; Mahphood e Arefi, 2020; Ojogbane *et al.*, 2021), modelagem de edificações (Haala e Kada, 2010; Souza e Amorim, 2015; Croce *et al.*, 2021; Li e Wu, 2021; Moyano *et al.*, 2021; Rausch e Haas, 2021; Xu e Stilla, 2021), dentre outras.

Os métodos de aquisição de nuvem de pontos podem ser categorizados em métodos baseados em imagens e os métodos baseados em sensores ativos (LiDAR - *Light Detection and Ranging* ou Câmeras Range). As nuvens de pontos LiDAR conquistaram uma posição importante desde o advento dos Sistemas de Varredura LASER Aerotransportados (SVLA) (Shan e Toth, 2018), isso se deu principalmente devido a algumas limitações das técnicas fotogramétricas. No entanto, o recente desenvolvimento de técnicas fotogramétricas e de visão computacional proporcionaram diversas inovações de algoritmos de processamento fotogramétrico, como por exemplo a incorporação do *Structure from Motion* (SfM) e do *Semi-Global Matching* (SGM), os quais trouxeram avanços para as etapas de medição de pontos fotogramétricos (extração de pontos de interesse), fototriangulação simultânea por feixes de raios perspectivos e correspondência de imagens para a geração de nuvem de pontos densa.

As vantagens e/ou desvantagens dos métodos de geração de nuvem de pontos têm sido abordadas por diversos autores nas últimas décadas, no entanto observa-se que não há unanimidade quanto ao tema. Os trabalhos de Baltsavias (1999), Bitelli, Dubbini e Zanutta (2004) e Wang e Shan (2009) indicam vantagens para os métodos baseados em sensores ativos, relacionadas à precisão posicional e à possibilidade de armazenamento de múltiplos retornos. Por outro lado, os trabalhos de Veneziano *et al.* (2002) e Choma *et al.* (2005) apontam que os métodos baseados em imagem ainda têm aplicações e vantagens relevantes, por estarem vinculados a processos intuitivos com possibilidade de utilização de dados semânticos. Adicionalmente, existem autores que exploram a fusão de dados e trazem as duas tecnologias como complementares, como por exemplo Habib e Morgan (2005); Champion *et al.* (2009) e Leberl *et al.* (2010).

Os métodos baseados em imagens permitem adquirir dados tridimensionais a partir da aplicação de geometria projetiva ou modelo de câmera perspectiva (Remondino, 2003). Os métodos baseados no emprego de sensores ativos, em especial os baseados na varredura a LASER, também conhecidos como LADAR (*LASER Detection and Ranging*) ou LiDAR, têm por princípio a medição de distâncias a partir da emissão de pulsos e a recepção de seus retornos. Ambas as técnicas permitem a coleta de conjuntos de dados com alta densidade, podendo ou não conter informações radiométricas. Mais detalhes sobre os métodos baseados em sensores ópticos e em sensores ativos são apresentados em Chen, Song e Brown (2000) e Blais (2004).

Independentemente do método utilizado, as nuvens de pontos podem ser adquiridas do ponto de vista terrestre ou aéreo, de forma estática ou dinâmica, podendo ainda estarem associadas a um sistema de referência global ou local. O referenciamento da nuvem pode ser realizado de forma direta, auxiliado por sensores de posição e atitude integrados à plataforma, ou de forma indireta, a partir da utilização de pontos de apoio para o georreferenciamento da nuvem. Em aplicações em que seja necessária a utilização de duas ou mais nuvens de pontos, obtidas em levantamentos independentes e que estejam referenciadas a sistemas de referência diferentes, há a necessidade de se executar a etapa de registro das nuvens.

Nuvens de pontos obtidas por meio de sistemas LASER apresentam feixes com múltiplos retornos, pontos em regiões espectralmente homogêneas e alta acurácia altimétrica. As nuvens de pontos fotogramétricas, por outro lado, possibilitam alta densidade (até 1 ponto por pixel) e grande quantidade de informação semântica devido a utilização das informações espectrais dos alvos. Nas

Seções 2.1.1 e 2.1.2 estão apresentados maiores detalhes a respeito da aquisição de nuvens de pontos por Sistemas de Varredura a LASER Aerotransportados (SVLA) e por fotogrametria, respectivamente.

2.1 Sistema de varredura a LASER aerotransportado

Os SVLA têm por princípio de funcionamento a medição de distâncias a partir da emissão de pulsos e a recepção de seus retornos. O sistema responsável pela realização de medidas, que posteriormente são utilizadas para o cálculo da distância, é o sistema LASER, o qual baseia-se no princípio de amplificação da luz por emissão estimulada de radiação. Dois princípios fundamentais podem ser empregados para o cálculo da distância entre o sensor e o alvo (Baltsavias, 1999b; Wehr e Lohr, 1999; Vosselman e Maas, 2010): (I) medição pelo tempo de propagação do pulso LASER e (II) medição da diferença de fase. Ambos os métodos consideram o tempo de propagação do pulso e a velocidade da luz no vácuo (c). Considerando o tempo de viagem (τ) de um dado pulso é possível estimar a distância ρ a partir da Equação 2.1. No segundo (II), o tempo (τ) deve ser estimado com base na diferença de fase ($\Delta\phi$) obtida entre o pulso emitido e o pulso recebido (Equação 2.2). A diferença básica entre os dois métodos consiste na forma de obtenção do tempo de propagação do pulso, sendo que no primeiro (I) o tempo é obtido pela diferença do instante de emissão e o instante de recepção do pulso.


$$\rho = c * \tau / 2 \quad (2.1)$$

$$= \Delta\phi / 2\pi * \lambda / c \quad (2.2)$$

De acordo com (Wehr e Lohr, 1999) um SVL é composto por três unidades principais: unidade de varredura a LASER, unidade de controle e processamento, e sistema de posicionamento e orientação. A unidade de varredura a LASER é composta basicamente por um gerador de pulsos LASER, conjunto óptico responsável pela emissão e recepção do pulso, detector de sinais e medidor de tempo, e unidade de controle e armazenamento (Wehr e Lohr, 1999; Shan e Toth, 2018). Após a geração dos pulsos LASER, o conjunto óptico de lentes e espelhos os orienta emitindo-os em direção aos objetos. O pulso retorna ao sensor após atingir o alvo, passa pelo conjunto óptico e é dirigido à parte eletrônica de recepção do sensor. O tempo de propagação do

pulso nos trechos sensor-alvo e alvo-sensor é então medido ou estimado pelo medidor de tempo, por meio de contagem de tempo ou comparação de fase. Por fim, a unidade de controle e armazenamento é responsável pela sincronização das medidas de distâncias e ângulos de varredura com as medidas de posição e orientação da plataforma ao longo do tempo.

Os SVLA empregam basicamente quatro tipos de sistema de varredura, sendo o padrão de amostragem dos pontos dependente do sistema óptico de lentes e espelhos utilizado para orientar os pulsos LASER na direção dos objetos. Na Figura 2.1 estão apresentados alguns exemplos de espelhos de varredura e seus respectivos padrões de amostragem.



Fonte: Adaptado de Vosselman e Maas (2010)


O sistema de posicionamento e orientação é composto pela integração do sistema de posicionamento por satélites *Global Navigation Satellite System* (GNSS) e do sistema de navegação inercial *Inertial Navigation System* (INS) (Shan e Toth, 2018). A partir da integração e sincronização dos sensores de posicionamento e orientação é possível estimar a posição e orientação da plataforma e consequentemente do sensor LASER. A integração GNSS/INS possibilita que dados de um sistema minimizem possíveis erros sistemáticos do outro sistema.

Basicamente, pode-se assumir a existência de quatro sistemas de coordenadas distintos em um levantamento por SVLA, como mostra a Figura 2.2: Sistema de referência; Sistema GNSS/INS; Sistema da unidade LASER; e Sistema do pulso LASER. Os parâmetros de translação (Δx , Δy , Δz) entre os sistemas GNSS/INS da unidade LASER são determinados por meio do levantamento preciso dos vetores entre as origens dos sistemas. Segundo Vosselman e Maas (2010), esta tarefa pode ser realizada por um levantamento terrestre, uma vez que uma

precisão de $\pm 0,01$ m é suficiente. A calibração dos parâmetros de *lever-arm* e da matriz de *boresight* é realizada por voos e procedimentos de calibração específicos (Vosselman e Maas, 2010).

A Unidade de controle e registro de dados é responsável por armazenar os dados dos sensores de posicionamento e orientação, além dos dados coletados pelo sistema LASER, e ainda pela sincronização de horário e controle de todo o sistema (Vosselman e Maas, 2010). Para a integração dos dados do SVL e posterior obtenção das coordenadas de pontos em um sistema de referência, além dos parâmetros de translação e desalinhamento entre os sistemas envolvidos, é necessária a sincronização dos dados de todos os sistemas sensores envolvidos (GNSS, INS e unidade LASER), para que todos os dados estejam em um mesmo referencial de tempo (Wehr e Lohr, 1999; Vosselman e Maas, 2010). Como os sensores que compõe os sistemas operam em diferentes frequências, e geralmente a frequência de repetição dos pulsos LASER é muito maior que a frequência de operação do sensor GNSS e do INS, as posições e orientações devem ser interpoladas para os instantes de medida de distância LASER.

Figura 2.2 - Sistemas de coordenadas envolvidos na aquisição de dados LiDAR.



Fonte: Adaptado de Habib *et al.* (2008).

A partir das medidas obtidas pelos sensores acoplados à plataforma (GNSS/INS, e LASER), dos vetores de translação entre a origem do sistema de coordenadas de referência e a origem dos sistemas de coordenadas dos sensores, e seus respectivos ângulos de desalinhamento

calibrados, as coordenadas de um ponto podem ser obtidas pela Equação 2.3 (Habib *et al.*, 2008, 2010).

$$\overrightarrow{X_G(t)} = \overrightarrow{X_0(t)} + R_{\omega,\varphi,\kappa}(t) * \vec{P}_G + R_{\omega,\varphi,\kappa}(t) * R_{\Delta\omega,\Delta\varphi,\Delta\kappa} * R_{\alpha,\beta}(t) * \vec{\rho}(t) \quad (2.3)$$

em que:

$\overrightarrow{X_G(t)}$ – Vetor de coordenadas de um dado ponto iluminado no instante t;

$\overrightarrow{X_0(t)}$ – Vetor de coordenadas da origem do sistema GNSS/INS no instante t;

$\vec{P}_G$ – Vetor com os parâmetros de translação entre as origens dos sistemas GNSS/INS e da unidade LASER;

$R_{\omega,\varphi,\kappa}(t)$ - Matriz de rotação entre o sistema de coordenadas GNSS/INS e o sistema de referência;

$R_{\Delta\omega,\Delta\varphi,\Delta\kappa}$ – Matriz de rotação entre o sistema GNSS/INS e o sistema da unidade LASER, no instante t. Resultante de pequenos desalinhamentos dos sistemas;

$R_{\alpha,\beta}(t)$ - Matriz de rotação entre o sistema da unidade LASER e o sistema do pulso LASER. Essa matriz é resultante do ângulo de varredura de um determinado pulso no instante t;

$\vec{\rho}(t)$ – Vetor que liga a unidade LASER ao ponto no terreno; e

t – Instante de recepção do pulso LASER.

A acurácia da nuvem de pontos resultante dependerá da qualidade das medidas realizadas pelos sensores, da qualidade da determinação dos parâmetros de translação e desalinhamento entre os sensores e da precisão do processo de sincronização e interpolação dos dados.

2.2 Nuvem de pontos fotogramétrica

Com o desenvolvimento de processos de automação, a Fotogrametria digital aérea e de curto alcance tornaram-se ferramentas poderosas e amplamente utilizadas para a modelagem topográfica tridimensional (Remondino e El-Hakim, 2006; Fraser e Cronk, 2009; Iqbal *et al.*, 2021).

Fazendo uso da Fotogrametria, aliada a outras ciências como a Cartografia, a Geodésia e, mais recentemente, a Visão Computacional, é possível a determinação de pontos sobre a superfície física. Segundo Mikhail, Bethel e McGlone (2001), a função fundamental da Fotogrametria é

estabelecer uma rigorosa relação geométrica entre a imagem e a forma do objeto no momento do imageamento. Tal relação é possível por meio dos processos fotogramétricos de orientação interior e exterior. O processo de orientação interior consiste na reconstrução do feixe perspectivo que deu origem à imagem. A orientação exterior permite a recuperação da posição e orientação de cada imagem segundo um referencial terrestre, geralmente aquele no qual se pretende realizar o levantamento fotogramétrico.

Em Fotogrametria o principal modelo matemático são as equações de colinearidade, que são equações projetivas baseadas no princípio da colinearidade entre pontos na imagem, o centro perspectivo da câmara (definido a partir do conjunto de lentes) e os pontos no espaço objeto (Equação 2.4).

$$\begin{aligned} x_i &= -f \frac{r_{11} * (X_i - X_{cp}) + r_{12} * (Y_i - Y_{cp}) + r_{13} * (Z_i - Z_{cp})}{r_{31} * (X_i - X_{cp}) + r_{32} * (Y_i - Y_{cp}) + r_{33} * (Z_i - Z_{cp})} \\ y_i &= -f \frac{r_{21} * (X_i - X_{cp}) + r_{22} * (Y_i - Y_{cp}) + r_{23} * (Z_i - Z_{cp})}{r_{31} * (X_i - X_{cp}) + r_{32} * (Y_i - Y_{cp}) + r_{33} * (Z_i - Z_{cp})} \end{aligned} \quad (2.4)$$

sendo:

(x_i, y_i, f) – coordenadas dos pontos no sistema fotogramétrico;

$(r_{11}, r_{12}, r_{13}, \dots, r_{33})$ – elementos da matriz de rotação $R(\omega, \varphi, \kappa)$ que relaciona os dois sistemas;

(X_i, Y_i, Z_i) – coordenadas dos pontos no espaço objeto; e

(X_{cp}, Y_{cp}, Z_{cp}) – coordenadas do centro perspectivo da câmara no espaço objeto.

A partir das equações de colinearidade é possível obter as coordenadas tridimensionais (X, Y, Z) de um dado ponto no terreno, desde que esse ponto esteja presente em ao menos duas imagens. Um dos procedimentos clássicos em fotogrametria é o ajustamento por feixes de raios, conhecido como *Bundle Block Adjustment* (BBA), no qual podem ser estimados todos os parâmetros do modelo matemático para um conjunto de (n) imagens contendo (p) pontos. Ao fim da aplicação do BBA as coordenadas 3D dos pontos no espaço objeto, bem como as posições e orientação das imagens são recuperados. Adicionalmente, existe a possibilidade de fazer a estimativa simultânea dos parâmetros de calibração da câmara, a partir da incorporação de parâmetros adicionais às Equações de Colinearidade apresentadas, como pode-se ver em Fraser (1997) e Galo e Tommaselli (2011).

O desenvolvimento de técnicas de processamento como SfM, aliado às técnicas de medição automática de pontos e ao estabelecimento da correspondência, por exemplo, tem impulsionado a obtenção de nuvem de pontos fotogramétricas com grande nível de detalhamento (Remondino e El-Hakim, 2006; Matthews, 2008; Fraser e Cronk, 2009). O processamento fotogramétrico tem seu advento baseado em 3 principais etapas: detecção de *key points* e construção de seus descritores; reconstrução da cena por meio de nuvem esparsa de pontos e estimativa dos parâmetros intrínsecos ao modelo matemático utilizado (SfM); e adensamento da nuvem de pontos (SGM).

A evolução histórica dos métodos e técnicas de detecção de *key points* tem seu início por volta da década de 1980, quando Moravec (1977) apresentou técnica voltada para a detecção de cantos, e Förstner e Gülch (1987) e Harris *et al.* (1988) apresentaram os detectores de *key points* com base em autovalores. Vale destacar que, tais detectores apresentam limitações quanto há variações de escala e rotação das cenas. No início da década de 2000 surgiram os detectores de *key points* invariantes aos parâmetros da transformação de similaridade (rotação, translação e escala) e aos parâmetros da transformação afim (rotação, translação, escala e não ortogonalidade). Dentre eles pode-se destacar: o detector Hessian-Affine (Mikolajczyk e Schmid, 2002; Mikolajczyk e Schmid, 2004), Harris-Affine (Mikolajczyk e Schmid, 2002; Mikolajczyk e Schmid, 2004), Maximally Stable Extremal Regions (MSER) (Matas *et al.*, 2004), e Scale Invariant Feature Transform (SIFT) (Lowe, 2004), dentre outros.

A invariância à escala baseia-se na detecção de pontos que se mantenham constantes conforme a escala das imagens é alterada. Para tal, as imagens são submetidas a um filtro Gaussiano, o qual possibilita a simulação da imagem em diferentes escalas. Com base nas múltiplas escalas de uma imagem, os algoritmos Hessian-Affine e Harris-Affine utilizam um operador laplaciano para a determinação da escala na qual o ponto é melhor representado (Mikolajczyk e Schmid, 2002; Mikolajczyk e Schmid, 2004). O algoritmo SIFT por outro lado, considera as múltiplas escalas para a seleção de pontos invariantes e a construção de detectores não influenciáveis por tais variações. A partir da vizinhança de cada ponto, a invariância à rotação pode ser obtida pela normalização baseada na orientação do gradiente predominante (Lowe, 2004) ou com base na determinação de uma região afim local (Mikolajczyk *et al.*, 2005).

Desenvolvido por volta de 1990, a técnica SfM está presente em diversos softwares de processamentos comerciais, como por exemplo Pix4D Mapper Pro, Agisoft PhotoScan (agora

denominado Metashape), Trimble Inpho, entre outros. As diferentes abordagens do SfM podem ser classificadas em incremental ou global, de acordo com Schonberger e Frahm (2016) e Gao *et al.* (2022). A abordagem incremental consiste na estratégia mais empregada para lidar com imagens “desordenadas”, ou seja, imagens sem uma sequência e sem informações posicionais (Schonberger e Frahm, 2016). Ainda segundo os mesmos autores, esta abordagem incremental apresenta maior robustez, porém traz alto custo computacional e pode incorrer em deriva devido ao acúmulo de erros ao longo do processo. A abordagem global, por outro lado, é capaz de lidar com a reconstrução da cena e estimar os parâmetros das imagens a partir de injunções relacionais. Tal abordagem é menos custosa computacionalmente e não é sensível à deriva, porém a acurácia da reconstrução é ligeiramente menor e tem menor robustez (Schonberger e Frahm, 2016).

De modo geral, o SfM consiste no alinhamento em bloco de imagens em um processo iterativo de solução das equações de colinearidade a partir do método BBA. Na solução pelo SfM deve-se considerar que o método garante apenas a convergência pelo MMQ para um mínimo local, assim é primordial que uma boa aproximação inicial seja considerada. Para contornar a limitação citada, algumas implementações buscam uma solução sequencial das posições e atitudes das tomadas das imagens e da reconstrução da cena (Lhuillier e Quan, 2005). Nessas implementações, a determinação aproximada das posições e orientações das imagens é estimada com base em uma nuvem esparsa de pontos.


A inicialização do SfM considera a estimativa da orientação relativa de pares de imagens. Em seguida os pontos homólogos determinados para cada par têm suas coordenadas 3D estimadas em um sistema de coordenadas arbitrário. O refinamento dos parâmetros de inicialização é obtido pela aplicação do BBA considerando as imagens e seus respectivos pontos homólogos. Em seguida, o BBA é aplicado novamente para a estimativa dos parâmetros intrínsecos da câmara. É importante destacar que a transformação de coordenadas de um sistema relativo em um sistema de coordenadas absolutas pode ser obtida usando uma transformação de similaridade 3D baseada em um pequeno número de pontos de controle.

2.3 Comparação entre nuvem de pontos LiDAR e nuvem de pontos fotogramétrica

Devido às particularidades dos princípios de aquisição das informações tridimensionais, as nuvens de pontos LiDAR e fotogramétricas apresentam características distintas. O primeiro


princípio considera a propagação de um pulso no espaço e a sua resposta registrada pelo detector (Figura 2.3). O segundo considera a estimativa das coordenadas de um dado ponto a partir da intersecção de no mínimo dois feixes de raios (Figura 2.3).

Um aspecto importante a favor do uso de nuvens fotogramétricas é fundamentado na possibilidade de utilização das informações radiométricas capturadas pelo sensor e na possibilidade de aquisição de dados com alta densidade (Leberl *et al.*, 2010). Esse aspecto destacado tem sido superado em razão dos avanços tecnológicos que possibilitaram o desenvolvimento de sistemas LiDAR que permitem o registro de informações radiométricas. Ainda assim, vale considerar que tais sensores podem apresentar alto custo e que as nuvens fotogramétricas ainda consistem em uma alternativa importante. As informações radiométricas permitem a caracterização dos alvos presentes na cena a partir da assinatura espectral, e subsidiam as atividades de classificação de objetos da cena. Por outro lado, um argumento utilizado em favor das nuvens LiDAR consiste na capacidade de adquirir múltiplos retornos de um único pulso (Leberl *et al.*, 2010). Os múltiplos retornos são resultantes da dispersão do feixe ao se propagar na trajetória entre a fonte emissora até o alvo e ocorrem em regiões em que a reflexão do feixe é parcial, como por exemplo, folhas da vegetação, galhos de árvores ou bordas de edificações.



Em regiões de vegetação a capacidade de registro de múltiplos retornos fica ainda mais evidente devido às características do dossel, o qual pode apresentar vazios de cobertura folhear, possibilitando que o feixe capture informação de partes que o permeiam. Assim, as nuvens LiDAR podem apresentar informações tanto do topo do dossel quanto do interior, e até mesmo do solo ou de objetos presentes sob as vegetações (Figura 2.4a). No caso de nuvens fotogramétricas, em que as coordenadas 3D dos pontos são estimadas a partir da correspondência de no mínimo dois raios perspectivos, não há ocorrência de pontos no interior da vegetação. Nesse caso, a aquisição de informações do terreno abaixo de vegetações só é possível caso o terreno seja visualizado em ao menos duas fotos. Na Figura 2.4 é exemplificado os tipos de pontos presentes na nuvem LiDAR (a) e fotogramétrica (b).

Figura 2.4 - Amostragem de pontos. (a) nuvem de pontos LiDAR; e (b) nuvem de pontos fotogramétrica.



Fonte: Elaborada pelo autor.

Leberl *et al.* (2010) comparam dados provenientes de levantamento LiDAR com dados adquiridos por técnicas fotogramétricas. As vantagens de um método de aquisição, e consequentemente de uma nuvem de pontos, em relação ao outro têm sido objeto de estudos e discussões durante a última década (Leberl *et al.*, 2010; Wallace *et al.*, 2016; Guerra-Hernández *et al.*, 2018; Filippelli, Lefsky e Rocca, 2019; Iqbal *et al.*, 2021). Os autores destacam diversas vantagens da aplicação de técnica fotogramétrica, dentre elas: alta rigidez da geometria do bloco, proporcionada pela fototriangulação a nível sub-pixel; procedimentos de verificação de erros implementados em softwares modernos de processamento; maior eficiência na coleta de dados,

principalmente com a popularização dos RPAS; redução dos efeitos de oclusão em razão da possibilidade de aquisição de imagens em diversos pontos de vista (imagens oblíquas); facilidade na interpretação de cena; dentre outros.

Em aplicações de extração de informações de terreno alguns autores consideram o LiDAR em detrimento às técnicas fotogramétricas (Baltsavias, 1999b; Bitelli, Dubbini e Zanutta, 2004). No contexto de extração de contornos de telhados não há unanimidade quanto aos dados mais adequados, sendo que as vantagens e desvantagens de cada técnica deve ser considerada pelos métodos de extração. Algumas das características de cada uma das técnicas estão sumarizadas na Tabela 2.1.

Tabela 2.1 – Características das nuvens de pontos LiDAR e fotogramétrica no contexto de extração de contornos de telhados.

Elementos de comparação	Nuvem LiDAR	Nuvem fotogramétrica
Linhas de descontinuidade	Menor densidade	Maior densidade
Regiões homogêneas	Não impactada	Dificuldade de correspondência
Precisão posicional	Maior em altimetria	Maior em planimetria
Informação semântica	Menor	Maior

Fonte: Adaptado de Shan e Toth (2018).

A superioridade de uma técnica em relação à outra é dependente da aplicação dos dados. Em aplicações em que sejam necessários dados radiométricos e alta densidade de informação, a nuvem fotogramétrica se apresenta como uma fonte de dados importante. Por outro lado, em aplicações em que seja priorizada a acurácia, em especial altimétrica, os dados provenientes de levantamentos LiDAR devem ser priorizados.


2.4 Fatores que influenciam a extração de contornos de telhados em nuvens fotogramétricas

A extração de informações sobre nuvens de pontos, sejam elas LiDAR ou fotogramétricas, é influenciada por diversos fatores, como por exemplo presença de pontos espúrios, densidade de pontos, variação de densidade ao longo da nuvem, oclusões causadas por vegetação e/ou edificações, e alta concentração de objetos na cena. Os fatores citados anteriormente são comuns em ambas as fontes de dados, porém as nuvens de pontos fotogramétricas podem ainda serem

influenciadas por presença de sombras, problemas de correspondência de imagens em regiões homogêneas e ou de padrões repetitivos.

A presença de pontos espúrios pode influenciar nas diversas etapas dos métodos de extração de informações, como por exemplo na filtragem, classificação, segmentação, extração de contornos, dentre outras. Em geral, os pontos espúrios devem ser identificados e excluídos do conjunto de dados em etapa prévia à aplicação dos processos de interesse. No caso de conjunto de dados LiDAR, a presença de pontos espúrios é usualmente menor do que em nuvem de pontos fotogramétricas. Em dados LiDAR, os pontos espúrios podem ser originados pela presença de aves, objetos aéreos, corpos d'água, e por atrasos no retorno do pulso em razão de reflexões do feixe, em regiões transparentes ou espelhadas, por exemplo (Sotoodeh, 2006). No caso de nuvens fotogramétricas, os pontos espúrios são, em sua maioria, resultantes de problemas na correspondência de imagens, especialmente em alvos homogêneos ou regiões de sombra, como mostrado na Figura 2.5.

Figura 2.5 - Exemplos de pontos espúrios em uma nuvem fotogramétrica. (a) Pontos espúrios em região de sombra; e (b) pontos espúrios em região homogênea.




Fonte: Elaborada pelo autor.

Os métodos que tratam da extração de edificações, como por exemplo segmentação e extração de contornos, usualmente consideram padrões de descontinuidade do conjunto de dados para a definição de limiares, como por exemplo a distância média entre os pontos. No caso de métodos de segmentação como o crescimento de regiões (do inglês - *Region Growing*), a distância média entre os pontos pode ser adotada como limiar para definir se um dado ponto é adicionado ou não ao agrupamento (*cluster*) testado. Nos métodos que tratam da extração de primitivas geométricas, como por exemplo a extração de planos dos telhados, o distanciamento entre pontos ou a densidade média não impactam diretamente no resultado. Entretanto, em casos extremos, considerando planos pequenos e grande perda de densidade, é possível que uma dada região não apresente quantidade adequada de pontos para a definição acurada dos parâmetros do plano.

A variação de densidade pode ocorrer entre diferentes conjuntos de dados (Figura 2.6a), ou até mesmo ao longo de um mesmo conjunto. No caso de variações da densidade ao longo da nuvem de pontos, a influência pode inviabilizar a aplicação de métodos que não tratem este tipo de problema (Santos, dos, Galo e Carrilho, 2019; Santos *et al.*, 2020). No caso de nuvens LiDAR, a variação de densidade da nuvem de pontos geralmente é resultante de variações de velocidade da aeronave, altura de voo e/ou atitude da aeronave durante a aquisição, pela sobreposição de faixas de voo consecutivas (Figura 2.6c), ou decorrentes do sistema de varredura, como o caso do espelho oscilante, por exemplo, em que pontos amostrados nas bordas da faixa de varredura possuem densidade diferente (Figura 2.1a). No caso de nuvens fotogramétricas, a variação de densidade da nuvem geralmente é resultante da variação da cobertura fotogramétrica, mudança da altura da tomada das imagens e/ou problemas de correspondência de imagens (Figura 2.6b). A densidade da nuvem de pontos quando uniforme terá impacto apenas em momento prévio à aplicação dos métodos nos quais tal fator tem influência, como por exemplo durante a definição de limiares.


Figura 2.6 - Variação de densidade da nuvem de pontos: (a) nuvens de pontos LiDAR adquiridas em três alturas de voo diferentes; (b) nuvem de pontos fotogramétrica após eliminação de pontos espúrios; e (c) nuvem de pontos LiDAR com variação de densidade devido à sobreposição de faixas de varredura.



Fonte: Adaptado de Santos (2019).

A oclusão de objetos de interesse, causada por edificações e por vegetação, é um problema recorrente, tanto em dados LiDAR quanto em dados fotogramétricos. Objetos altos podem provocar a obstrução parcial ou total de objetos mais baixos localizados em suas proximidades, a depender do ponto de vista do observador (neste caso, do sensor). O efeito das oclusões causadas por edificações é similar em ambos os conjuntos, não havendo informação sob a área. No caso de oclusões causadas por vegetação, há diferenças entre os efeitos ocorridos em cada um dos conjuntos de dados. Nos dados LiDAR é possível que alguns pontos sejam obtidos sob a área de oclusão em decorrência da característica de penetração dos feixes no dossel da vegetação (Figura 2.7b). Por outro lado, nos dados fotogramétricos usualmente a oclusão é total, não havendo nenhum ponto sob a região ocluída (Figura 2.7a). Os exemplos apresentados na Figura 2.7 tratam de duas áreas distintas.


Figura 2.7 - Efeito da oclusão causada por vegetação (azul) próxima à edificação (rosa). (a) nuvens fotogramétricas; e (b) nuvens de pontos LiDAR. As imagens da esquerda apresentam uma vista perspectiva lateral inclinada, enquanto as imagens da direita apresentam a vista nadiral dos pontos amostrados sobre a edificação.



Fonte: Elaborada pelo autor.

No que tange a extração automática de edificações, diferentes técnicas de classificação e segmentação podem ser exploradas para a obtenção do agrupamento referente a cada edificação. No entanto, a grande quantidade de edificações e vegetação aumenta substancialmente a complexidade do conjunto de dados (Figura 2.8). Nesses casos, a classificação e a segmentação dos indivíduos presentes na cena tornam-se tarefas não triviais para os processos automáticos. Na Figura 2.8 é apresentado um exemplo do resultado do método de segmentação aplicado sobre pontos classificados como edificação, sendo possível observar a não separação entre as edificações contíguas, como destacado nas Figuras 2.8b, 2.8c e 2.8d.

Figura 2.8 - Dificuldade de segmentação de edificações em cena com alta complexidade devido à proximidade entre construções vizinhas. (a) vista nadir de região com alta densidade de edificações; (b) resultado do procedimento de crescimento de regiões; (c) vista inclinada, mostrando a proximidade das edificações; e (d) resultado da segmentação para as 4 edificações destacadas.



Fonte: Elaborada pelo autor.

Capítulo 3

Classificação de nuvem de pontos fotogramétricas em ambiente urbano


A complexidade de ambientes urbanos é um dos fatores que dificultam a discriminação dos diferentes objetos presentes na cena, principalmente a partir de métodos automáticos de classificação (Sohn e Dowman, 2007). Nesse sentido, diversos trabalhos têm explorado a integração de imagens e dados LiDAR com foco na sinergia entre dados radiométricos e geométricos para tarefas de classificação (Hermosilla *et al.*, 2011; Malpica *et al.*, 2013). Uma alternativa à necessidade de integração de diferentes conjuntos de dados é a utilização de nuvens de pontos fotogramétricas, as quais têm sido cada vez mais exploradas em razão dos desenvolvimentos recentes de RPAS, sensores de posicionamento e sensores inerciais, concomitantemente ao desenvolvimento de algoritmos para processamento de imagens e visão computacional (Nex e Remondino, 2014; Rau, Jhan e Hsu, 2015; Ali-Sisto e Packalen, 2017).

Embora o desenvolvimento de plataformas RPAS tenha permitido grandes avanços na aquisição de dados, a capacidade de carga útil define limitações para a quantidade e qualidade dos sensores embarcados nesta plataforma (Colomina e Molina, 2014; Nex e Remondino, 2014), impactando diretamente na quantidade de informações radiométricas disponíveis (Aasen *et al.*, 2015; e Näsi *et al.*, 2018). No caso de nuvens de pontos resultantes do processamento fotogramétrico de imagens obtidas por sensores embarcados em RPAS, geralmente há uma quantidade limitada de informações radiométricas. Além das limitações dos dados radiométricos, outro problema está relacionado à precisão posicional da nuvem de pontos, a qual geralmente apresenta maior frequência de pontos espúrios se comparada aos dados LiDAR (Leberl *et al.*, 2010; Wallace *et al.*, 2016; Filippelli, Lefsky e Rocca, 2019), que afeta diretamente a qualidade dos objetos extraídos. Nestes casos, a exploração da complementaridade de informações radiométricas e geométricas é ainda mais importantes.

Nesse capítulo é apresentado o método proposto para a classificação da nuvem de pontos fotogramétrica. Inicialmente é feita uma descrição dos atributos selecionados. Na sequência é apresentada uma ideia geral dos classificadores empregados, sendo destacado o classificador *Randon Forest*. Por fim é colocada a etapa de refinamento dos resultados derivados da classificação. Essa etapa de refinamento foi proposta com o intuito de minimizar os erros de classificação devido à presença de sombra nas classes “telhados” e “árvores”.

Os procedimentos adotados para a classificação da nuvem de pontos consideram a extração de atributos radiométricos e geométricos, a aplicação de um classificador e de processos de refinamento de pontos nas regiões de sombra e pontos sobre objetos não previstos na classificação. A sequência de processos aplicados pode ser visualizada no fluxograma apresentado na Figura 3.1.

Figura 3.1 - Fluxograma geral das etapas de definição de atributos, classificação da nuvem de pontos e refinamentos da classificação.



Fonte: Elaborada pelo autor.

3.1 Descrição dos atributos utilizados na classificação

No que tocante à definição de atributos, trabalhos que visam a classificação de nuvens de pontos tendem a explorar a potencialidade de atributos geométricos, como por exemplo (Weinmann *et al.*, 2017). No caso de nuvem de pontos fotogramétricas, além de atributos geométricos é possível a utilização de atributos radiométricos, como por exemplo em Pessoa *et al.* (2019a) e Pessoa *et al.* (2019b). O primeiro trabalho apresenta um estudo para a classificação de nuvem de pontos fotogramétricas em ambiente urbano, considerando atributos radiométricos e geométricos aplicados à uma árvore de decisão projetada com este propósito. O segundo apresenta o processo de classificação considerando a mesma área teste e mesmos atributos, porém considera a aplicação do classificador RF. Na sequência serão apresentados os procedimentos para a extração dos atributos considerados neste trabalho.

3.1.1 Atributos radiométricos

Os sensores utilizados na aquisição de informações sobre a superfície terrestres usualmente consideram a energia eletromagnética refletida pelos alvos, em uma ou mais faixas do espectro. Inicialmente, a quantidade de atributos radiométricos é igual a quantidade de bandas capturadas pelo sensor. Richards e Jia (2006) destacam que, dependendo do sensor utilizado e da aplicação, dois problemas podem emergir: grande quantidade de atributos ou possibilidade de alvos serem indistinguíveis considerando apenas os atributos originais, capturados pelo sensor. Nesses casos, uma alternativa para facilitar a extração de informações, bem como para melhorar a diferenciação de alvos em dados de Sensoriamento Remoto é a utilização de alguns métodos de transformações baseados em aritmética de bandas. Dentre esses métodos podem ser consideradas as transformações em espaços de cores e o uso de índices espectrais.

Neste trabalho a nuvem de pontos utilizada apresenta informações radiométricas adquiridas em três faixas do espectro eletromagnético: Verde (*Green* – G), Vermelho (*Red* – R) e infravermelho próximo (*Near-InfraRed* – NIR). Em Pessoa *et al.* (2019) é apresentado um estudo detalhado sobre a importância de cada atributo radiométrico na discriminação dos alvos em uma área urbana. Além dos atributos radiométricos originais (G, R, NIR), foram considerados alguns atributos adicionais como o *Minimum* (R, G, NIR) e o índice espectral *Normalized Difference Vegetation Index* (NDVI).

Os índices espectrais são utilizados com o objetivo de realçar alvos específicos, de acordo com as suas respostas espectrais. Esses índices são obtidos a partir de operações aritméticas entre bandas espectrais, envolvendo faixas de reflectância específicas que possibilitam a diferenciação dos alvos. No caso deste trabalho, como o propósito é identificar as oclusões provocadas pela vegetação e a minimização desse efeito, optou-se pela utilização do índice NDVI (Equação 3.1) que permite o realce da vegetação.

$$NDVI = \frac{\rho_{nir} - \rho_{red}}{\rho_{nir} + \rho_{red}} \quad (3.1)$$

Jensen (2005) afirma que o índice NDVI é válido como uma medida efetiva na separação entre pixels caracterizados pelo crescimento ativo da vegetação daqueles que são não vegetados ou caracterizados por vegetação senescente, constituindo um dos principais índices para a classificação de áreas vegetadas.

3.1.2 Atributos geométricos baseados nos autovalores

De acordo com Lin *et al.* (2014) a partir de um dado ponto p_i e uma dada vizinhança v_i , no espaço tridimensional, é possível obter um conjunto de atributos que descrevem o ponto e/ou sua região. Entre esses atributos, os autovalores (λ_i) calculados a partir da matriz de covariância de um conjunto de pontos locais consistem em descritores geométricos (Lin *et al.*, 2014). Autovalores podem ser eficientemente obtidos pela análise de componentes principais (do inglês *Principal Component Analysis* - PCA) (Johnson e Wichern, 1998; Jutzi e Gross, 2009; Mallet *et al.*, 2011), que é uma ferramenta matemática amplamente utilizada em estudos como segmentação e reconstrução de objetos a partir de nuvens de pontos (Sampath e Shan, 2010).

Os autovalores ($\lambda_1, \lambda_2, \dots, \lambda_n$) correspondem à variância das componentes principais e podem ser obtidos a partir da matriz de covariância dos dados originais, considerando a aplicação da Equação 3.2. A cada autovalor λ_i é associado um autovetor $\vec{e}^i$ de módulo unitário, sendo que os autovalores podem ser obtidos pela aplicação da Equação 3.3.

$$\det (\Sigma - I * \lambda) = 0 \quad (3.2)$$

$$(\Sigma - I * \lambda_i) * \vec{e}^i = 0 \quad (3.3)$$

sendo Σ a matriz de covariância das variáveis originais; I matriz identidade de ordem igual ao número de variáveis originais; λ_i iésimo autovalor; e $\vec{e}^i$ iésimo autovetor. O número de autovalores e autovetores obtidos será igual ao número de variáveis originais.

Os autovalores obtidos são maiores ou iguais a zero e por padrão são ordenadas de maneira decrescente, ou seja, $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n \geq 0$. Segundo Gumhold *et al* (2001), com base nos autovalores obtidos a partir das coordenadas 3D é possível inferir sobre a estrutura geométrica da vizinhança analisada: $\lambda_1 > \lambda_2 \approx \lambda_3$ representa um elipsoide alongado na direção do eixo de maior variabilidade, semelhante a uma estrutura linear como por exemplo bordas de edificação; $\lambda_1 \approx \lambda_2 > \lambda_3$ indica um elipsoide achatado, analogamente a uma estrutura plana; e $\lambda_1 \approx \lambda_2 \approx \lambda_3$ corresponde a uma estrutura volumétrica como nos cantos de edifícios. Assim, após a estimativa dos autovalores, a planaridade de uma vizinhança, e conseqüentemente do ponto gerador da vizinhança em questão, é assumida caso a condição $\lambda_1 \approx \lambda_2 > \lambda_3$ seja verificada.

A extração de atributos geométricos por meio de autovalores é diretamente influenciada pela etapa de definição da vizinhança. Nesse contexto, alguns trabalhos buscam a definição de uma vizinhança ótima a partir da análise do comportamento da entropia, como por exemplo (Demantké *et al.*, 2011; Weinmann *et al.*, 2015; Santos, Galo e Carrilho, 2018). De forma similar, neste trabalho os atributos geométricos são extraídos considerando a estimativa de uma vizinhança local ótima, com base no conceito de entropia. A determinação da vizinhança ótima consiste em um processo iterativo, aplicado a cada possível vizinhança de um dado ponto, da seguinte forma:

1. Para uma dada vizinhança estima-se a Matriz Variância Covariância (MVC), considerando as coordenadas 3D dos pontos contidos dentro da vizinhança;
2. A partir da MVC calcula-se os autovalores λ_1 , λ_2 e λ_3 (Equação 3.2);
3. Determinação dos atributos geométricos baseados nos autovalores: linearidade, planaridade e dispersão (Equações 3.4, 3.5 e 3.6); e
4. Estima-se o valor de entropia relacionado à vizinhança de interesse por meio da Equação 3.7.

$$L_{\lambda} = \frac{\lambda_1 - \lambda_2}{\lambda_1} \quad (3.4)$$

$$P_{\lambda} = \frac{\lambda_2 - \lambda_3}{\lambda_1} \quad (3.5)$$

$$S_{\lambda} = \frac{\lambda_3}{\lambda_1} \quad (3.6)$$

$$E_{p_i}^{v_i} = -L_{\lambda} \ln(L_{\lambda}) - P_{\lambda} \ln(P_{\lambda}) - S_{\lambda} \ln(S_{\lambda}) \quad (3.7)$$

Ao fim do processo iterativo, cada vizinhança possível terá um valor de entropia associado. A vizinhança ótima será aquela que apresentar o menor valor de entropia. Nesse trabalho a vizinhança pode variar de 10 a 100 pontos, considerando o passo de 1 ponto a cada iteração.

Após a definição da vizinhança ótima, para cada ponto são extraídos os atributos geométricos: linearidade (L_{λ}), planaridade (P_{λ}), dispersão (S_{λ}), anisotropia (A_{λ}), omnivariância (O_{λ}) e entropia dos autovalores (E_{λ}), os quais podem ser estimados a partir da aplicação das Equações 3.4, 3.5, 3.6, 3.8, 3.9 e 3.10, respectivamente. Vale destacar que, embora os atributos linearidade, planaridade e dispersão tenham sido estimados durante a definição da vizinhança ótima, o valor final foi reestimado apenas para a vizinhança considerada. Além dos atributos citados, o atributo altura (h) também foi considerado, no entanto esse atributo foi estimado durante o processo de filtragem, como descrito na Subseção 3.1.3

- Anisotropia:
$$A_{\lambda} = \frac{\lambda_1 - \lambda_3}{\lambda_1} \quad (3.8)$$

- Omnivariância:
$$O_{\lambda} = \sqrt[3]{\lambda_1 * \lambda_2 * \lambda_3} \quad (3.9)$$

- Entropia dos autovalores:
$$E_{\lambda} = - \sum_{i=1}^3 \lambda_i * \ln(\lambda_i) \quad (3.10)$$

3.1.3 Atributo altura, calculado a partir do Modelo Digital de Terreno

Para obtenção do atributo altura (h), inicialmente aplicou-se um processo de filtragem sobre a nuvem de pontos original para identificar os pontos pertencentes ao terreno e pontos sobre objetos (não terreno). Os pontos de não terreno consistem em pontos obtidos sobre objetos naturais, como árvores, ou sobre objetos artificiais, tais como edificações, veículos, linhas de transmissão etc. Segundo Pfeifer, Köstli e Kraus (1998), Axelsson (2000) e Sithole (2001), diversos algoritmos realizam a filtragem diretamente sobre dados irregularmente espaçados, como é o caso das nuvens de pontos, outras aplicações procuram adaptar algoritmos convencionais de processamento de imagem e, desse modo, necessitam de uma reamostragem prévia da nuvem de pontos para gerar uma malha regular de pontos.


Nesse trabalho a etapa de filtragem foi realizada utilizando um pacote de ferramentas de processamento de nuvem de pontos disponível no mercado, o rapidlasso *LAStools*, desenvolvido por Martin Isenburg (Isenburg, 2014). O *LAStools* contém ferramenta de filtragem e extração de MDT, mais especificamente a ferramenta *Lasground*. Nessa ferramenta estão definidos conjuntos de configurações padrão, sendo elas *town*, *city* e *metro*. Essas configurações foram definidas pelo desenvolvedor da ferramenta considerando diferentes padrões de relevo e cenas urbanas. Além dessas configurações é possível definir os parâmetros *spike*, *stddev* e *offset* a fim de priorizar a melhor separação entre pontos pertencentes ao terreno e pontos de não terreno. O parâmetro *spike* (informado em metros) remove picos na malha triangular (vértices com distância vertical para seus vizinhos de uma vez acima e dez vezes abaixo do valor especificado para o parâmetro). O parâmetro *stddev* é utilizado como medida de planaridade local. O parâmetro *offset* refere-se ao afastamento máximo para que um ponto seja incluído na malha TIN. Por se tratar de uma etapa de pré-processamento, nesse trabalho foram testadas variações das configurações padronizadas para a ferramenta de filtragem. Após análise visual o melhor resultado foi considerado para as etapas posteriores.

Segundo Isenburg (2014), a ferramenta *Lasground* realiza a filtragem com base em uma adaptação do algoritmo de filtragem *Progressive TIN Densification* (PTD) proposto por Axelsson (2000). O método PTD consiste em um dos métodos clássicos para filtragem de nuvem de pontos e é amplamente aplicado, tanto na comunidade científica, quanto na comunidade comercial (Zhang e Lin, 2013). Basicamente, o método PTD consiste na extração de MDT a partir de uma abordagem

iterativa. O método PTD proposto por Axelsson (2000) é constituído por dois processos: seleção dos pontos sementes e construção de uma malha triangular (*Triangular Irregular Network* – TIN) como aproximação inicial do terreno; e densificação progressiva dessa malha triangular com pontos que atendam aos critérios estipulados.

Na seleção dos pontos sementes e construção de um TIN, inicialmente uma malha regular (Figura 3.2a) é realizada com o intuito de subdividir a nuvem de pontos. Para tal, deve-se definir o retângulo envolvente e o tamanho de cada célula da malha. O tamanho das células da malha é definido com base na maior feição não pertencente ao terreno. Em cada célula da malha o algoritmo busca o ponto de menor altitude e o classifica como ponto semente. Os vértices do retângulo envolvente também são classificados como ponto de terreno e a eles atribui-se a altura do ponto semente mais próximo. Isso é feito para que todos os pontos da nuvem estejam dentro de um dos triângulos formados (Zhang e Lin, 2013). Nesse passo inicial os pontos sementes são utilizados para a geração de um TIN (Figura 3.2b), o qual é uma representação grosseira do terreno por ser construído com uma pequena amostra dos pontos da nuvem.


Figura 3.2 - Etapas de seleção de pontos sementes e geração da representação grosseira do terreno. (a) pontos semente para a geração da TIN; e (b) TIN gerada a partir dos pontos sementes.



Fonte: Adaptado de Zhang e Lin (2013).

Segundo Axelsson (2000), na etapa de densificação progressiva do TIN, a cada iteração os pontos são testados em relação ao triângulo ao qual estão inseridos. Um ponto é considerado pertencente ao terreno caso atenda a dois critérios (Figura 3.3): distância (d) do ponto à face do triângulo considerado; e os ângulos (α , β , γ) estimados considerando o plano do triângulo e os alinhamentos formados entre o ponto e os 3 vértices.

Figura 3.3 - Critérios para densificação progressiva do TIN.



Fonte: Adaptado de Axelsson (2000).

Por fim, os pontos detectados como pontos de terreno são adicionados ao TIN e uma nova iteração se inicia. O método é encerrado após a iteração em que nenhum ponto seja adicionado ao TIN.

Após a extração do MDT todos os pontos da nuvem são submetidos à estimativa do atributo altura, por meio da aplicação da ferramenta *lasheight*. A ferramenta *lasheight* estima a altura de cada ponto da nuvem com relação do TIN construído considerando os pontos pertencentes ao terreno, extraídos durante o processo de filtragem. Para cada ponto, a altura é estimada pela distância vertical entre o ponto e sua projeção sobre o TIN.

3.2 Classificação de nuvem de pontos

Dentre os métodos de classificação presentes na literatura, os classificadores baseados no conceito de aprendizagem de máquina (*Machine Learning*) têm sido utilizados para diversas aplicações. Uma das principais vantagens das técnicas de aprendizagem de máquina consiste na capacidade em resolver de forma autônoma problemas de natureza não linear (Chlingaryan, Sukkariéh e Whelan, 2018), considerando o pressuposto básico que computadores são capazes de detectar e quantificar

padrões por meio de algoritmos específicos (Behmann *et al.*, 2015). Entre os algoritmos mais populares encontram-se o *Support Vector Machine* (SVM), Árvores de Decisão, *Random Forest* (RF), Redes Neurais Artificiais (RNA), entre outros (Lary *et al.*, 2016). Cada um desses algoritmos apresenta características próprias, que os tornam apropriados às diferentes aplicações.

Além da escolha de um classificador adequado, a seleção de atributos e a definição das classes são etapas imprescindíveis para a classificação. Embora para o desenvolvimento deste trabalho seja relevante a identificação de apenas 2 classes, telhados e árvores, na etapa de classificação serão consideradas as classes asfalto, solo exposto, vegetação rasteira, telhados, árvores, linhas de transmissão e calçada. A definição de classes mais específicas foi realizada com o intuito de reduzir a variabilidade intraclasses, consequentemente potencializando a capacidade de discriminação dos atributos considerados. Além disso, vale destacar que as classes consideradas consistem nos principais tipos de alvos presentes numa área urbana.

Similar ao trabalho de Pessoa *et al.*, (2019a), nesse trabalho foram considerados atributos radiométricos e geométricos. Os atributos extraídos foram submetidos ao classificador *Random Forest* para a classificação dos pontos nas classes previstas. A aplicação do classificador RF possibilita a hierarquização dos atributos com base na contribuição deles em relação ao potencial de separabilidade das classes consideradas. Com isso, foram realizados experimentos de classificação considerando a utilização de atributos radiométricos, geométricos, e a combinação de ambos, visando analisar a contribuição de diferentes atributos para o processo de classificação. Por fim, os resultados foram analisados com base na matriz de erros da classificação, considerando o índice Kappa, acurácia global, bem como indicadores completude e nível de acerto. O subconjunto com os atributos selecionados, foi utilizado como entrada para a classificação final da nuvem e pontos.

3.2.1 *Random Forest*

O classificador RF possibilita a classificação da nuvem bruta sem a necessidade de processo prévio para regularização. Segundo (Breiman, 1996), o classificador *Random Forest* apresenta vantagens em comparação à outros classificadores de aprendizagem de máquina. Dentre elas podemos destacar a robustez à ruído, o rápido processamento em relação ao processo *bagging* e ao refinamento do *boosting*, a possibilidade de estimativas de erros internos e a possibilidade da estimativa da importância de cada atributo no processo de classificação. Além disso, tal

classificador é estritamente não-paramétrico e não requer suposições sobre a distribuição estatística dos dados de entrada, possibilita a estimativa da contribuição de cada atributo para o processo de classificação e é capaz de lidar com relações não-lineares entre os atributos e as classes. Por outro lado, o RF necessita de amostra de treinamento e pode apresentar dificuldades em lidar com classes desbalanceadas.

De acordo com Gao (2008), o classificador RF consiste em uma combinação de árvores de decisão. A técnica utilizada para a construção do *Random Forest* é uma combinação dos métodos *Bagging* e *Random Subspace*. Proposto por Breiman (1996), o método *Bagging* gera um número de novos conjuntos de treinamento de tamanho n a partir de um conjunto de treinamento de tamanho N , onde $n < N$. O método *Random Subspace* faz uma subamostragem no espaço de atributos. Em cada nó um conjunto m de atributos é selecionado e utilizado para definir o ponto de divisão adequado, sendo $m < M$ e M o total de atributos dos dados originais.

Cada árvore na floresta consiste de um nó raiz, nós de decisão e nós folha. O nó raiz é o nó mais geral que contém todas as amostras de entrada. No nó de decisão, um critério de divisão é definido considerando um atributo (ϕ) e uma regra de decisão (τ) aplicada ao atributo considerado. Após o processo de divisão, todos os pontos em um nó folha específico devem pertencer a uma classe específica.

Durante o processo de crescimento das árvores da floresta, em cada nó de decisão um atributo é selecionado levando-se em consideração a importância de cada um dos atributos para o processo de divisão (Gao, 2008). Existem várias possibilidades de métricas para avaliar a importância dos atributos (Friedl & Brodley, 1997). Segundo Gao (2008), os mais comuns são entropia, *Information Gain* e *Information Gain Ratio*. Depois de definir a aplicação dos atributos em cada nó de decisão, a próxima consideração importante é projetar uma regra de divisão apropriada, por meio da qual os dados de entrada são particionados em subconjuntos cada vez mais homogêneos. A regra de decisão escolhida em um determinado nó de decisão deve, portanto, ser aquela que fornece a maior homogeneidade nos subconjuntos dos nós descendentes. Muitos algoritmos foram desenvolvidos para estabelecer a regra de divisão nos nós internos durante o crescimento de uma árvore de decisão. Destas regras, as quatro mais comuns são o índice de Gini, entropia, o índice de Twoing e probabilidade de classe (Zambon *et al.*, 2006).

O classificador RF é implementado e disponibilizado por várias bibliotecas, sendo uma delas a biblioteca de aprendizado de máquina *Python Scikit-Learn* (Pedregosa *et al.*, 2011). Essa biblioteca permite que o usuário configure, entre outros parâmetros: as métricas para medir a importância dos atributos, a regra de decisão e definir a profundidade e o número de árvores na floresta. Neste trabalho, a métrica de entropia foi usada tanto para seleção de atributos quanto para definição de regras de decisão. Os parâmetros de profundidade e número de árvores foram selecionados empiricamente, após testes.

A profundidade variou de 5 a 100, enquanto o número de árvores variou de 50 a 10.000. Os valores finais para os parâmetros profundidade e quantidade de árvores foram definidos com base na acurácia global. Para tal, foram modificados os valores de profundidade, mantendo a quantidade de árvores igual à 10.000. Em seguida os valores de acurácia global da classificação foram analisados e o valor que produziu o resultado com maior acurácia global foi selecionado. A definição da quantidade de árvores foi realizada mantendo o valor de profundidade fixo e variando apenas a quantidade de árvores. De modo semelhante, o valor final para a quantidade de árvores foi definido com base nos valores de acurácia global.

Nesse trabalho todos os atributos gerados foram considerados para o processo de classificação. Foram produzidos quatro resultados para a classificação, um considerando apenas os atributos radiométricos (R, G, NIR, *minimum* (R, G, NIR) e NDVI), um considerando apenas os atributos geométricos (h , L_λ , P_λ , S_λ , A_λ , O_λ e E_λ), um considerando todos os atributos e um considerando os atributos radiométricos acrescidos do atributo geométrico altura (h). Esses experimentos têm por finalidade mostrar a contribuição trazida pela complementaridade dos atributos radiométricos e geométricos para o processo de classificação. Por fim, a classificação final foi gerada considerando apenas os atributos relevantes. A análise de relevância foi feita com base no *ranking* de atributos gerado pelo RF considerando todos os atributos extraídos.

3.3 Refinamento dos resultados de classificação para as classes telhados e árvores

Após a classificação, foram aplicados dois refinamentos sobre os pontos de interesse. O primeiro teve por objetivo minimizar os erros causados pela influência direta/indireta de sombras. O segundo, teve por objetivo identificar e eliminar pontos pertencentes a objetos não previstos dentro das classes consideradas. Vale destacar que, pontos gerados em regiões de sombra

apresentam baixa resposta espectral devido à baixa incidência de luz. Esse comportamento espectral prejudica diretamente a extração dos atributos radiométricos. Além disso, a extração de atributos geométricos é prejudicada de forma indireta, uma vez que existe uma maior incerteza na determinação das coordenadas 3D. Esse aumento na incerteza está relacionado à baixa quantidade de informação radiométrica em regiões de sombra, afetando negativamente a determinação precisa de pontos homólogos nestas regiões.

Em razão das classes de interesse deste trabalho serem árvores e telhados, os procedimentos de refinamento dos resultados da classificação foram desenvolvidos e aplicados apenas para tais classes. Vale ressaltar que os erros de classificação devido à existência de sombras impactam ambas as classes, enquanto os erros causados pela inserção de elementos não previstos como fachada das construções, muros, grades etc., os quais caracterizam geometricamente por pertencerem à planos verticais, impactam de forma significativa apenas a classe telhados. Desta forma, o refinamento para eliminar pontos de sombras foi aplicado para as duas classes, enquanto o procedimento de eliminação de pontos em regiões plano verticais foi aplicado apenas aos pontos de telhados, após a eliminação dos pontos de sombra.

Embora diferentes abordagens possam ser consideradas para determinar as possíveis áreas de sombra, a identificação dos pontos localizados em regiões de sombra foi realizada de forma similar ao apresentado por Pessoa *et al.* (2019a). No referido trabalho, foi verificado que o atributo *minimum (R, G, NIR)* apresenta resposta característica para os pontos de sombra. Similar ao trabalho de Pessoa *et al.* (2019a), o atributo *Minimum (R, G, NIR)* foi considerado após o resultado da classificação. Para identificação dos pontos de sombra, selecionou-se um limiar de forma empírica. Nesse contexto, pontos que apresentam valores de *Minimum (R, G, NIR)* inferiores a 0,3 (considerando a normalização dos valores no intervalo de 0 a 1), foram marcados como pontos de sombra e na sequência eliminados.

Os pontos sobre objetos não previstos, tais como muros, grades e fachadas de edificações, são definidos por planos verticais. Assim a identificação e posterior eliminação destes pontos foi realizada a partir da identificação de pontos em regiões planas e posterior estimativa da angulação do plano em relação ao plano horizontal. Para tal, foram utilizados os autovalores e autovetores estimados para a vizinhança definida pelos 20 pontos mais próximos ao ponto sob análise. O

procedimento para estimativa dos autovalores e autovetores foi realizada de forma similar ao descrito na Seção 3.1.2.

Foram aplicados dois limiares para verificar se um dado ponto pertence à uma superfície plana. O primeiro considera $\lambda_1 - \lambda_2 < 0,05$, enquanto o segundo assume que $\lambda_3 < 0,1$. Os pontos identificados sobre regiões planas tiveram a verticalidade de suas vizinhanças testadas com base no ângulo ϕ formado entre o vetor normal local (autovetor $\vec{e}_3$ associado ao terceiro autovalor λ_3) e o vetor normal ao horizonte, a partir da Equação 3.11 (Figura 3.4).

$$\cos \phi = \frac{\langle \vec{e}_3, \vec{e}_h \rangle}{|\vec{e}_3| \cdot |\vec{e}_h|} \quad (3.11)$$

Sendo $\vec{e}_h$ o vetor normal ao plano do horizonte, representado por $\langle 0, 0, 1 \rangle$; e $\vec{e}_3$ o terceiro autovetor $\langle x, y, z \rangle$, o qual por definição possui módulo igual a 1. Assim, a Equação 3.12 pode ser simplificada chegando à Equação 3.13.


$$\cos \phi = \frac{x * 0 + y * 0 + z * 1}{1} \quad (3.12)$$

$$\cos \phi = z \quad (3.13)$$

sendo z a terceira componente do terceiro autovetor.

Sabendo que um dado plano apresenta dois vetores normais com direções diametralmente opostas, os quais tem componentes inversas entre si (Figura 3.4), nesse trabalho optou-se por utilizar o vetor normal com menor ângulo em relação ao plano horizontal $(0, 0, 1)$, ou seja, o vetor normal ao plano que apresente a terceira componente maior ou igual a 0. Tal consideração reduz os valores possíveis de ϕ para o intervalo de -90° a 90° . Além disso, visto que a função arco cosseno resultará em valores negativos e positivos para ϕ , para um dado valor aplicado à função, e que por padrão podemos considerar para a análise apenas o valor positivo de ϕ , é possível aplicar o módulo de ϕ para analisar a verticalidade, reduzindo assim os valores possíveis para o intervalo de 0 a 90° .

Figura 3.4 - Ilustração geométrica do ângulo formado entre os vetores normais à dois planos. Nesse caso NV_1 apresenta componente z maior ou igual a 0, enquanto NV_2 apresenta z menor que 0.



Fonte: Elaborada pelo autor.

O ponto sob análise é considerado inserido em uma região plano vertical caso o ângulo estimado pela Equação 3.13 seja maior que 40° . A definição dos ângulos levou em consideração as características das edificações presentes na área sob análise. Tais pontos uma vez identificados são retirados do conjunto de pontos classificados como pontos de telhados.

Capítulo 4

Detecção de regiões de oclusão em edificações, causadas por árvores


Nesse capítulo são apresentadas as etapas que compõem o método proposto para detecção de oclusão. Os processos aqui descritos iniciam-se sobre os resultados dos processos descritos no Capítulo 3. A primeira etapa consiste em realizar um processo de segmentação. Na segunda etapa, um método de extração de contornos é aplicado. Por fim, a detecção das regiões de oclusão é executada por meio de um critério de proximidade no espaço bidimensional.

A sequência de processos visando a detecção das regiões de oclusão pode ser visualizada no fluxograma apresentado na Figura 4.1. Os dados de entrada correspondem aos conjuntos de pontos das classes “edificação” e “árvore”, identificados após os processos de refinamento da classificação (descritos no Capítulo 3). A segmentação é executada tanto para os pontos de edificações quanto para os pontos de árvores. Nesse caso, o algoritmo de crescimento de regiões (do inglês - *Region Growing*) baseado em limiares de distância pode ser aplicado tanto no espaço 2D quanto no espaço 3D. A extração de contornos é realizada usando o algoritmo *alpha-shape*, sendo também aplicado para ambas as classes. A detecção das oclusões é realizada a partir dos contornos das edificações e das árvores; sendo adotado um critério de proximidade entre estes contornos. Adicionalmente, uma análise de qualidade é executada com o intuito de avaliar a robustez do método.

Diferentemente de trabalhos de detecção de oclusões que exploram dados LiDAR, entre eles Feng *et al.* (2020), Mahphood e Arefi (2020) e Carrilho (2021), este trabalho de detecção de oclusão explora nuvem de pontos fotogramétrica. No geral, métodos de detecção de oclusão baseados em dados LiDAR exploram a característica de penetração do pulso e de múltiplos retornos para a identificação de regiões oclusas. Mahphood e Arefi (2020), por exemplo, exploram a característica de múltiplos retornos para detecção e extração de bordas de edificações, incluindo aquelas parcialmente oclusas. Carrilho (2021) e Feng *et al.* (2020) buscam a reconstrução de

contornos oclusos considerando a premissa de forma regular das edificações. Nesses trabalhos a característica de penetração do pulso é explorada. No caso de nuvens de pontos fotogramétricas não há penetração do pulso, em consequência disto não há registro de múltiplos retornos. Além disso, nesse tipo de dados é possível que não haja pontos amostrados na região de transição entre a árvore e o telhado. Tal ausência de pontos é oriunda de falhas na correspondência de imagens devido à existência de sombra ou até mesmo pela confusão radiométrica característica de tais regiões, conforme apresentado na Figura 2.7 na Seção 2. Em consequência do tipo de dados utilizado, diversos métodos já desenvolvidos para a detecção de oclusão não apresentarão bons resultados devido às premissas consideradas, com isso destaca-se a importância de explorar alternativas para a detecção de oclusões com base em nuvem de pontos fotogramétricas.

Figura 4.1 - Fluxograma geral das etapas de segmentação, extração de contornos e detecção de regiões oclusas.



Fonte: Elaborada pelo autor.


4.1 Segmentação

O objetivo de processos de segmentação consiste em particionar um conjunto de dados em subconjuntos com base no compartilhamento de características similares. A literatura apresenta a evolução dos métodos e de suas aplicações. Os processos de segmentação foram desenvolvidos inicialmente para fins de análise de imagens, porém muitos dos conceitos desenvolvidos para imagens podem ser adaptados para segmentar nuvens de pontos (Nguyen e Le, 2013). Dentre os diversos conceitos de segmentação aplicados a nuvens de pontos, neste trabalho optou-se por utilizar o conceito de crescimento de regiões (*Region Growing - RG*). Essa abordagem possibilita a diferenciação de dados não similares e conectados no espaço, sendo um método de simples conceptualização e que permite a adoção de múltiplos critérios. Por outro lado, o RG apresenta sensibilidade a ruídos, sendo um método local.

Na etapa de segmentação os pontos rotulados como árvore e edificações foram processados separadamente, sendo considerados diferentes limiares de segmentação para cada classe. Para os pontos de árvores foi utilizado um limiar de distância euclidiana no plano. Para os pontos de edificações, adicionalmente foi aplicado um limiar de distância vertical. O algoritmo RG é descrito de forma simplificada na lista de passos a seguir e de forma mais detalhada no fluxograma apresentado na Figura 4.2.

1. Dado o conjunto de pontos rotulados C_r composto de árvore ou edificações, selecionar aleatoriamente um ponto P_i ;
2. Criar um segmento N_j e adicionar o ponto P_i ;
3. Calcular os atributos considerados na segmentação;
4. Os pontos de C_r que atenderem as condições previstas devem ser movidos para o segmento N_j ;
5. Selecionar aleatoriamente um ponto de N_j que ainda não tenha sido utilizado e repetir os passos 3 e 4. Caso não exista em N_j pontos não utilizados seguir para o passo 6;
6. Se existir ao menos 1 ponto em C_r ir para o passo 1. Caso contrário o algoritmo é finalizado.

Figura 4.2 – Fluxograma do crescimento de regiões, por meio da aplicação do algoritmo *Region Growing*.



Fonte: Elaborada pelo autor.

Os limiares utilizados no algoritmo descrito na Figura 4.2 têm influência direta no resultado da etapa de segmentação. Neste trabalho, os valores relacionados a tais limiares foram definidos empiricamente. A definição do TD_{xy} considerou a separação mínima esperada para edificações/árvores vizinhas e medidas de densidade da nuvem de pontos utilizada (0,20 m), enquanto a definição do TD_h considerou a inclinação médias das faces dos telhados das edificações e a separação vertical esperada entre edificações vizinhas. Para a segmentação dos *clusters* de edificação foi utilizado o limiar de distância euclidiana no plano TD_{xy} no valor de 0,25 m e o limiar de distância vertical TD_h no valor de 0,10 m. Para a segmentação dos *clusters* de árvores foi utilizado o limiar de distância euclidiana no plano TD_{xy} no valor de 0,40 m. Vale ressaltar que, nos casos em que as construções sejam contíguas o algoritmo não é capaz de segmentá-las, conforme exemplos apresentados na Figura 2.8, na Seção 2.4.

Ao fim do processo de crescimento de regiões foram aplicados limiares considerando um número mínimo de pontos por agrupamento formado. No caso dos agrupamentos de edificação foi considerado o mínimo de 500 pontos, equivalente a edificações com área de aproximadamente 15 m². No caso dos agrupamentos de árvores foi considerado o mínimo de 200 pontos, equivalente a árvores com área de aproximadamente 6 m².


4.2 Extração de contornos das edificações e árvores

A determinação dos contornos de objetos é uma tarefa não trivial como destacam Rottensteiner e Brieser (2002). Em se tratando da determinação de contornos a partir de nuvem de pontos, o conceito de *convex hull* é amplamente utilizado. Este conceito possibilita a extração dos contornos de um conjunto de pontos com baixo custo computacional (Wang e Shan, 2009). No entanto, o *convex hull* falha em extrair o contorno em regiões côncavas (Sampath e Shan, 2007). Como alternativa para a extração de contornos mais complexas, incluindo concavidades, Edelsbrunner *et al.* (1983) propuseram o algoritmo conhecido como *alpha-shape*, ou α -shape.

No algoritmo *alpha-shape*, a definição dos pontos pertencentes ao contorno de um dado conjunto é realizada da seguinte forma: a partir de dois pontos randomicamente selecionados (P_1 e P_2) duas circunferências de raio α são construídas de forma que os pontos P_1 e P_2 pertençam sobre suas bordas (Figura 4.3a). O segmento que liga os pontos P_1 e P_2 será considerado contorno caso não exista nenhum ponto pertencente a S no interior de ao menos uma das circunferências. Caso a

circunferência tenha em seu interior pelo menos um ponto do conjunto S, o segmento que liga os pontos P_1 e P_2 não será considerado contorno (Figura 4.3b). Esse procedimento é repetido iterativamente para todos os pontos. De forma geral, o algoritmo α -shape pode ser interpretado como a convolução de um círculo de raio α sobre um conjunto de pontos S (Figura 4.3c). De acordo com Segundo Wei (2008) e Shen *et al.* (2011), o algoritmo α -shape pode ser utilizado para reconstrução de contornos a partir de um conjunto de pontos não organizados espacialmente.

Figura 4.3 – Extração de contornos pela aplicação do algoritmo α -shape.



Fonte: Adaptado de Wei (2008).

As coordenadas (x_c, y_c) do centro do círculo (P_3) podem ser obtidas pela Equação 4.1, utilizada por Zhang *et al.* (2006) e por Wei (2008).

$$\begin{aligned} x_c &= x_1 + 0,5 * (x_2 - x_1) + H * (y_2 - y_1) \\ y_c &= y_1 + 0,5 * (y_2 - y_1) + H * (x_2 - x_1) \end{aligned} \quad (4.1)$$

com

$$H = \frac{\alpha^2}{\sqrt{S_{P_1P_2}^2} - 0,25} \quad (4.2)$$

$$S_{P_1P_2}^2 = (x_2 - x_1)^2 + (y_2 - y_1)^2 \quad (4.3)$$

em que:

α – raio do círculo; e

x_1, y_1, x_2, y_2 – coordenadas dos pontos P_1 e P_2 , respectivamente.

O resultado da aplicação do algoritmo é dependente do conjunto de pontos S e do valor do parâmetro α . Quando o valor de α tende ao infinito ($\alpha \rightarrow \infty$), o formato do contorno extraído se aproxima do resultado da aplicação do método *convex hull*. Por outro lado, quando o valor α é muito pequeno ($\alpha \rightarrow 0$), todos os pontos de S podem ser considerados pontos de contorno. No caso ideal, quando o conjunto de pontos S é distribuído uniformemente e α aproximando-se do valor ideal, o algoritmo é capaz de extrair os contornos internos e externos de S simultaneamente (Wei, 2008).

A definição do parâmetro α é um fator determinante da qualidade dos contornos extraídos. Nesse sentido, diversos autores têm proposto métodos de estimativa de parâmetros α . Basicamente há trabalhos que estimam parâmetros α globais, com base na média de espaçamento entre os pontos da nuvem, e trabalhos que estimam parâmetros α locais, com base no espaçamento de cada segmento ou de cada vizinhança. Dentre os trabalhos que estimam valores de parâmetros α locais tem-se os trabalhos de Santos *et al.* (2018) e Santos *et al.* (2019). Além dos trabalhos mencionados há também estudos que propõem a combinação de diferentes estratégias de estimativa de parâmetros α (Santos *et al.*, 2020) visando resolver problemas que ocorrem em conjuntos de dados com diferentes densidades.


Nesse trabalho a extração dos contornos das edificações e árvores foi realizada por meio da aplicação do algoritmo α -shape, considerando duas abordagens para a estimativa do parâmetro α . A primeira delas considera a aplicação de α -shape com parâmetro α global. A segunda considera a aplicação de α -shape com parâmetro α local, estimado com base no espaçamento médio dos pontos por segmento, similar às abordagens propostas por Shen *et al.* (2011) e Santos *et al.* (2018). Ao fim da aplicação da extração de contornos espera-se obter os pontos de contorno de cada um dos segmentos criados.

O processo de extração de contornos a partir do algoritmo α -shape foi implementado em linguagem C++, a partir do ambiente de desenvolvimento integrado (IDE) do *Code::Blocks*. Os dados de entrada foram organizados e armazenados em uma estrutura *KD-tree* por meio da aplicação de ferramentas disponíveis na biblioteca FLANN – *Fast Library for Approximate Nearest Neighbors*. Essa biblioteca foi desenvolvida e disponibilizada por Muja e Lowe (2009). Segundo os autores, as ferramentas disponíveis na biblioteca FLANN possibilitam melhoria no tempo de processamento para tarefas de busca por vizinhos mais próximos.

4.3 Detecção das regiões de oclusão

A determinação da ocorrência de oclusão é realizada ponto a ponto considerando a relação topológica entre os pontos de contorno do telhado e a região de influência da árvore. A determinação da região de influência de uma dada árvore é realizada a partir da aplicação de um *buffer* considerando o contorno de árvore inicialmente extraído (Figura 4.4). Optou-se por definir a região de influência por meio de um *buffer* em razão de duas características da nuvem de pontos fotogramétrica. A primeira refere-se a região de transição entre árvores e edificações, a qual não é bem definida. Essa deficiência decorre das dificuldades de correspondência de imagens devido à existência de sombras. A segunda corresponde a não geração de pontos sob os dosséis (Figura 2.7). Ambas as características podem incorrer em menor densidade de pontos nas regiões de transição e até mesmo buracos na nuvem, podendo acarretar dificuldades na detecção das oclusões. A Figura 4.4 ilustra uma situação em que uma árvore oclui uma edificação, na Figura 4.4a é possível perceber que o espaçamento entre os pontos de árvore e os pontos de edificação é relativamente maior na região de transição. Na Figura 4.4c é possível perceber que a adoção de um *buffer* possibilitou gerar uma área de influência representativa da oclusão causada pela árvore.

Figura 4.4 - Detecção de pontos candidatos à oclusão: (a) cluster de pontos de árvore (verde) e de telhado (rosa); (b) contorno da árvore representado pelos pontos em verde, região de influência da árvore gerada considerando um buffer de 0,50 m (pontos em amarelo) e contorno do telhado (pontos em azul); e (c) pontos detectados em região de oclusão (pontos em vermelho).



Fonte: Elaborada pelo autor.

Após a determinação de região de influência da árvore, os pontos do contorno de telhado que estiverem contidos em tal região são considerados potenciais pontos de regiões de oclusão e, portanto, são considerados como candidatos à oclusão. Em seguida é aplicado um processo de refinamento que tem por objetivo minimizar a ocorrência de falsos positivos gerados por árvores que não apresentam altura suficiente para causar oclusão. Para tal, cada ponto detectado como candidato à oclusão tem o valor de Δh estimado para os 5 pontos de contorno de árvore mais próximos (Equação 4.4), conforme ilustrado na Figura 4.5. Por fim, o maior valor de Δh é comparado a um limiar L_h , os pontos que apresentarem Δh maior que L_h são considerados pontos oclusos (Figura 4.4).

$$\Delta h_i = h_i - h_j \quad (4.4)$$


sendo:

h_i – um dos 5 pontos de contorno de árvore mais próximos ao ponto h_j ;

h_j – ponto de contorno de telhado interno à região de influência da árvore; e

Δh_i – diferença de altura entre os pontos h_i e h_j .

Figura 4.5 - Estimativa do valor de Δh para um dado ponto interno à região de influência da árvore. À direita é mostrado em destaque a área realçada à esquerda.



Fonte: Elaborada pelo autor.

O processo de identificação dos pontos oclusos pode ser realizado considerando que uma árvore pode ocluir mais de uma edificação e que uma edificação pode estar ocluída por mais de uma árvore. Este processo pode ser caracterizado como sendo um relacionamento do tipo muitos para muitos em Análise de Sistemas e Banco de Dados. Com o objetivo de minimizar o problema relacionado ao volume de operações, inicialmente ambos os conjuntos de dados são estruturados na estrutura *KD-tree*. Em seguida, cada conjunto de pontos de contorno de árvores é testado contra cada um dos conjuntos de pontos de contorno de telhados.

Os procedimentos realizados para a detecção das regiões candidatas à oclusão estão descritos de forma simplificada na lista de passos a seguir e de forma mais detalhada no fluxograma apresentado na Figura 4.6.


1. Dados os conjuntos de pontos que definem os contornos das n_t árvores e das n_k edificações, selecionar os pontos de contorno da árvore t ;
2. Estruturar os pontos de contornos da árvore t considerando a estrutura *KD-tree*;
3. Definir a região de influência da árvore t com base em um limiar de *buffer*;
4. Dada uma edificação k selecionar o ponto j ;

-
5. Testar se o ponto j está contido na região de influência da árvore sob análise. Se o ponto estiver contido, testar se a diferença de altura do ponto j para os 5 pontos mais próximos do contorno da árvore t é maior que o limiar L_h . Caso o primeiro e o segundo testes retornem positivo, mover o ponto para o Vetor O . Caso contrário, descartar ponto j ;
 6. Verificar se há mais algum ponto na edificação k que ainda não tenha sido testado. Se houver algum ponto ainda não testado, substitui o ponto j por um novo ponto e repetir os passos 4, 5 e 6. Caso não haja mais pontos, ir para o passo 7;
 7. Verificar se Vetor O está vazio. Caso esteja vazio, a edificação k não é oclusa pela árvore t . Caso contrário, os pontos no Vetor O consistem nos pontos de contorno da edificação k oclusos pela árvore j ;
 8. Armazenar os pontos da edificação k oclusos pela árvore j ;
 9. Repetir os passos 4, 5, 6, 7 e 8 até que todas as edificações tenham sido testadas em comparação com a árvore t ; e
 10. Verificar se ainda existem árvores que não tenham sido testadas. Caso exista, repetir os passos de 1 a 9.

No método proposto, para cada conjunto de pontos de contorno de árvores e cada conjunto de pontos de contorno de edificações é gerado um resultado, caso oclusões sejam detectadas. O resultado consiste em um arquivo ASCII contendo as coordenadas de cada um dos vértices do contorno da edificação em análise, acrescidos de um rótulo binário, no qual 1 indica que o ponto está em região de oclusão e 0 para o ponto isento de oclusão. Essa geração ocorre na etapa 8 do algoritmo descrito, também representada pelo item destacado em verde na Figura 4.6.

Assim como o processo de extração de contornos, o processo de detecção de oclusão foi implementado em linguagem C++, no IDE do *Code::Blocks*. Os dados de entrada foram lidos e armazenados em uma estrutura *KD-tree* por meio da aplicação de ferramentas disponíveis na biblioteca FLANN – *Fast Library for Approximate Nearest Neighbors*. Após a estruturação dos dados, as regiões de influência das árvores foram geradas por meio de aplicação de ferramentas disponíveis na biblioteca *boost* (Koranne, 2011).

Figura 4.6 - Fluxograma do método proposto para detecção de oclusões



Fonte: Elaborada pelo autor.

4.3.1 Avaliação de qualidade da etapa de detecção de oclusão

Os resultados da detecção de oclusão serão avaliados qualitativamente, com base em inspeção visual sobre as oclusões detectadas, e quantitativamente, por meio de métricas extraídas da matriz de erros.

Para o caso de processos cujos resultados são binários, nos quais objetiva-se a diferenciação dos elementos em duas classes de interesse, considera-se que há quatro possibilidades para um dado elemento da matriz de erros: ele pode estar corretamente identificado como elemento de interesse, nesse caso será um Verdadeiro Positivo (*VP*); ele pode ser corretamente identificado como não sendo um elemento de interesse, nesse caso será um Verdadeiro Negativo (*VN*); ele pode ser erroneamente identificado como sendo elemento de interesse, nesse caso será um Falso Positivo (*FP*); ele poder ser erroneamente não identificado como sendo um elemento de interesse, nesse caso será um Falso Negativo (*FN*).

A partir dos valores de *VP*, *VN*, *FP* e *FN* é possível fazer a estimativa de indicadores de qualidade como nível de acerto (*NA*) e a completeza (*C*) (Equações 4.5 e 4.6, respectivamente), apresentados como *correctness* e *completeness* por (Wiedemann *et al.*, 1998). O nível de acerto representa a acurácia atingida dentre os elementos identificados como sendo elementos de interesse. A completeza relaciona o número de elementos corretamente identificados com o número de elementos presentes na referência.

$$NA = \frac{TP}{TP + FP} \quad NA \in [0, 1] \quad (4.5)$$

$$C = \frac{TP}{TP + FN} \quad C \in [0, 1] \quad (4.6)$$

Além dos indicadores apresentados nas Equações 4.5 e 4.6, é possível a estimativa de um valor único como para indicativo de qualidade geral, denominado F-score. O F-score é calculado como a média harmônica do nível de acerto e da completeza (Equação 4.7) (Sokolova, Japkowicz e Szpakowicz, 2006).

$$F - score = \frac{2 VP}{2 VP + FP + FN} \quad (4.7)$$

Capítulo 5

Uso combinado de nuvens de pontos para a extração dos contornos oclusos

Nesse capítulo são apresentadas as etapas do método proposto para mitigação dos contornos oclusos. O método é realizado com base na integração entre as nuvens fotogramétricas tomadas a partir de dois pontos de vista, aéreo e terrestre, sendo uma das premissas básicas do método a necessidade de que as duas nuvens estejam disponíveis em um mesmo sistema de referência. Nesse trabalho, a fim de garantir o registro das nuvens de pontos utilizadas, ressalta-se que a aquisição dos dados foi realizada apoiada em sistemas de posicionamento e inercial integrados. Além disso, durante o processamento fotogramétrico foram utilizados pontos de apoio determinados com precisão milimétrica. Assim, considera-se que ambos os conjuntos são georreferenciados em um mesmo sistema de referência, sendo as possíveis translações e rotações encontradas entre as nuvens de ordem residuais.


Em casos em que o compartilhamento de um mesmo sistema de referência não seja assumido é possível a aplicação de algoritmos que visam realizar o registro entre nuvens de pontos, como por exemplo o *Iterative Closest Point* (ICP) (Besl e McKay, 1992) ou o *Iterative Closest Line* (ICL) (Alshawwa, 2007), os quais têm por princípio estimar os parâmetros de uma transformação que seja capaz de alinhar um conjunto de dados a ser registrado a um conjunto de dados considerado como referência, de modo que o erro estimado ao fim do processo de ajustamento dos parâmetros da transformação seja minimizado.

Os processos aqui descritos são aplicados sobre os resultados dos processos descritos no Capítulo 4 e apenas sobre as edificações nas quais as oclusões tenham sido detectadas. Na primeira etapa é realizada a extração dos planos que compõe o telhado sob análise (Seção 5.1). Na segunda etapa ocorre a determinação da região de busca na nuvem fotogramétrica terrestre, referente a cada

oclusão detectada, bem como a seleção de pontos candidatos (Seção 5.2). Em seguida é aplicada a estratégia para a determinação dos contornos oclusos (Seção 5.3).

A sequência de processos adotados para a mitigação dos contornos oclusos é apresentada no fluxograma da Figura 5.1. Os dados de entrada correspondem aos pontos de edificação, a região de influência das árvores e a nuvem de pontos terrestre. A determinação dos planos que compõem o telhado é realizada a partir da aplicação do algoritmo *Random Sample Consensus* (RANSAC). A determinação da região de busca considera a região definida pela intersecção entre a região de influência da árvore que causou a oclusão e a região delimitadora dos pontos pertencentes à face oclusa. Após a extração dos planos, os pontos da nuvem terrestre pertencentes à região de busca são testados quanto a pertinência aos planos extraídos, os pontos que satisfaçam as equações dos planos de telhado extraídos são selecionados e adicionados ao conjunto de pontos de edificação. Por fim, o novo contorno é extraído considerando a aplicação do algoritmo *alpha-shape* sobre o conjunto de pontos originais do telhado incluindo os pontos adicionados por essa etapa do método.

Figura 5.1 - Fluxograma da etapa de mitigação dos contornos oclusos



Fonte: Elaborada pelo autor.

5.1 Extração de planos por meio do algoritmo RANSAC

A estratégia de mitigação dos contornos oclusos tem por base a extração de planos por meio da aplicação do algoritmo RANSAC. Proposto por Fischler e Bolles (1981), o RANSAC é uma técnica utilizada para a detecção de feições matematicamente parametrizáveis, como por exemplo planos, cones, cilindros, dentre outros. De acordo com Raguram *et al.* (2008) e Derpanis (2010) o algoritmo RANSAC é uma técnica comumente aplicada para estimar parâmetros de um modelo matemático.

Basicamente, o RANSAC é uma técnica de reamostragem que gera soluções candidatas usando o número mínimo de dados necessários para estimar os parâmetros de um dado modelo (reta, plano, cilindro, etc.). Diferente das técnicas convencionais, que buscam soluções a partir da maior quantidade de dados possível, o RANSAC utiliza o menor conjunto de dados possível e busca acrescentar iterativamente ao modelo dados consistentes (*inliers*) (Derpanis, 2010), operando em uma estrutura de hipótese e verificação (Raguram *et al.*, 2008; Zheng *et al.*, 2012).

Em sua formulação clássica, o problema tratado pelo RANSAC é encontrar todos os *inliers* de um modelo definido a partir de um conjunto mínimo de dados. O número de *inliers* normalmente não é conhecido a priori. Derpanis (2010) faz uma descrição breve dos passos gerais adotados pelo algoritmo:

1. Selecionar aleatoriamente a menor quantidade de dados necessários para estimar os parâmetros do modelo matemático;
2. Solucionar os parâmetros do modelo matemático para o conjunto mínimo de dados aleatoriamente selecionado no passo anterior;
3. Determinar o número de *inliers* do conjunto inicial;
4. Comparar o número de *inliers* obtidos na iteração com o maior número de *inliers* obtido nas iterações anteriores (chamado conjunto consenso). Caso o número de *inliers* seja maior que o conjunto consenso, admite-se que a solução atual é a ideal. Se a iteração atual for a última o passo 5 é executado, caso contrário retorna-se ao passo 1.
5. Estima-se pelo Método dos Mínimos Quadrados (MMQ) os parâmetros do modelo utilizado usando todos os dados considerados *inliers*.

Segundo Derpanis (2010) o número de iterações (N) deve ser grande o suficiente para garantir, com uma probabilidade p (normalmente considerada de 0,99), que ao menos um dos subconjuntos amostrados randomicamente não possua dados incorretos.

Nesse trabalho a técnica RANSAC será aplicada sobre os pontos da edificação oclusa, visando determinar os parâmetros do plano da face do telhado onde ocorreu a oclusão detectada (Seção 5.2.1). A aplicação do RANSAC gera dois resultados que serão utilizados em etapas subsequentes do método, o primeiro consiste na segmentação dos planos que compõe o telhado, o segundo consiste nos parâmetros matemáticos que definem os planos extraídos. O primeiro

resultado será utilizado na Seção 5.2 desta Tese, a fim de possibilitar a determinação da região de busca. O segundo resultado será utilizado na Seção 5.3, a fim de selecionar pontos internos à região de busca que satisfaçam a equação do plano extraído.

A extração de planos é realizada por meio da aplicação da técnica RANSAC, implementada e disponível no software *Cloud Compare*. Nesta ferramenta é selecionada a primitiva de interesse “*plane*” e configurados os parâmetros “*min Support points per primitive* (100)”, “*max distance to primitive* (e = 0,10 m)”, “*sampling resolution* (b = 0,15)”, “*max normal deviation* (a = 25°)” e “*overlooking probability* (0,01)”. Vale destacar que os parâmetros são aplicados com os mesmos valores para todas as edificações de interesse.

O parâmetro *min support points per primitive* estabelece a quantidade mínima de pontos que definem a primitiva, no caso desta Tese optou-se por adotar o mínimo de 100 pontos, equivalente a uma área de 3 m². O parâmetro *max distance to primitive* limita a distância máxima entre ponto e plano. O parâmetro *sampling resolution* corresponde ao espaçamento médio dos pontos. O parâmetro *max normal deviation* considera o desvio em graus contado entre a normal local de um ponto candidato em relação a normal da primitiva a ser extraída. Por fim, o parâmetro *overlooking probability* corresponde à probabilidade de que algum ponto candidato tenha sido desconsiderado.


5.2 Definição da região de influência e seleção dos pontos na nuvem terrestre

A determinação da região de busca para os pontos candidatos a oclusão tem por objetivo a pré-seleção de pontos de interesse. Vale considerar que a própria região de influência da árvore causadora da oclusão poderia ser utilizada. No entanto, a fim de evitar regiões de busca muito grandes, optou-se pela definição de uma região de busca melhor delimitada, a partir da intersecção entre a região de influência da árvore causadora da oclusão e a região delimitadora dos pontos de cada edificação (*bounding box* – BB). A região de influência da árvore causadora da oclusão é determinada conforme apresentado no Capítulo 4 desta Tese.

O conceito de BB pode ser definido pela menor região envolvente do conjunto de pontos ou objetos. De acordo com Barequet e Har-Peled (2001) diversas estratégias podem ser utilizadas para a definição de tal região, dentre elas a mais simples é conhecida como AABB (*axis-aligned bounding box*). A AABB consiste na determinação do menor retângulo orientado paralelamente

aos eixos cartesianos. Por considerar apenas BB alinhadas aos eixos cartesianos a AABB usualmente gera retângulos com áreas que extrapolam o limite ideal do conjunto de pontos. Visando a determinação de BB com áreas mais ajustadas ao conjunto de pontos, independentemente da orientação dos eixos cartesianos, surgiram as estratégias OBB (*oriented bounding box*), MOBB (*minimum oriented bounding box*), AOBB (*arbitrary oriented bounding box*), MVBB (*minimum volume bounding box*) etc. As estratégias OBB, MOBB, MVBB e AOBB, buscam definir o BB que melhor envolva o conjunto de pontos, considerando a variação da orientação da BB visando a minimização da área ou do volume, a depender se considera o espaço 2D ou 3D. A Figura 5.2 apresenta o resultado da extração do BB para um conjunto de pontos no espaço 3D, considerando a estratégia AABB e a estratégia MOBB.

Figura 5.2 - Região delimitadora definida pelo conceito de *bounding box*: (a) AABB vista ortogonal; (b) AABB vista em perspectiva; (c) MOBB vista ortogonal; e (d) MOBB vista em perspectiva.




Fonte: Elaborada pelo autor.

Nesse trabalho a determinação da BB foi realizada utilizando ferramentas implementadas na biblioteca COMPAS, em linguagem *Python*. As ferramentas utilizadas consideram a aplicação

de um algoritmo similar ao algoritmo proposto por (Chan e Tan, 2001). A Figura 5.3 apresenta resultados parciais do algoritmo utilizado na determinação da MOBB, o qual reproduz basicamente os seguintes passos:

- 1 – Determinar a AABB para o conjunto de pontos;
- 2 – Determinar o eixo R_z passante pelo centro da AABB determinada no passo 1 (Figura 5.3a);
- 3 – Aplicar rotações sucessivas em torno de R_z buscando a menor área para a BB projetada no plano XY (Figura 5.3b). As rotações sucessivas são aplicadas considerando um valor fixo de variação angular, por exemplo 1° ;
- 4 – Determinar o eixo R_y passante pelo centro da BB rotacionada e aplicar sucessivas rotações em torno de R_y buscando a menor área para a BB projetada no plano XZ (Figura 5.3c);
- 5 – Determinar o eixo R_x passante pelo centro da BB rotacionada e aplicar sucessivas rotações em torno de R_x buscando a menor área para a BB projetada no plano YZ (Figura 5.3d); e
- 6 – Aplicar as rotações inversas a fim de determinar as coordenadas dos vértices da OBB determinada.

Figura 5.3 - Ilustração dos procedimentos para determinação da MOBB, onde são mostradas as projeções do objeto em cada um dos planos (XY, YZ e XZ).



Fonte: Adaptado de Chan e Tan (2001).

Na sequência, os pontos candidatos são selecionados com base na relação topológica entre os pontos da nuvem terrestre e as regiões de busca, definidas pela MOBB e pela região de influência da árvore causadora da oclusão. Basicamente, os pontos da nuvem terrestre que estiverem contidos na região 3D definida pela MOBB e na região 2D definida pela região de influência da árvore serão considerados nas próximas etapas do método.

5.3 Extração do contorno final e avaliação de qualidade

Nessa etapa os procedimentos descritos serão aplicados a cada face do telhado individualmente, considerando apenas as faces em que a oclusão foi detectada. Para a detecção das faces oclusas considerou-se o resultado da etapa 4.3 em que os pontos de contorno sob área de oclusão são detectados. Cada ponto detectado como sendo ocluído é testado contra os parâmetros de todos os planos extraídos, sendo este ponto associado ao plano que estiver a uma menor

distância. O plano que tiver associado a algum ponto detectado como ocluso é assumido como plano candidato à oclusão, sendo trabalhado nas etapas subsequentes do método.

Para cada face de telhado de uma determinada edificação, os pontos selecionados pelos procedimentos descritos na Seção 5.2 serão testados quanto à pertinência ou não, ao plano da face. Para tal, as coordenadas dos pontos serão aplicadas na equação do plano e aqueles que apresentarem distância de até 10 cm serão selecionados. No caso deste trabalho adotou-se o limiar de 10 cm, visto que se trata de nuvens de pontos fotogramétricas ruidosas, conforme já discutido na Seção 2. Esse procedimento será repetido para todas as faces oclusas de cada edificação. Ao fim do processo espera-se obter um conjunto de pontos formados por todos os pontos que satisfazem as equações dos planos oclusos, de acordo com o limiar mencionado.

Os pontos selecionados serão adicionados ao conjunto de pontos da edificação. Em seguida, o contorno final da edificação sob análise será extraído de forma similar ao apresentado na Seção 4.2 desta Tese, considerando a aplicação do algoritmo α -shape com parâmetro α global. Nesta etapa é considerado o parâmetro α global de 0,50 m, com base nos resultados obtidos na Seção 4.2 e discutidos na Seção 6.3.2 desta Tese. Ao fim da aplicação da extração de contornos espera-se obter os contornos das edificações tratadas, incluindo aqueles sob áreas de oclusão.

Por fim, o processo de extração de contornos o método será avaliado considerando métricas derivadas da matriz de erros, de modo similar ao apresentado na Seção 4.3.1. Destaca-se que, assim como o processo de detecção de oclusão, a avaliação de qualidade do método de mitigação dos contornos oclusos pode ser considerado um problema binário.

5.3.1 Avaliação de qualidade dos contornos finais

As métricas utilizadas no contexto de avaliação de qualidade dos processos de extração e regularização de contornos podem ser classificadas em dois grupos, baseadas nas áreas e baseadas em medidas lineares entre os contornos. O primeiro grupo considera métricas como completeza, nível de acerto e F-score, os quais já foram apresentados na Seção 4.3.1. O segundo considera métricas como distância de *Hausdorff* e de *Chamfer*. Ainda com foco na análise baseada em medidas lineares, Avbelj, Müller e Bamler (2015) propuseram a métrica *Polygons and Line Segments* (PoLiS), a qual foi idealizada para a realização de análises quantitativas de similaridades de polígonos.

A métrica PoLiS pode ser utilizada para estimativas de medidas lineares no espaço bidimensional ou tridimensional. A partir dos pontos pertencentes a dois polígonos, denotados A e B, a métrica PoLiS pode ser estimada a partir da seguinte equação:

$$p(A, B) = \frac{1}{2q} \sum_{a_j \in A} \min_{b \in \partial B} \|a_j - b\| + \frac{1}{2r} \sum_{b_k \in B} \min_{a \in \partial A} \|b_k - a\| \quad (5.1)$$

sendo q e r o número de vértices dos polígonos A e B, respectivamente; ∂A e ∂B correspondem aos polígonos A e B; e $\|a - b\|$ corresponde a distância Euclidiana entre dois pontos a e b.

Capítulo 6


Dados utilizados, Resultados e Discussões

Nesse capítulo é realizada uma breve descrição dos equipamentos e procedimentos adotados para a aquisição dos dados. Além disso, são apresentados os resultados relacionados as três fases principais: classificação, detecção de oclusões e mitigação dos contornos de edificações oclusas. Vale destacar que nas três etapas existem contribuições, sendo estas destacadas ao longo das Subseções 6.2-6.4.

6.1 Descrição dos dados e da área de estudo

Os experimentos foram realizados em dados de uma área teste localizada no município de Regente Feijó, região oeste do Estado de São Paulo/Brasil. As coordenadas referidas ao Sistema de Referência Geocêntrico para as Américas (SIRGAS) 2000 e projeção Universal Transversa de Mercator (UTM) do centro da área de estudo são: E = 463336 m, N = 7545302 m, 22S. A área de estudo apresenta alta complexidade e é composta por edificações de diferentes tamanhos e formatos, constituídas por diferentes materiais, observando a presença de árvores isoladas e aglomerados, linhas de transmissão, bem como diferentes tipos de alvos a nível de solo, como asfalto, solo exposto, vegetação rasteira etc. A Figura 6.1 apresenta a nuvem de pontos RGNIR em composição colorida falsa cor *Red* (R), *Green* (G) e *Blue* (NIR).

Figura 6.1 - Nuvem de pontos fotogramétrica em composição falsa cor *Red* (R), *Green* (G) e *Blue* (NIR).



Fonte: Elaborada pelo autor.

Para a realização deste trabalho foram necessários dois conjuntos de dados, um aéreo e um terrestre. Os dados aéreos foram gerados a partir de imagens adquiridas por meio aerolevantamento utilizando veículo aéreo não tripulado (RPAS). Os dados terrestres foram gerados a partir de imagens adquiridas por um sistema de mapeamento móvel. Ambos os conjuntos de imagens foram processados no software fotogramétrico Pix4D MapperPro para obtenção de nuvem de pontos.

A aquisição das imagens aéreas foi realizada utilizando um RPAS, modelo Ebee da fabricante Sensefly (Figura 6.2a), tendo embarcado uma câmara Canon 110S NIR (Figura 6.2b). Ambos os equipamentos foram comprados com recursos do Processo FAPESP nº 2014/01841-1.


A câmara utilizada para a tomada de imagens aéreas possibilita obter imagens em 3 comprimentos de onda: Verde (G), Vermelho (R) e *Near Infra-red* (NIR). Na Figura 6.3 são mostradas as curvas de sensibilidade das bandas da câmara. Adicionalmente, os parâmetros do voo estão apresentados na Tabela 6.1.

Figura 6.2 - Equipamentos utilizados no aerolevantamento. (a) RPAS eBee da fabricante sensefly. (b) câmara Canon 110S NIR.



Fonte: Elaborada pelo autor.

Figura 6.3 - Curvas de sensibilidade das bandas G, R e NIR (comprimento de onda x sensibilidade relativa).



Fonte: SenseFly (2014).

Tabela 6.1 - Parâmetros adotados para aquisição de imagens aéreas.

Data	Altura de voo	GSD médio	Sobreposição (%)		Configuração de faixas de voo
			Lateral	Longitudinal	
08/11/2018	120 m	4 cm	70	80	cruzadas

Tanto a configuração de sobreposição quanto a opção pela realização de voo com faixas cruzadas foram selecionadas com o intuito de garantir o recobrimento e a qualidade da nuvem de pontos gerada, uma vez que a qualidade da nuvem é dependente da precisão em que as intersecções fotogramétricas são estimadas. Dessa forma, quanto maior o número de imagens em que um determinado ponto aparece, maior é o número de intersecções fotogramétricas possíveis e, consequentemente, maior será a possibilidade de identificação de falsa correspondência fotogramétrica.


No mesmo dia da tomada de imagens, realizou-se a determinação das coordenadas de 17 pontos no terreno por meio de rastreamento GNSS. Desse total, 10 pontos foram utilizados como pontos de controle, enquanto os outros 7 foram adotados como pontos de verificação no processamento fotogramétrico do bloco de imagens.

Durante o processamento, os valores de posição e atitude da aeronave fornecidos pelos sensores embarcados foram considerados como valores iniciais no processamento. Além disso, adotou-se injunção relativa para os pontos de apoio, considerando um valor de desvio-padrão de 0,02 m. Ao fim do processamento, a partir dos pontos de verificação foram estimados valores de *Root Mean Square Error* (RMSE) de 0,04 m na componente planimétrica e 0,06 m na componente vertical.

Para a geração da nuvem de pontos aérea foi utilizada uma restrição referente ao mínimo de imagens nas quais um ponto deve ser identificado. Para que um ponto seja estabelecido ele deve aparecer e ser identificado em, no mínimo, 6 imagens. Tal restrição foi adotada a fim de diminuir a ocorrência de pontos resultantes de falsas correspondências. Por fim, o processamento resultou em uma nuvem de pontos com densidade média de 32 pontos/m² (Figura 6.5a). Cada ponto da nuvem possui 3 coordenadas (X, Y, Z) e um conjunto de 3 informações radiométricas, correspondentes às respostas espectrais dos alvos nos comprimentos de onda do Verde (G), Vermelho (R) e infravermelho próximo (NIR).

Os dados terrestres foram coletados e fornecidos pela empresa Sensormap Geotecnologia, empresa do grupo Engemap Geoinformação, cujo processamento fotogramétrico foi realizado no software Pix4D MapperPro. No levantamento dos dados terrestres foi utilizado o sistema de mapeamento móvel SMM. Esse sistema possui cinco câmaras, receptores GNSS de dupla frequência, sistema inercial e unidade de controle. Os equipamentos utilizados na aquisição dos dados terrestres estão ilustrados na Figura 6.4.

Figura 6.4 - Equipamentos utilizados na aquisição dos dados terrestres: (a) conjunto de câmaras do SMM instalado no teto de um automóvel; e (b) unidade de controle do SMM.




Fonte: Sensormap (2015).

Destaca-se que o SMM possui sistemas de posicionamento e inercial integrados, os quais possibilitam a determinação da posição e orientação de cada uma das câmaras no momento da aquisição das imagens. Dessa forma, no processamento fotogramétrico dos dados os valores de posição e atitude da plataforma, fornecidos pelos sensores embarcados, foram utilizadas como injeção relativa com desvio padrão de 0,05 m para as coordenadas X, Y e Z e 5' para os ângulos de atitude ($\hat{\Omega}$, $\hat{\Phi}$, $\hat{\kappa}$).

O processamento fotogramétrico das imagens adquiridas resultou em uma nuvem de pontos terrestre com densidade média de 1000 pontos/m² (Figura 6.5b). Assim como no caso da nuvem

aérea, os pontos da nuvem terrestre têm associados a eles 3 coordenadas (X, Y, Z) e um conjunto de 3 informações radiométricas, correspondentes às respostas espectrais dos alvos nos comprimentos de onda do Azul (B), Verde (G) e Vermelho (R).

Figura 6.5 – Nuvens fotogramétricas da edificação 304: (a) nuvem aérea (R, G, NIR); e (b) nuvem terrestre (R, G, B).



Fonte: Elaborada pelo autor.

6.2 Resultados da classificação da nuvem de pontos fotogramétrica aérea (Cap. 3)

Nessa subseção são apresentados os resultados obtidos na fase de classificação da nuvem de pontos fotogramétrica, descrita no Capítulo 3. Parte dos resultados aqui descritos foram publicados em dois artigos científicos (Pessoa *et al.*, 2019a e 2019b).


6.2.1 Atributos extraídos

A complementariedade de atributos radiométricos e geométricos tem sido explorada na etapa de classificação, em especial para ambientes complexos, como por exemplo ambientes densamente urbanizados (Hartfield, Landau e Leeuwen, 2011; Man, Dong e Guo, 2015; Zhang e Lin, 2017). Em comum, os trabalhos citados têm a necessidade de integração de dados multifonte para a exploração da complementariedade de informação radiométrica e geométrica. Embora a complementariedade de atributos radiométricos e geométricos tenha sido explorada, como nos exemplos citados, tais atributos apresentam qualidade e quantidade diferentes daqueles obtidos por meio de nuvens fotogramétricas produzidas a partir de RPAS e câmaras de baixo custo. Nesse sentido, a primeira contribuição deste trabalho consiste na exploração da complementariedade de tal informação extraída a partir de nuvem de pontos fotogramétrica, gerada por meio de processamento fotogramétrico de imagens adquiridas por RPAS.

Vale destacar que embora o desenvolvimento dos RPAS tenha trazido grandes avanços para a aquisição de dados, as limitações da capacidade de carga de algumas dessas plataformas implicam em limitações nos tipos de sensores utilizados. No caso de nuvens de pontos obtidas por processamento fotogramétrico de imagens de RPAS, a capacidade de carga da plataforma afeta diretamente a disponibilidade de informação radiométrica. Além disso, outro problema está relacionado à precisão posicional da nuvem de pontos, a qual impacta diretamente a qualidade dos atributos geométricos extraídos. Nestes casos, a exploração da complementaridade de informações radiométricas e geométricas é ainda mais relevante.

Para melhor apresentar os resultados da extração de atributos foi selecionada uma área central da área de estudo, conforme pode ser verificado na Figura 6.6. Os resultados apresentados contemplam diferentes tipos de edificações, compostas por diferentes materiais e com diferentes formatos, além de árvores próximas às edificações selecionadas.

Figura 6.6 - Região selecionada para apresentar os resultados da extração de atributos.




Fonte: Elaborada pelo autor.

6.2.1.1 Atributos radiométricos

Conforme apresentado na Seção 3.1.1 desta Tese, foram extraídos os atributos radiométricos G, R, NIR, NDVI e *minimum* (R, G, NIR). Os atributos G, R e NIR correspondem aos valores de Nível Digital (ND) obtidos para cada um dos pontos da nuvem a partir do processamento fotogramétrico das imagens adquiridas. Tais valores foram quantizados em 8 bits, com valores de ND variando de 0 a 255. Os valores de NDVI são por concepção valores normalizados no intervalo de -1 a 1. Por fim, os valores de *Minimum* (R, G, NIR) foram obtidos e normalizados na escala de 0 a 1. Na Figura 6.7 são apresentados os resultados da extração de atributos radiométricos para a região selecionada.

Figura 6.7 - Atributos radiométricos extraídos.



Fonte: Elaborada pelo autor.

Com base na Figura 6.7 é possível verificar visualmente que os atributos radiométricos R, G, NIR e *Minimum* (R, G, NIR) apresentam informações similares, não sendo possível distinguir entre os diferentes tipos de alvos, como por exemplo: vegetação rasteira e árvores; e calçada e solo exposto. Quanto ao atributo NDVI é possível perceber a vegetação em evidência (na cor amarela) se comparada aos demais alvos da cena. Para uma análise mais conclusiva a respeito do potencial do uso dos atributos radiométricos para a identificação dos alvos foram gerados gráficos com os valores de média e desvio padrão dos alvos em relação a cada um dos atributos extraídos, conforme apresentado na Figura 6.8.

Figura 6.8 - Gráficos de média e desvio-padrão dos atributos radiométricos para as classes previstas, considerando as bandas R, G, NIR, bem como o NDVI e o *Minimum* (R,G,NIR).



Fonte: Elaborada pelo autor.

Com base nos gráficos da Figura 6.8 o mesmo efeito visualizado na análise da Figura 6.7 foi verificado. A semelhança entre os gráficos construídos para os atributos radiométricos originais indica alta correlação entre os atributos, sendo que tais atributos não apresentam informações complementares entre si, de modo a contribuir efetivamente na classificação. Além disso, é possível verificar que alguns atributos apresentam alto grau de dispersão em classes específicas, como por exemplo o atributo *Minimum* (R, G, NIR) nas classes Grama, Calçada, Asfalto e Árvore. Ainda com base nos gráficos é possível perceber que, com exceção do atributo NDVI, os alvos apresentam alto grau de similaridade entre si. Assim, fica evidente a dificuldade em obter a

discriminação desejada entre os alvos previstos, quando se considera apenas os atributos radiométricos originais.


No entanto, os gráficos indicam que os atributos radiométricos seriam capazes de contribuir para uma classificação mais genérica, como por exemplo a separação de asfalto e linha de transmissão, dos demais alvos, com base no atributo NIR; a identificação dos pontos de vegetação rasteira e árvores com base no atributo NDVI; e a identificação dos pontos de solo exposto com base no atributo *Minimum* (R, G, NIR).

6.2.1.2 Atributos geométricos

A partir da vizinhança ótima de cada ponto (conforme descrito na Seção 3.1.2), os atributos Anisotropia, Omnivariância, Dispersão, Planaridade, Linearidade e Entropia dos autovalores foram determinados. Exceção a isso foi o atributo Altura, o qual foi extraído a partir da utilização dos aplicativos *Lasground* e *Lasheight*, ambos disponíveis no pacote de ferramentas *LAStools* (Isenburg, 2014). O resultado da extração de atributos geométricos pode ser visualizado na Figura 6.9.

Com base na análise visual da Figura 6.9 é possível verificar que o atributo altura apresenta a maior contribuição para a separabilidade dos alvos presentes na cena. Esse atributo possibilita separar os alvos em dois conjuntos, pontos elevados e pontos a nível de solo. Outro atributo que visualmente contribui para classificação consiste no atributo omnivariância, nele é possível identificar os alvos a nível de solo. No entanto, os demais atributos geométricos apresentam alta variabilidade local, não sendo possível a identificação visual dos alvos presentes na cena. Ademais, a análise visual indica que tais atributos têm potencial para classificações mais específicas, como por exemplo identificação de feições lineares, planares etc.

Figura 6.9 – Representação dos atributos geométricos extraídos da área de estudo.




Fonte: Elaborada pelo autor.

Para uma análise mais conclusiva a respeito do potencial dos atributos geométricos estimados para a identificação dos alvos, foram gerados gráficos com os valores de média e desvio padrão dos alvos em relação a cada um dos atributos extraídos, conforme apresentado na Figura 6.10. Com base nos gráficos dos atributos geométricos é possível ter a percepção da real contribuição do atributo altura. Nota-se que para tal atributo os alvos apresentam média bem definida e pequeno desvio-padrão. No entanto, os demais

gráficos apresentam altos valores de desvio-padrão para os diferentes alvos considerados, indicando assim que, com exceção do atributo altura, os atributos geométricos têm baixo potencial de contribuição no processo de classificação.

Figura 6.10 - Gráficos de média e desvio-padrão dos atributos geométricos nas classes previstas.



Fonte: Elaborada pelo autor.

6.2.2 Classificação

Quatro experimentos foram realizados considerando os atributos extraídos. Os experimentos foram planejados e realizados a fim de verificar a contribuição do uso combinado dos diferentes tipos de atributos para obter a classificação final dos dados. O primeiro experimento foi realizado com base apenas nos atributos radiométricos e o segundo com base nos atributos geométricos. Por fim, o terceiro e o quarto experimentos consideraram a combinação de atributos radiométricos e geométricos. O terceiro experimento contou com a utilização de todos os atributos extraídos, enquanto o quarto experimento considerou todos os atributos radiométricos em conjunto com o atributo geométrico altura.

Para o treinamento do classificador foram manualmente selecionados dados amostrais a partir de análise visual, sendo tal procedimento realizado por meio do software *CloudCompare*. A Tabela 6.2 apresenta o total de pontos por classe presentes na amostra. A partir dos dados amostrais, 60% foram randomicamente selecionados para o treinamento (crescimento da floresta) e 40% foram utilizados para validação e análise da qualidade da classificação. Vale ressaltar que não há sobreposição entre os dados de treinamento e os de validação.


Tabela 6.2 - Número de pontos utilizados para treinamento e validação dos experimentos de classificação.

Classes	Número de pontos		
	Treinamento	Validação	Total
Asfalto	5030	3354	8384
Solo exposto	5075	3383	8458
Edificações	6162	4108	10270
Gramma	4770	3180	7950
Calçada	3367	2244	5611
Árvores	8446	5630	14076
Linhas de transmissão	10594	7063	17657
Total	43444	28962	72406

Para cada experimento foi realizado um treinamento. Após os treinamentos foram gerados os respectivos resultados da classificação, bem como os *rankings* de importância dos atributos (Figura 6.11), os quais tem por objetivo possibilitar a identificação dos atributos que contribuem para a maior separabilidade entre as classes.

Com base nas importâncias dos atributos (Figura 6.11), é possível verificar que os atributos geométricos em sua maioria não contribuíram para a separabilidade entre as classes previstas, com exceção ao atributo altura, o qual apresenta-se como o de maior importância, superando inclusive os atributos radiométricos.

Figura 6.11 - *Ranking* de importância dos atributos (gerados a partir da aplicação do classificador RF): (a) *Ranking* dos atributos geométricos; (b) *ranking* dos atributos radiométricos; (c) *ranking* dos atributos geométricos e radiométricos; e (d) *ranking* dos atributos radiométricos e do atributo altura.



Fonte: Elaborada pelo autor.


Visando facilitar a visualização dos resultados da classificação foram selecionadas 3 regiões, conforme apresentado na Figura 6.12. Para a apresentação visual dos resultados da classificação (Figura 6.13) foram considerados os experimentos que utilizam somente os atributos geométricos (Figura 6.11a), apenas os atributos radiométricos (Figura 6.11b) e todos os atributos radiométricos e geométricos combinados (Figura 6.11c).

Figura 6.12 - Regiões selecionadas para apresentação dos resultados da classificação.



Fonte: Elaborada pelo autor.

Figura 6.13 - Resultados da classificação para três áreas distintas, considerando os três experimentos realizados.



Fonte: Elaborada pelo autor.

A partir de uma análise visual dos resultados da classificação apresentados na Figura 6.13 pode-se observar que a classificação considerando apenas atributos geométricos (Figura 6.13a, d, g) apresenta o pior resultado. Esta classificação foi capaz de diferenciar os objetos em duas classes mais gerais, solo (solo exposto, grama, calçadas e asfalto) e objetos elevados (árvores, edificações e linhas de transmissão), mas com alto grau de confusão entre eles. A confusão entre esses elementos está diretamente relacionada à alta variabilidade local dos atributos geométricos, conforme pode ser verificado nas Figuras 6.9 e 6.10. A classificação considerando apenas atributos radiométricos (Figura 6.13b, e, h) apresenta melhores resultados do que a classificação com atributos geométricos, mas ainda alguma confusão persiste, especialmente em classes com respostas espectrais semelhantes, tais como: árvores, grama e edificações; e asfalto e linhas de transmissão. Por fim, os resultados apresentados pela classificação considerando ambos os conjuntos de atributos, radiométricos e geométricos (Figuras 6.13c, 6.13f e 6.13i), apresentou os melhores resultados. Nela o classificador foi capaz de diferenciar entre todas as classes previstas.

As observações feitas a partir de análises visuais dos resultados das classificações são corroboradas pelos resultados extraídos das matrizes de erros (Tabelas 6.3, 6.4, 6.5 e 6.6). Nestas tabelas as posições que possuem mais de 100 pixels classificados errados são realçadas. Com base nelas foram calculadas as métricas de qualidade: nível de acerto, completeza, acurácia global e índice *kappa*, conforme apresentado na Tabela 6.7.

Tabela 6.3 – Matriz de erros para o experimento de classificação considerando apenas os atributos geométricos.

		Previsto						
		Asfalto	Solo exposto	Edificação	Grama	Calçada	Árvore	Linhas de trans.
Classe real	Asfalto	1133	817	8	744	550	1	13
	Solo exposto	443	2426	0	45	563	1	0
	Edificação	4	0	3691	51	1	40	350
	Grama	496	340	61	2044	200	2	0
	Calçada	586	852	11	226	586	2	0
	Árvore	12	0	60	23	12	4944	516
	Linhas de trans.	3	0	213	0	0	437	6450

Tabela 6.4 – Matriz de erros para o experimento de classificação considerando apenas os atributos radiométricos.

		Previsto						
		Asfalto	Solo exposto	Edificação	Grama	Calçada	Árvore	Linhas de trans.
Classe real	Asfalto	2285	1	104	0	1	0	875
	Solo exposto	0	3119	47	128	184	0	0
	Edificação	199	113	3340	43	237	10	195
	Grama	0	59	8	2599	0	477	0
	Calçada	1	187	104	0	1938	0	33
	Árvore	3	0	12	408	2	5132	10
	Linhas de trans.	1977	2	229	2	43	7	4843

Tabela 6.5 – Matriz de erros para o experimento de classificação considerando os atributos geométricos e radiométricos.

		Previsto						
		Asfalto	Solo exposto	Edificação	Grama	Calçada	Árvore	Linhas de trans.
Classe real	Asfalto	3249	1	3	0	0	0	13
	Solo exposto	1	3280	0	72	125	0	0
	Edificação	4	1	4110	0	5	0	17
	Grama	1	54	0	3088	0	0	0
	Calçada	3	172	6	1	2081	0	0
	Árvore	6	1	4	2	1	5552	1
	Linhas de trans.	1	0	5	0	0	5	7092

Tabela 6.6 – Matriz de erros para o experimento de classificação considerando apenas os atributos radiométricos e a altura.

		Previsto						
		Asfalto	Solo exposto	Edificação	Grama	Calçada	Árvore	Linhas de trans.
Classe real	Asfalto	3243	1	2	0	0	0	20
	Solo exposto	0	3190	0	109	179	0	0
	Edificação	5	0	4110	0	9	0	13
	Grama	0	64	0	3079	0	0	0
	Calçada	3	187	7	0	2066	0	0
	Árvore	6	0	6	3	3	5547	2
	Linhas de trans.	0	0	9	0	0	4	7090

As matrizes de erros permitem verificar quais classes apresentam maior confusão ao fim da classificação. A matriz de erros da classificação com atributos geométricos (Tabela 6.3) apresentou confusão entre todas as classes, sendo as classes mais confusas a classe de Linhas de transmissão e Asfalto. A matriz de erros da classificação apenas com atributos radiométricos (Tabela 6.4) mostra que tal classificação não permitiu a distinção entre as seguintes classes: Asfalto e Linhas de transmissão; e Grama e Árvores. A classificação que considerou os atributos radiométricos e geométricos (Tabela 6.5 e Tabela 6.6) atingiu resultados satisfatórios, reduzindo a confusão entre as classes, apresentando apenas duas classes com grau de confusão mais elevado (Calçada e Solo exposto). Por fim, a classificação que considerou os atributos radiométricos em conjunto com o atributo geométrico altura (Tabela 6.6) mostrou-se compatível com os resultados obtidos para a classificação com todos os atributos.

Tabela 6.7 – Parâmetros de qualidade extraídos das matrizes de erros resultantes dos experimentos de classificação.

Classes	Atributos geométricos		Atributos radiométricos		Atributos radiométricos e geométricos		Atributos radiométricos e altura	
	Completeza	Nível de acerto	Completeza	Nível de acerto	Completeza	Nível de acerto	Completeza	Nível de acerto
Asfalto	0,35	0,42	0,70	0,51	0,99	1,00	0,99	0,99
Solo exposto	0,70	0,55	0,90	0,90	0,94	0,93	0,92	0,90
Edificações	0,89	0,91	0,81	0,87	0,99	1,00	0,99	0,99
Grama	0,65	0,65	0,83	0,82	0,98	0,98	0,97	0,98
Calçada	0,26	0,31	0,86	0,81	0,92	0,94	0,91	0,91
Árvores	0,89	0,91	0,92	0,91	1,00	1,00	1,00	1,00
Linhas de transmissão	0,91	0,88	0,68	0,81	1,00	1,00	1,00	1,00
Acurácia global		0,74	0,80		0,98		0,98	
Índice Kappa		0,68	0,77		0,98		0,97	

Com base nos parâmetros de qualidade da classificação, apresentados na Tabela 6.7, é possível verificar que a classificação que considerou apenas atributos geométricos produziu os piores resultado, com uma acurácia global de 0,74. Os valores de nível de acerto e completeza para as classes de asfalto e calçada foram inferiores a 0,40, o que indica falha grave para classificar objetos dessas classes. Os valores nível de acerto e completeza para as classes solo exposto e grama variaram de 0,50 a 0,70, indicando que a classificação não foi satisfatória. Os valores de nível de

acerto e completeza para as classes que consideram objetos acima do solo, como árvores, edificações e linhas de transmissão, apresentaram valores acima de 0,90, indicando a potencialidade dos atributos geométricos na diferenciação dos objetos elevados.

A classificação considerando atributos radiométricos apresentou resultados melhores do que a classificação considerando atributos geométricos, com acurácia global de 0,80. Os valores de nível de acerto e completeza para as classes consideradas ficaram acima de 0,80, com exceção das classes asfalto e linha de transmissão. A confusão entre asfalto e linhas de transmissão pode ser vista na Figura 6.13b.

A classificação considerando todos os atributos extraídos apresentou os melhores resultados com acurácia global de 0,98. Os valores de nível de acerto e completeza para as classes consideradas foram superiores a 0,92, indicando assim a sinergia entre os atributos radiométricos e geométricos. Por fim, considerando os resultados atingidos para a classificação considerando atributos radiométricos em conjunto com o atributo geométrico altura, nota-se que os resultados foram semelhantes aos resultados da classificação com todos os atributos (acurácia global igual à 0,98) fato que indica que os demais atributos geométricos tiveram pouca ou nenhuma contribuição para o resultado da classificação.

A sinergia entre os atributos geométricos e radiométricos fica evidente quando são comparados os resultados das classificações que consideram apenas um ou outro atributo, com os obtidos para as classificações que utilizam ambos. Houve um ganho de acurácia global de 0,18 quando se compara a acurácia da classificação com atributos radiométricos e a classificação com atributos radiométricos e a altura, 0,80 e 0,98 respectivamente. Os números são ainda mais discrepantes quando se compara a classificação apenas com atributos geométricos e a classificação com atributos radiométricos e a altura, atingindo um ganho de acurácia global de 0,24.

6.2.3 Refinamento


Os processos de refinamento descritos na Seção 3.3 foram aplicados aos resultados obtidos pela classificação que considerou os atributos radiométricos acrescidos do atributo geométrico altura. Os resultados dos processos de refinamento são apresentados na Tabela 6.8 e podem ser visualizados nas Figuras 6.14 e 6.15. Para melhor visualizar os pontos eliminados pelos

processos de refinamento foram consideradas as mesmas 3 regiões apresentadas na Figura 6.12, bem como uma região adicional que apresenta a presença de edificações e árvores.

Na Figura 6.15 é possível perceber um padrão na eliminação de pontos em sombra, os quais, em sua maioria, foram detectados na porção leste e sul de objetos elevados (edificações e árvores). Esse fato reflete exatamente a posição da sombra no momento da aquisição dos dados.


Ao analisar as Figuras 6.14 e 6.15 percebe-se que a eliminação dos pontos de sombra aplicado sobre os pontos classificados como árvore resultou na eliminação de pontos sob a copa mais elevada da vegetação, incluindo pontos espúrios mais próximos ao chão. No caso da eliminação de sombras aplicada aos pontos de edificação, foram eliminados pontos localizados em muros de divisas e em algumas faces de edificações voltadas para sul e leste. A eliminação de pontos de sombra foi mais relevante para o caso de pontos classificados como árvores, resultando na eliminação de aproximadamente 25% dos pontos classificados como árvores.

Figura 6.14 - Exemplos do resultado de refinamento da classificação. Em (a), (c), (e) e (g) têm-se exemplo de regiões com edificações e árvores ainda com os pontos excluídos pelos refinamentos de pontos em planos verticais (pontos amarelos) e regiões de sombra (pontos vermelhos). Em (b), (d), (f) e (h) têm-se as regiões sem os pontos eliminados.



Fonte: Elaborada pelo autor.

Figura 6.15 - Vista ortogonal dos pontos de edificação, de árvores e dos pontos eliminados nos processos de refinamento.



Fonte: Elaborada pelo autor.


Tabela 6.8 - Quantidade de pontos eliminados em cada processo de refinamento aplicado.

Pontos de Edificação				Pontos de Árvore		
Total Classificado	Pontos após refinamento	Eliminados (Ref. Sombra)	Eliminados (Ref. Planos verticais)	Total Classificado	Pontos após refinamento	Eliminados (Ref. Sombra)
1.838.072	1.473.463	155.723	208.886	403.675	305.228	98.447
	67,57%	8,4%	11,36%		75,61%	24,39%

Fonte: Elaborada pelo autor.

A eliminação de pontos de edificação por meio do refinamento baseado em planos verticais resultou na eliminação de pontos sobre as faces, incluindo muros e cercas. Embora façam parte das edificações tais pontos não são de interesse no caso deste trabalho. Além disso, esse processo também resultou na eliminação de pontos espúrios sobre os telhados (Figura 6.16).

Figura 6.16 – Exemplo dos pontos eliminados pelo refinamento de pontos em regiões plano-verticais.



Fonte: Elaborada pelo autor.

Vale destacar que, embora nem todos os pontos espúrios localizados sobre os telhados foram detectados, a eliminação de parte considerável de tais pontos resulta em uma diminuição da conectividade destes com os demais pontos de telhado, fazendo assim com que eles sejam eliminados durante o crescimento de regiões, aplicado na sequência para segmentar as edificações. Isso vale para pequenos aglomerados de pontos sobre muros de divisas e demais objetos erroneamente classificados, como por exemplo o muro de divisa e veículo destacado por círculos vermelhos na Figura 6.14f.

6.3 Resultados da detecção de contornos oclusos (Cap. 4)

Nessa subseção são apresentados os resultados obtidos na fase de detecção de contornos oclusos, incluindo os resultados da segmentação por crescimento de regiões, extração de contornos por meio da aplicação do algoritmo *alpha-shape* e da detecção de oclusões propriamente dita. Os resultados foram obtidos com a aplicação dos métodos descritos no Capítulo 4 sobre os pontos classificados como edificação e árvores após aplicados os processos de refinamento.

6.3.1 Segmentação

Conforme descrito na Seção 4.1, a etapa de segmentação foi aplicada aos pontos de edificação e árvores separadamente. Ambas as segmentações foram realizadas por meio da aplicação do conceito de crescimento de regiões (*Region Growing*). No processo de segmentação dos pontos de edificações foram adotados 2 limiares, sendo um baseado na distância no plano (TD_{xy}) e o outro na distância vertical (TD_h). Já no processo de segmentação dos pontos de árvores foi considerado apenas um limiar de distância no plano (TD_{xy}).

A opção de utilizar dois limiares no processo de segmentação para os pontos de edificação e apenas um para pontos de árvores foi feita com base nas características geométricas das classes de interesse. Em geral, os pontos de edificação apresentam uma variação plano-vertical previsível (Figura 6.17a), enquanto os pontos amostrados sobre árvores têm um comportamento irregular na componente vertical (Figura 6.17b).


Os valores dos limiares de distâncias têm influência direta no resultado da segmentação, valores de limiares muito pequenos podem gerar supersegmentação, enquanto valores de limiares muito grandes podem produzir subsegmentação. No caso deste trabalho, os limiares de distância no plano foram definidos com base no espaçamento médio entre os pontos da nuvem ($D_m = 0,20$ m), separação horizontal mínima esperada entre edificações vizinhas ($S_{xy} = 0,50$ m), separação horizontal mínima esperada entre árvores vizinhas ($Sa_{xy} = 1,00$ m) e separação vertical mínima esperada entre edificações vizinhas ($S_h = 0,20$ m).

A fim de evitar problemas de supersegmentação e subsegmentação causados pelos limiares de distância no plano, os mesmos foram estimados considerando os intervalos de $D_m < TD_{xy} < S_{xy}$ e $D_m < TD_{xy} < Sa_{xy}$, para os pontos de edificação e árvores respectivamente. De forma similar, o limiar de distância vertical (TD_h) foi definido considerando valores no intervalo $0 < TD_h < S_h$. Os valores aplicados aos limiares TD_{xy} e TD_h estão apresentados na Tabela 6.9. Os resultados para a segmentação aplicada aos pontos de edificação e de árvores estão apresentados nas Figuras 6.19 e 6.21.

Ao fim do processo de crescimento de regiões foram aplicados limiares considerando um número mínimo de pontos por agrupamento formado. A aplicação desse limiar tem por objetivo a eliminação de agrupamentos insignificantes. No caso dos agrupamentos de edificação foi considerado o mínimo de 500 pontos, o que corresponde a objetos com área de aproximadamente

de 14 m². No caso dos agrupamentos de árvores foi considerado o mínimo de 200 pontos, o que corresponde a objetos com área de aproximadamente de 5 m².

Figura 6.17 - Variação plano-vertical dos pontos amostrados sobre edificação e árvores.



Fonte: Elaborada pelo autor.


Tabela 6.9 - Parâmetros utilizados na segmentação.

Pontos de edificação			Pontos de árvores	
Limiar de dist. no plano (TD _{xy})	Limiar de dist. vertical (TD _h)	Número mínimo de pontos por <i>cluster</i>	Limiar de dist. no plano (TD _{xy})	Número mínimo de pontos por <i>cluster</i>
0,25 m	0,10 m	500	0,40 m	200

O processo de segmentação dos pontos de edificação e de árvores foi aplicado sobre os pontos obtidos da classificação e após cada processo de refinamento. Os resultados dos processos de segmentação sobre os pontos de edificação estão apresentados na Tabela 6.10 e nas Figuras 6.19 e 6.20. Os resultados dos processos de segmentação aplicados sobre os pontos de árvores estão apresentados na Tabela 6.11 e na Figura 6.21. Vale destacar que, em razão da alta complexidade de cena urbana considerada nos experimentos (Figura 6.18), o processo de segmentação foi


refinado manualmente. Tal refinamento teve por objetivo a segmentação de telhados secundários (garagem e áreas externas) e a segmentação de edificações geminadas. Na Figura 6.18 é apresentada uma região complexa, com edificações geminadas e telhados com diversos telhados secundários.

Figura 6.18 - Região urbana complexa e resultados da segmentação das edificações: (a) imagem RGB da região; (b) resultado da segmentação por crescimento de regiões; e (c) refinamento manual.



Fonte: Elaborada pelo autor.

Figura 6.19 - Resultados das segmentações aplicadas aos pontos de edificação: (a) segmentação aplicada aos pontos oriundos da classificação; (b) segmentação aplicada aos pontos após refinamento dos pontos de sombra; (c) segmentação aplicada aos pontos após refinamento dos pontos em planos verticais; e (d) segmentação manual.



Fonte: Elaborada pelo autor.

Tabela 6.10 – Resultado do processo de segmentação dos pontos de edificação considerando diferentes cenários.


Cenários	Classificação sem refinamento	Após aplicar o refinamento de sombra	Após aplicar o refinamento dos planos verticais	Segmentação manual*
Número de <i>clusters</i> formados	160	209	236	364

Com base nos resultados apresentados na Figura 6.19 e na Tabela 6.10 pode-se perceber que o refinamento da classificação trouxe melhoria para o processo de segmentação. As áreas II e III destacadas na Figura 6.19 são exemplos da melhoria produzida pelo refinamento da

classificação. Na área II é possível verificar a definição de 4 agrupamentos na segmentação aplicada sobre os dados sem refinamento. Após o refinamento baseado nos pontos de sombra, o mesmo conjunto de pontos deu origem a 8 agrupamentos. Em seguida, após o refinamento baseado em planos verticais o número de agrupamentos se manteve. Por fim, após inspeção visual, foram determinados 10 agrupamentos. Na área III é possível verificar que 3 edificações haviam sido agrupadas em apenas 1 *cluster* na segmentação aplicada sobre os dados sem refinamento. Após o refinamento baseado na eliminação de pontos de sombra o agrupamento não modificou, mostrando que nesse caso apenas a eliminação de sombra não foi suficiente para a separação das edificações. Porém, após o segundo processo de refinamento, o mesmo conjunto de pontos deu origem a 2 agrupamentos. Por fim, a mesma área deu origem a 3 agrupamentos após inspeção visual.

Ainda que os refinamentos aplicados aos resultados da classificação tenham resultado em melhorias ao processo de segmentação, pode-se perceber que houve um número grande de segmentos não detectados, conforme valores apresentados na Tabela 6.10. Um exemplo de área segmentada incorretamente, mesmo após refinamento, é apresentado na área I da Figura 6.20. A área I destacada é composta por 6 edificações, nesse caso o segmentador foi incapaz de realizar a separação entre as edificações devido à proximidade entre edificações vizinhas, tanto em distância no plano, quanto ao longo da vertical. Tal região é caracterizado por edificações contíguas e de apenas um pavimento, construídas em terreno aproximadamente plano. Por outro lado, a mesma figura apresenta a área II com edificações contíguas separadas devido à variação de altura entre as construções vizinhas.

Figura 6.20 – Regiões complexas para o processo de segmentação aplicado aos pontos de edificações contíguas. Na figura são apresentadas duas regiões (I e II) complexas para a segmentação.




Fonte: Elaborada pelo autor.

Casos como os destacados na área I da Figura 6.20 são de difícil tratamento pelo segmentador baseado no conceito de crescimento de região. Porém, mesmo quando a proximidade entre edificações vizinhas é menor do que o limiar de distância no plano aplicado, o segmentador é capaz de realizar a separação quando há diferença de altura na região de transição de uma edificação para a outra, conforme exemplo apresentado na área II (Figura 6.20).

O refinamento aplicado aos pontos de árvores possibilitou que o segmentador identificasse indivíduos arbóreos em aglomerados de árvores, conforme exemplo apresentado na área I da Figura 6.21. Por outro lado, diferente do ocorrido para os resultados da segmentação dos pontos de edificação, a segmentação aplicada sobre os pontos pós-refinamento de sombra resultou na

diminuição da quantidade de agrupamentos formados, se comparada aos agrupamentos formados na segmentação dos pontos oriundos da classificação. Isso ocorreu pois o refinamento acabou reduzindo substancialmente a quantidade de pontos, conforme pode ser observado na Tabela 6.8, na qual é apresentada uma redução de aproximadamente 25% dos pontos de árvore após o refinamento dos pontos de sombra. Com isso, árvores de pequeno porte acabaram por ser eliminadas durante a segmentação, por apresentarem número de pontos inferior a 200, aproximadamente 6 m². Esse efeito pode ser verificado nas áreas II e III da Figura 6.21

Figura 6.21 - Resultado da segmentação aplicada aos pontos de árvores: (a) segmentação aplicada aos pontos oriundos da classificação; e (b) segmentação aplicada aos pontos após refinamento dos pontos de sombra.



Fonte: Elaborada pelo autor.

Tabela 6.11 - Resultado do processo de segmentação dos pontos de árvore considerando diferentes cenários.

Cenários	Classificação sem refinamento	Após aplicar o refinamento de sombra
Número de <i>clusters</i> formados	167	141

Vale destacar que a perda de informação durante a segmentação dos pontos de árvores, causada pela eliminação de pontos de sombra, pode impactar os resultados das etapas posteriores, em especial a identificação de oclusão. Nesse sentido, optou-se por considerar os resultados da segmentação aplicada aos pontos de árvores oriundos da classificação, a fim de evitar a ocorrência de erros de omissão no processo posterior de detecção de oclusão por vegetação.

6.3.2 Detecção de contornos iniciais


Nessa etapa do método espera-se obter apenas um contorno inicial dos objetos, a fim de utilizá-los como dados de entrada na etapa de detecção de oclusão. Assim, não foi realizada avaliação quantitativa dos contornos extraídos. A estimativa do contorno final será feita apenas após a integração das nuvens aérea e terrestre, visando a complementação de informação nas áreas de oclusão.

A extração dos contornos de árvores foi realizada utilizando valor de *alpha* constante, com base no espaçamento médio da nuvem, enquanto a extração dos contornos de edificação foi realizada a partir de duas abordagens de estimativa do parâmetro *alpha*. A primeira consistiu na aplicação de um parâmetro constante estimado de forma similar ao parâmetro *alpha* aplicado na extração dos contornos de árvores. A segunda abordagem considerou a estimativa de um parâmetro *alpha* por edificação, com base no espaçamento médio dos pontos de cada edificação, similar ao proposto por Santos, Galo e Carrilho (2018, 2019). Os valores e/ou estratégias para determinação do parâmetro *alpha* para cada uma das extrações de contornos aplicadas estão apresentados na Tabela 6.12.

Tabela 6.12 - Estratégias e valores de parâmetros alpha aplicados à extração de contornos.

Tipo de objeto	Edificações		Árvores
Estratégia	Fixo	Variante por edificação	Fixo
Valor considerado	0,50 m	---	1,00 m


Nessa etapa do trabalho foram considerados apenas os dados resultantes da segmentação manual de edificações e da segmentação de árvores aplicada sobre os dados oriundos da classificação. Os resultados da extração de contorno aplicada sobre os segmentos de árvores estão apresentados na Figura 6.22. Para a apresentação dos resultados da extração de contornos sobre os aglomerados de pontos de edificações foram selecionadas edificações com diferentes características geométricas (Figura 6.23), sendo os resultados das duas abordagens aplicadas apresentados na Figura 6.24.



Fonte: Elaborada pelo autor

Com base em análises visuais acerca do resultado da extração de contornos sobre os pontos de árvores é possível observar que não houve a geração de contornos internos, mesmo para o caso da árvore, ou aglomerado de árvores, como pode-se ver em T28 (Fig. 6.22), por exemplo. Para este agrupamento o processo de segmentação aplicado não foi capaz de individualizar as árvores devido à proximidade entre elas. Nesse caso considera-se o contorno como um aglomerado de árvores, sendo que este resultado não acarretará em prejuízo para a etapa de detecção de oclusões.


Figura 6.23 - Edificações selecionadas para apresentar os resultados da extração de contornos iniciais.



Fonte: Elaborada pelo autor.

Com base em análises visuais sobre o resultado da extração de contornos das edificações, observa-se que a abordagem que considera a estimativa do parâmetro *alpha* por edificação apresentou extração incorreta para as edificações B6, B11, B162. Essas falhas podem ser atribuídas principalmente a dois fatores, existência de elementos sobre o telhado (B162, Figura 6.23 seta em vermelho), como por exemplo antenas parabólicas, ou ruídos oriundos da geração da nuvem de pontos que foram eliminados em fases preliminares desse trabalho (B11, Figura 6.23 setas em laranja). Na Figura 6.24 é mostrado o resultado do uso de diferentes valores do parâmetro *alpha* para sete edificações diferentes.

Figura 6.24 - Resultados da extração de contornos sobre edificações para as diferentes estratégias de estimativa do parâmetro alpha.



Fonte: Elaborada pelo autor.

Com base nos parâmetros *alpha* gerados para cada edificação foram estimados os valores de média, desvio-padrão, máximo e mínimo, bem como a média ± 3 desvios-padrão (Tabela 6.13), a fim de analisar a variabilidade desse parâmetro. Com base nos valores apresentados é possível perceber que houve uma grande variabilidade nos valores de *alpha* estimados. Destaca-se que em razão da alta densidade da nuvem, algumas edificações resultaram em valores de *alpha* inferiores a 0,20 m. Além disso, com base nos valores máximo e mínimo é possível perceber que ocorreram valores maiores que o intervalo de média ± 3 desvios-padrão, podendo esses serem considerados como *outliers*.

Tabela 6.13 - Estatísticas extraídas sobre o conjunto de parâmetros *alpha* estimados.

Média	Desvio-padrão	Média ± 3 desvios-padrão		Máximo	Mínimo
0,402 m	0,342 m	0,000	1,428 m	2,870 m	0,169 m

Vale destacar que valores de *alpha* muito pequenos podem gerar contornos muito serrilhados. Em teoria, valores de *alpha* na ordem de 0,20 m são capazes de detectarem e extraírem contornos em reentrâncias ou vazios maiores ou iguais à duas vezes sua magnitude, podendo gerar detalhamento excessivo do contorno e até mesmo extração de contornos inexistentes, como no caso das edificações B6 e B11.

Ao se comparar os resultados obtidos nesse trabalho com os resultados de trabalhos que exploram a extração de contornos de telhados em situação de variação de densidade da nuvem, como o de Santos *et al.* (2020), percebe-se que no caso de dados LiDAR a variação de densidade é mais homogênea (Figura 2.6c), usualmente originada por variações de velocidade e atitude da plataforma ou por sobreposição entre faixas de varredura. Em ambos os casos a densidade para uma edificação é aproximadamente constante, diferente do que ocorre em nuvens fotogramétricas, nas quais as variações de densidade são pontuais e abruptas (Figura 2.6b). Nesse caso a utilização de um parâmetro *alpha* por edificação não se justifica.


6.3.3 Detecção de oclusão

Nessa etapa do trabalho foram considerados apenas os dados resultantes da extração de contornos de edificação e árvores com parâmetro *alpha* fixo, 0,50 m e 1,00 m respectivamente. A partir dos pontos pertencentes aos contornos das árvores foram geradas regiões de influências das

árvores por meio da aplicação de *buffer*, conforme descrito na Seção 4.3. Nesta etapa foram testadas diferentes regiões de influência da árvore a partir da aplicação de diferentes valores de *buffer*, variando de 0 a 100 cm com passo de 5 cm. O valor de *buffer* igual a 0 cm considera os pontos pertencentes ao contorno extraído da árvore como região de influência. Os resultados aqui apresentados contemplam oclusões de diferentes características.

Na Figura 6.25 estão representados os resultados para 7 oclusões corretamente detectadas. Das 7 oclusões apresentadas três foram detectadas a partir de 0 cm de *buffer* (T25 B34; T74 B64; e T77 B89), uma com *buffer* a partir de 25 cm (T52 B353), uma com *buffer* a partir de 30 cm (T42 B145), uma com *buffer* a partir de 40 cm (T10 B203), e uma com *buffer* de 50 cm (T42 B148). Nesta Figura estão representados em verde os pontos definem o contorno da árvore, em amarelo os pontos da região de influência da árvore para o menor valor de *buffer* no qual a oclusão foi detectada e em azul e vermelho os pontos que definem o contorno da edificação, sendo os pontos em vermelho aqueles detectados como oclusos. Nos casos das Figura 6.25 (T25 B34, T10 B203, T42 B148 e T42 B145) é possível notar que ocorrem outras oclusões além daquelas representadas, embora tais oclusões também tenham sido detectadas corretamente, nesse caso optou-se por não representá-las na figura para não prejudicar a visualização das oclusões selecionadas.

Figura 6.25 - Oclusões detectadas a partir de diferentes valores de *buffer*.



Fonte: Elaborada pelo autor.

Na Figura 6.25 (T25 B34, T74 B64 e T42 B145) estão indicados por setas vermelhas pontos oclusos não detectados. Isso ocorre devido à perda de informação na região de transição entre a edificação e a árvore, que por sua vez implica em um distanciamento entre os pontos dos contornos de árvores e edificações, conforme já discutido na Seção 2 e apresentado na Figura 2.7. Assim, o método é capaz de indicar a ocorrência de oclusão, mas não é capaz de indicar a região completa de oclusão, ou mesmo o local de início e fim da oclusão. Uma vez detectada uma oclusão, deve-se considerar que ela pode se estender por toda a região de influência da árvore e, dessa forma, a detecção de apenas 1 ponto ocluso ou de todos os pontos oclusos não terá impacto na mitigação do contorno ocluso, cujos resultados estão apresentados na Seção 6.4 desta Tese.

Conforme pode-se verificar nos resultados apresentados na Figura 6.25 (T52 B353, T42 B145, T10 B203 e T42 B148), sem a aplicação do *buffer* tais oclusões não seriam detectadas, incorrendo em FN. Nota-se que o distanciamento entre os pontos de contorno de edificação e dos pontos de contorno de árvores, causados pelas características da nuvem de pontos fotogramétrica, tornam necessária a aplicação do *buffer* não nulo para a determinação de uma região de influência da árvore. Em contrapartida, a aplicação de valores de *buffer* maiores pode incorrer na detecção de oclusões inexistentes, como nos casos apresentados na Figura 6.26.



Fonte: Elaborada pelo autor.

Na Figura 6.26 são apresentadas 3 oclusões erroneamente detectadas, as quais foram consideradas falsos positivos (FP) na análise quantitativa do método (Tabela 6.14). Das 3 oclusões apresentadas uma foi detectada a partir de 0 cm de *buffer* (T79 B293); uma foi detectada com *buffer* de 40 cm (T85 B262); e uma foi detectada com *buffer* de 100 cm.

A avaliação quantitativa dos resultados foi realizada a partir da comparação dos resultados em relação aos dados de referência. Para tal, foram gerados os contornos das árvores e das edificações da área de estudo, por meio de vetorização sobre o ortofotomosaico gerado com base no mesmo conjunto de dados que originaram a nuvem de pontos fotogramétrica utilizada neste trabalho. Vale destacar que a utilização de uma referência obtida a partir da mesma fonte de dados possibilita que erros de georreferenciamento não influenciem os resultados da avaliação do método objeto de análise.

Os resultados da detecção de oclusão foram avaliados por meio dos parâmetros de qualidade apresentados na Seção 4.3.1 e estimados por meio das Equações 4.5, 4.6 e 4.7. Os valores de parâmetros de qualidade estimados para cada um dos *buffers* testados estão apresentados na Tabela 6.14. Com base nessa tabela é possível perceber que os indicadores *C* e *NA* variam de acordo com a variação do *buffer* utilizado. Os valores de *C* aumentam conforme são utilizados valores de *buffer*

maiores, porém os valores de *NA* diminuem. Esse efeito ocorre uma vez que o aumento dos valores do *buffer* incorre em maior quantidade de FP, afetando assim o *NA* do método. Por outro lado, valores pequenos de *buffer* incorrem em maior quantidade de FN, afetando a capacidade de detectar oclusões e refletindo diretamente no indicador *C*. Por fim, é possível notar que valores de *buffer* de 50 cm atingiram o pico do valor de F_{score} , apresentando *NA* e *C* na ordem de 0,731 e 0,936, respectivamente.

Tabela 6.14 - Parâmetros de qualidade para detecção de oclusão considerando diferentes valores de *buffer*.

<i>Buffer</i> (cm)	VP	FP	FN	VN	<i>C</i>	<i>NA</i>	F_{score}
0	108	26	63	56	0,632	0,806	0,708
5	116	29	55	55	0,678	0,800	0,734
10	128	33	43	53	0,749	0,795	0,771
15	135	39	36	52	0,789	0,776	0,783
20	142	41	29	52	0,830	0,776	0,802
25	147	45	24	51	0,860	0,766	0,810
30	148	47	23	51	0,865	0,759	0,809
35	151	48	20	51	0,883	0,759	0,816
40	152	52	19	48	0,889	0,745	0,811
45	157	58	14	47	0,918	0,730	0,813
50	161	58	11	47	0,936	0,731	0,821
55	161	64	10	47	0,942	0,716	0,813
60	161	65	10	47	0,942	0,712	0,811
65	163	67	8	46	0,953	0,709	0,813
70	163	69	8	46	0,953	0,703	0,809
75	165	70	6	46	0,965	0,702	0,813
80	165	72	6	46	0,965	0,696	0,809
85	165	74	6	46	0,965	0,690	0,805
90	165	74	6	46	0,965	0,690	0,805
95	165	78	6	46	0,965	0,679	0,797
100	165	84	6	46	0,965	0,663	0,786

No caso de trabalhos de detecção de oclusão deve-se considerar que a completeza é mais relevante que *NA*. A detecção de falsas ocorrências não gera prejuízos, uma vez que tais ocorrências podem ser verificadas em um segundo momento. Por outro lado, a não detecção de oclusões pode fazer com que um contorno seja aceito como corretamente extraído, quando de fato foi extraído de

forma incompleta em razão da ocorrência de oclusões. Assim, para esse trabalho os resultados do Cap. 5 foram gerados com base nas oclusões detectadas com buffer de 50 cm.

6.4 Resultados da mitigação dos contornos oclusos (Cap. 5)


Nessa subseção são apresentados os resultados obtidos na fase de mitigação de contornos oclusos, incluindo a etapa de extração de planos, definição da região de busca e a extração de contornos por meio da aplicação do algoritmo *alpha-shape*. Os resultados foram obtidos com a aplicação dos métodos descritos no Capítulo 5. Nesta etapa do método, conforme o fluxo apresentado na Figura 5.1, considerou-se como dados de entrada a nuvem terrestre e os grupamentos de edificações em que foram detectadas oclusões, bem como o contorno das árvores que as causaram.

A mitigação dos contornos por meio da integração de nuvens fotogramétricas obtidas a partir de diferentes pontos de vistas é tarefa complexa, sendo composta por uma série de processos, desde a aquisição, passando pelo registro da nuvem, até a seleção dos pontos de interesse. Nesta Tese a aquisição e o registro das nuvens não são foco de discussão, sendo estas consideradas georreferenciadas em um mesmo sistema de referência. O foco desta etapa do método se concentra na exploração de estratégias para a seleção de pontos de interesse, bem como na extração e análise dos contornos oclusos.

Dentre as estratégias de seleção destaca-se a exploração do conceito de MOBB e a utilização da técnica RANSAC para testes de pertinência dos pontos em relação aos planos que compõe os telhados. A extração de contorno foi realizada pela aplicação do algoritmo *alpha-shape* com valor de *alpha* fixo igual a 0,50 m, de forma similar ao descrito na Seção 4.2. A análise de qualidade considera a aplicação dos parâmetros descritos nas Seções 4.3.1 e 5.3.1.

Para melhor avaliar os resultados foram selecionadas 13 edificações, as quais estão apresentadas na Figura 6.27. Os resultados das sub etapas de extração de planos e definição da região de busca estão apresentados nas Seções 6.4.1 e 6.4.2. Os resultados do método de mitigação dos contornos oclusos, bem como a avaliação quantitativa deles, estão apresentados na Seção 6.4.3. Os resultados referem-se a diferentes tipos de oclusões, contemplando oclusões de pequenas dimensões até oclusões de grandes dimensões, as quais são críticas para o método por ocluírem faces inteiras dos telhados.

Figura 6.27 - Edificações selecionadas para discussão dos resultados.



Fonte: Elaborada pelo autor.

As oclusões T10_B203, T18_B301, T32_B61 e T69_B252 podem ser consideradas de pequena magnitude. As oclusões T17_B265, T18_B299, T25_B35, T33_B315 e T43_B167 podem ser consideradas de média magnitude. Por fim, as oclusões T9_B304, T17_B289, T18_B279 e T32_B49 podem ser consideradas de grande magnitude. Vale destacar ainda que, as oclusões T17_B289 e T18_B279 são de alta complexidade, sendo a primeira caracterizada pela oclusão total de uma das faces e a segunda caracterizada pela oclusão de parte significativa da edificação, dificultando a identificação dos limites de parte da edificação. Ademais, embora diversos aglomerados de árvores causem oclusões em mais de uma edificação, como é o caso dos T10, T17,

T18, T25, T32 e T69, nem todas as oclusões aparentes nas imagens foram selecionadas para apresentação dos resultados.

6.4.1 Extração de planos


Conforme descrito na Seção 5.1, a etapa de extração de planos foi aplicada sobre os pontos de cada edificação individualmente. Os planos oclusos de cada edificação foram detectados pela proximidade dos pontos oclusos do contorno em relação aos pontos dos planos extraídos. Os resultados da extração de planos e seleção dos planos oclusos estão resumidos e apresentados na Tabela 6.15.

Com base nos resultados da Tabela 6.15 é possível perceber que a técnica RANSAC aplicada, considerando os limiares já apresentados, foi capaz de extrair todos os planos das edificações testadas, com exceção da edificação B279. No caso específico desta edificação, houve perda total dos pontos componentes do plano não extraído. O caso mencionado está ilustrado na Figura 6.28, na qual o triângulo definido por linhas tracejadas vermelhas representa a face oclusa do telhado.

Tabela 6.15 - Número de planos extraídos e oclusos por edificação.

Edificações	Nº de planos	Nº planos extraídos	Nº planos parcialmente oclusos	Nº planos totalmente oclusos
B304	12	12	5	0
B203	6	6	2	0
B289	2	2	2	0
B265	4	4	2	0
B279	7	6	3	1
B301	4	4	2	0
B299	6	6	4	0
B167	4	4	1	0
B35	6	6	3	0
B49	4	4	3	0
B61	6	6	2	0
B315	4	4	2	0
B252	5	5	1	0

Figura 6.28 - Extração de planos para a edificação 279. (a) planos extraídos a partir da nuvem aérea. (b) visualização da edificação na nuvem terrestre.




Fonte: Elaborada pelo autor.

Vale destacar que nas edificações em que ocorre perda total ou parcial dos pontos que compõem uma ou mais faces do telhado, restando menos pontos na face do que os pontos especificados pelo parâmetro *min support points per primitive*, não é possível extrair o plano da face oclusa e consequentemente não é possível realizar as etapas subsequentes. Ainda assim, a referida edificação será utilizada nas etapas subsequentes na tentativa de mitigação dos contornos oclusos, cujo resultado da etapa de mitigação dos contornos oclusos será apresentado na Seção 6.4.3.

A fim de ilustrar os planos extraídos para as edificações em que regiões oclusas foram detectadas apresenta-se a Figura 6.29, que representa os planos extraídos para a edificação B304. Neste caso foi possível extrair a totalidade dos planos que compõem o telhado da edificação. Resultados similares foram obtidos para as demais edificações, mesmo para aquelas em que ocorreram oclusões de magnitude média ou grande.

Figura 6.29 - Planos extraídos para a edificação 304.



Fonte: Elaborada pelo autor.


Na Figura 6.29 os pontos representados em branco correspondem aos pontos não adicionados a nenhum dos planos extraídos, sendo os demais pontos coloridos de acordo com a sequência de planos extraídos. O padrão de cores apresentados nesta figura foi adotado para as demais figuras ao longo desta seção. O número do plano foi atribuído de acordo com a quantidade relativa de *inliers*, sendo o plano mais numeroso considerado o “Plano 1” e menos numeroso “Plano n”, onde n representa o número total de planos extraídos por edificação.

6.4.2 Definição da região de busca e seleção dos pontos na nuvem terrestre

Conforme apresentado na Seção 5.2, a etapa de definição da região de busca foi aplicada aos pontos pertencentes às edificações com oclusões detectadas. A definição da região de busca considera a área comum a duas regiões, a MOBB dos pontos da edificação sob análise e a área de influência da árvore que causou a oclusão. A região de influência de cada árvore é definida pelo polígono *convex hull* dos pontos da árvore, conforme descrito na Seção 4.2. A MOBB foi gerada por meio de aplicação de ferramentas disponíveis na biblioteca COMPAS, utilizando a linguagem *Python*.

A utilização da MOBB permite a redução do espaço de busca se comparada a BB mais genéricas, como por exemplo as BBs orientadas aos eixos cartesianos (AABB). Para efeito de comparação entre as diferentes regiões criadas por diferentes BBs, a Figura 6.30 apresenta o resultado de uma AABB (linhas amarelas) e da MOBB (linhas vermelhas) para a edificação B315.

Figura 6.30 - Comparação entre as áreas definidas pela AABB (amarelo) e pela MOBB (vermelho).




Fonte: Elaborada pelo autor.

Como pode ser observado na Figura 6.30, o retângulo envolvente resultante da MOBB (vermelho) se ajusta melhor aos dados (menor volume), quando comparado ao retângulo envolvente resultante da AABB (amarelo), com isso, ao se utilizar a MOBB a seleção de pontos de interesse é mais restritiva.

Na Figura 6.31 é apresentado o resultado do processo de seleção de pontos de interesse para a edificação 299. Na Figura mencionada estão representados em rosa os pontos da edificação, em amarelo os pontos selecionados pela MOBB, em azul os pontos selecionados pela área de influência da árvore, e em laranja os pontos selecionados por ambas as áreas. Ainda na Figura mencionada, destacados por círculo vermelho, é possível perceber que foram selecionados pontos

que não pertencem ao telhado da edificação. Tais pontos são eliminados posteriormente, na etapa em que a pertinência dos pontos aos planos das faces dos telhados é verificada.

Figura 6.31 - Pontos selecionados por cada uma das regiões de busca. Exemplo da seleção de pontos para a edificação 299, considerando a aplicação da MOBB e da região de influência da árvore. Figura da esquerda apresenta a vista ortogonal, enquanto a figura da direita apresenta vista lateral.




Fonte: Elaborada pelo autor.

A utilização da MOBB tem por objetivo limitar a busca apenas para a região da edificação, evitando que o método detecte pontos em regiões vizinhas. A utilização da região de influência da árvore causadora da oclusão tem por objetivo evitar que o método selecione pontos sobre a edificação, em regiões não oclusas. As restrições do espaço de busca auxiliam no processo de reconstrução do contorno ocluso, pois estas pré-selecionam os pontos a serem testados quanto a pertinência ao plano. Sem a consideração da região de busca o processo incorreria na seleção de pontos não pertencentes à edificação sob análise. Vale destacar que a etapa que testa a pertinência dos pontos aos planos não apresenta limitação no espaço, sendo possível a seleção de pontos em qualquer região. Assim, para um determinado plano seria possível a detecção de pontos em objetos vizinhos a edificação de interesse, como por exemplo edificações vizinhas, muros, calçada, rua etc.

A fim de ilustrar o efeito da não utilização das regiões de busca previamente a aplicação da seleção pela equação dos planos, a Figura 6.32 apresenta os pontos selecionados pelo método com e sem a utilização das regiões de busca. Nota-se nas Figuras 6.32b e 6.32e que foram selecionados diversos pontos em regiões que extrapolam a edificação. A maioria dos pontos selecionados incorretamente encontram-se sobre muros vizinhos e nas vias que dão acesso à edificação. Os resultados de seleção dos pontos considerando as regiões de busca e o teste de pertinência aos planos foram capazes de selecionar pontos apenas na edificação sob análise, sendo limitados ainda apenas à região onde ocorreu a oclusão (Figuras 6.32c e 6.32f).

Figura 6.32 - Pontos selecionados com e sem a restrição pela área de busca. (a) e (d) vista superior e perspectiva da edificação 299. (b) e (e) vista superior e perspectiva dos pontos selecionados sem considerar restrição na área de busca. (c) e (f) vista superior e perspectiva dos pontos selecionados considerando a restrição na área de busca.



Fonte: Elaborada pelo autor.

A não utilização da restrição no espaço de busca pela MOBB é particularmente crítica para o caso de oclusões causadas por aglomerados de árvores. Nesse caso, apenas a restrição pela região de influência das árvores (ou aglomerados) terão um conjunto muito grande de pontos, o que pode provocar o aumento da probabilidade de seleção de pontos não pertencentes à edificação sob análise. Nesse caso, o custo computacional também será impactado. A quantidade de pontos selecionados pelas áreas de busca, bem como os pontos selecionados para cada ponto parcialmente ocluído estão apresentados na Tabela 6.16.

Tabela 6.16 – Pontos selecionados por plano parcialmente ocluso.

Edificação	Nº de pontos selecionados pelas áreas de busca	Plano	Nº de pontos que satisfazem a eq. do plano	Nº de pontos descartados
B304	53.574	1	90	26.755
		2	23.684	
		3	2.760	
		5	285	
B203	3.118	3	123	585
		4	2.410	
B289	2.523	1	251	2.344
		2	1.441	
B265	8.929	3	4.722	178
		4	4.029	
B279	12.350	1	7.323	3.667
		2	1.360	
		5	0	
301	1.521	2	1.439	82
B299	23.658	2	1.066	13.713
		3	1.954	
		5	3.267	
		6	3.658	
B167	8.885	3	7.690	1.195
B35	11.440	1	28	5.573
		3	0	
		4	5.003	
B49	18.541	1	100	4.692
		2	8.732	
		3	5.017	
B61	2.114	1	743	790
		2	581	
B315	6.339	2	409	1.168
		4	4.762	
B252	6.955	1	4.157	2.798

Os planos apresentados na Tabela 6.16 foram numerados de acordo com a quantidade de *inliers* resultantes da aplicação do algoritmo RANSAC, sendo o plano com maior quantidade de *inliers* numerado como 1, como mencionado. O número total de planos de cada edificação está apresentado na Tabela 6.16, na coluna “Nº de planos”.


Os planos destacados em vermelho na Tabela 6.16 referem-se aos planos parcialmente oclusos, sendo menos visíveis do ponto de vista do qual o mapeamento terrestre foi realizado. Nesses casos, dois efeitos foram percebidos: a oclusão é de pequena dimensão, resultando em poucos pontos selecionados pelo método; ou a região de oclusão tem visada prejudicada a partir do ponto de vista em que a nuvem terrestre foi adquirida, resultando assim em poucos pontos passíveis de seleção.

Na Figura 6.33 as edificações e seus respectivos planos oclusos e pontos selecionados são apresentados. Nesta figura, os locais destacados por setas na cor laranja correspondem a oclusões em planos menos visíveis do ponto de vista terrestre. Os pontos destacados na mencionada figura coincidem com aqueles destacados na Tabela 6.16. Vale ressaltar que, embora tais planos sejam de difícil reconstrução por estarem em locais com visibilidade reduzida, ainda assim foram selecionados pontos que compõem tais planos, mesmo que em número reduzido.

As situações destacadas pelas setas verdes consistem em oclusões nos planos laterais das edificações, similares às aquelas destacadas pelas setas laranjas. No entanto, diferente da situação destacadas pelas setas laranjas, nesses casos a edificação vizinha não causou oclusão do ponto de vista terrestre, possibilitando assim uma melhor geometria de intersecção dos feixes perspectivos no momento do processamento das imagens terrestres para a geração da nuvem. As limitações destacadas acima estão mais relacionadas às limitações de geração da nuvem de pontos terrestre do que às limitações do método proposto.

Os casos destacados por setas vermelhas nas edificações T17_B289 e T18_B279 referem-se a falhas na seleção dos pontos em razão da formação de uma MOBB menor do que a ideal, limitando assim a região de busca. No caso da ocorrência T17_B289 houve perda parcial dos pontos de ambos os planos, impactando diretamente na geometria da MOBB. No caso da ocorrência T18_B279 a MOBB foi afetada pela não extração de um dos planos, conforme destacado na Tabela 6.16 e apresentado na Figura 6.28.

Figura 6.33 - Planos parcialmente oclusos e pontos selecionados pelo método.



Fonte: Elaborada pelo autor.

Os casos destacados por setas azuis (T18_B299 e T32_B49) referem-se a conjuntos de pontos corretamente selecionados, porém com grande variação de densidade. Esse efeito é resultante da grande quantidade de sombras nas regiões, as quais refletiram diretamente na nuvem

de pontos terrestre. Tal variação de densidade pode impactar na etapa subsequente do método, gerando uma grande quantidade de pontos de contorno, incluindo ocorrências de contornos internos não existentes.


6.4.3 Extração do contorno final

A etapa de extração do contorno final das edificações foi realizada por meio da aplicação do algoritmo *alpha-shape* com parâmetro α fixo de 0,50 m, conforme apresentado na Seção 5.3. Os contornos finais foram extraídos sobre o conjunto de pontos da edificação, resultantes dos processos de segmentação da nuvem aérea, acrescidos dos pontos selecionados a partir da nuvem terrestre, sendo os resultados apresentados na Figura 6.34.

Os contornos extraídos para as edificações B35, B61, B279 e B289 foram parcialmente mitigados, conforme pode ser observado na Figura 6.34. Especificamente para os casos das edificações B279 e B289 a mitigação parcial é resultante de problemas na definição da área de busca, resultante de perda significativa do telhado na nuvem área. Em ambos os casos a MOBB gerada não possibilitou a definição correta da região de busca, sendo o caso da B279 mais crítico por ocorrer a oclusão total de uma das faces do telhado. Nesse caso a busca por pontos que pertençam ao plano ocluso não é possível, uma vez que, o plano não foi extraído.

As edificações B35 e B61 apresentam a maior parte de região de oclusão na parte lateral da edificação. Nesses casos, os contornos extraídos após a seleção de pontos foram similares aqueles extraídos considerando apenas os dados aéreos, isto ocorre devido a dificuldades de aquisição de dados nestas regiões, sendo esta de difícil visualização do ponto de vista do mapeamento terrestre.

Figura 6.34 - Resultados da extração de contornos oclusos. As linhas pretas representam os contornos de referência, as linhas laranjas os contornos originais, prévios à integração da nuvem terrestre e as linhas amarelas os contornos finais.



A avaliação quantitativa foi realizada por meio da aplicação das métricas descritas nas Seções 4.3.1 e 5.3.1. As métricas: nível de acerto, completeza e F-score foram estimadas com base na relação topológica entre os contornos extraídos e os contornos de referência. As áreas comuns entre os polígonos formados pelos contornos analisados e pelos contornos de referência consistem nos VP (Verdadeiro Positivo). As áreas em que existe o polígono de referência, mas não existe o polígono extraído consistem em FN (Falso Negativo). Por fim, as áreas em que existe o polígono

extraído, mas não existe o polígono de referência consistem em FP (Falso Positivo). A métrica PoLiS, por sua vez, foi estimada com base na relação topológica entre os vértices e segmentos de retas dos contornos extraídos e de referência.

Os resultados para as métricas nível de acerto, completeza e F-score estão sumarizados na Tabela 6.17, sendo apresentada na Tabela 6.18 o ganho relativo ao aplicar o método proposto.

Tabela 6.17 - Métricas de qualidade (nível de acerto e completeza e F-score).

	Nível de acerto		Completeza		F-score	
	Contorno original	Contorno final	Contorno original	Contorno final	Contorno original	Contorno final
B35	0,959	0,960	0,798	0,821	0,871	0,885
B49	0,992	0,990	0,708	0,864	0,826	0,923
B61	0,990	0,985	0,873	0,916	0,928	0,949
B167	0,990	0,974	0,915	0,960	0,944	0,967
B203	0,974	0,953	0,950	0,976	0,952	0,964
B252	0,977	0,974	0,953	0,965	0,965	0,970
B265	0,902	0,916	0,802	0,953	0,849	0,934
B279	0,978	0,980	0,649	0,716	0,780	0,827
B289	0,971	0,973	0,648	0,711	0,777	0,821
B299	0,960	0,964	0,685	0,943	0,800	0,953
B301	0,971	0,971	0,946	0,948	0,958	0,959
B304	0,930	0,932	0,887	0,980	0,908	0,955
B315	0,958	0,955	0,929	0,961	0,943	0,958

Os valores obtidos para a métrica nível de acerto, tanto dos contornos originais, quanto dos contornos finais, foram superiores a 0,90, indicando assim a potencialidade do uso do algoritmo alpha-shape sobre nuvens de pontos aéreas para aplicações de extração automática de contornos de edificações. Ademais, após aplicação do método proposto nesta Tese os valores de nível de acerto pioraram marginalmente para metade dos casos testados (indicados pelas células com sombreamento laranja). A piora marginal dos valores de nível de acerto ocorrem para os casos em que os contornos oclusos, após mitigação das oclusões, extrapolam os contornos de referência.

Os valores para a métrica completeza são os mais impactados pelo método, nesse caso houve melhora para todas as edificações, inclusive para aquelas destacadas anteriormente (B35, B61, B279 e B289). Ressalta-se que a métrica completeza é a métrica mais relevante para avaliação do método, uma vez que, o método busca pela complementação de regiões oclusas do ponto de vista aéreo.

Ainda no que se refere a métrica completeza, os valores destacados em vermelho correspondem às edificações em que houve a maior perda de informação devido à oclusão, atingindo valores inferiores ou iguais a 0,80 para os contornos originais. Destas, as edificações B49, B265 e B299 tiveram reconstrução satisfatória, evoluindo os valores de completeza de 0,708 a 0,864 de 0,802 a 0,953 e de 0,685 a 0,943, respectivamente. As edificações B35 e B279 e B289 apresentaram melhora significativa, porém não atingiram valores de completeza satisfatórios, evoluindo de 0,798 a 0,821, de 0,649 a 0,716 e de 0,648 a 0,711, respectivamente. Esse fato é resultante dos problemas de definição da região de busca e de dificuldade de aquisição de informação na região da oclusão, já citados anteriormente. Para melhor avaliar as variações das métricas foi estimada a porcentagem de ganho relativo, a partir da fórmula a seguir:

$$M_F = \frac{M_1 - M_2}{M_1} * 100 \quad (6.1)$$

sendo M_1 e M_2 os valores da métrica para os contornos originais e finais, respectivamente; e M_F valor de ganho relativo para a métrica considerada. Os valores de porcentagem de ganho relativo estão apresentados na Tabela 6.18.

Tabela 6.18 - Porcentagem de ganho relativo para o nível de acerto, completeza e F-score.

	Nível de acerto (%)	Completeza (%)	F-score (%)
B35	0,12	2,93	1,63
B49	-0,17	22,18	11,76
B61	-0,45	4,92	2,32
B167	-1,66	4,92	2,46
B203	-2,16	2,66	1,28
B252	-0,29	1,32	0,52
B265	1,55	18,87	10,04
B279	0,17	10,41	6,09
B289	0,25	9,65	5,68
B299	0,33	37,71	19,22
B301	0,00	0,23	0,12
B304	0,18	10,48	5,20
B315	-0,33	3,51	1,59
Média	-0,19	9,98	5,22

Com base na Tabela 6.18 é possível verificar que os valores de nível de acerto variam marginalmente, conforme já observado na Tabela 6.17. Ao se analisar a métrica completeza, os ganhos são mais expressivos, sendo que os mais significativos aconteceram para as edificações B49, B265, B279, B289, B299 e B304, como porcentagens de ganho próximas ou superior a 10%. Os valores de ganho são reduzidos quando se analisa a métrica F-score, pelo fato desta métrica ser estimada a partir da média harmônica das outras duas métricas apresentadas na tabela. Ainda assim, observa-se que o método proposto apresentou um ganho médio de F-score em torno de 5,22% e um aumento da completeza da ordem de 9,98%.

As edificações B35, B203, B252, B301 e B315 apresentam ganhos de completeza menores que 4%. No caso da edificação B35 a mitigação do contorno não foi possível para grande parte da área oclusa devido à região em que a mesma ocorreu, conforme já discutido anteriormente. Nos casos das edificações B301 e B315 os baixos valores relativos são resultantes das dimensões reduzidas da área de oclusão. Para as demais edificações, os baixos valores de ganho relativos justificam-se pelo tamanho da oclusão em relação à área total da edificação. Os valores absolutos de área de referência, área do contorno original e área do contorno final estão apresentados na Tabela 6.19. Além disso são apresentados os erros relativos em área, estimados para o contorno original e também para o contorno final, após a aplicação do método proposto. Este erro relativo é calculado por uma equação análoga à Eq. 6.1 onde M_1 corresponde a área de referência e M_2 a área do contorno em análise, ou o contorno original ou o contorno final.

Tabela 6.19 - Áreas das edificações analisadas e respectivos erros relativos.

	Área Ref. (m ²)	Área C. Ori. (m ²)	Área C. Fin. (m ²)	Erro relativo no contorno original (%)	Erro relativo no contorno final (%)
B35	97,42	81,13	83,25	-16,72	-14,55
B49	79,10	56,41	69,09	-28,69	-12,65
B61	109,24	96,22	101,63	-11,92	-6,97
B167	110,75	104,03	109,25	-6,07	-1,35
B203	143,04	142,47	146,44	-0,40	2,38
B252	134,77	131,41	133,53	-2,49	-0,92
B265	44,26	40,25	47,09	-9,06	6,39
B279	79,88	53,00	58,28	-33,65	-27,04
B289	59,78	39,94	43,69	-33,19	-26,92
B299	86,06	61,31	84,19	-28,76	-2,17
B301	55,86	54,41	54,56	-2,60	-2,33
B304	328,94	313,19	335,81	-4,79	2,09
B315	66,54	64,53	66,91	-3,02	0,56
Média (%)				-13,95	-6,42
Desvio-padrão (%)				12,71	10,82

Ao analisar os valores de diferença entre a área de referência e as áreas obtidas pelos contornos finais (Tabela 6.19), nota-se que as edificações B35, B49, B279 e B289 apresentaram os piores resultados, restando áreas maiores que 10 m² ainda não reconstruídas. Os casos das edificações B35, B279 e B289 já foram discutidos anteriormente. O caso da edificação B49 ocorre por perda de parte da área da edificação, causada por uma oclusão na face do telhado voltada para os fundos do prédio, como pode ser verificado na Figura 6.34. Ainda assim, vale destacar que, para a edificação B49 a oclusão passível de ser tratada pelo método, ou seja, a oclusão que ocorreu na parte frontal da edificação, possibilitou a reconstrução de cerca de 12 m². A partir da análise dos erros relativos para o contorno inicial e contorno final, pode-se notar que em todas as edificações as magnitudes dos erros relativos após a aplicação do método proposto foram menores do que quando comparados aos respectivos contornos iniciais. Como já discutido, algumas edificações não tiveram os seus contornos totalmente reconstruídos. Ainda assim, analisando o valor médio do erro no contorno final (-6,42%) e o valor médio do erro no contorno inicial (-13,95%) observa-se que o método proposto contribuiu para a mitigação do erro da área, como esperado.

A fim de avaliar os contornos extraídos foram estimados os valores para a métrica PoLiS, os quais estão apresentados na Tabela 6.20.

Tabela 6.20 – Métrica PoLiS estimada para os contornos originais e após a aplicação do método proposto.

PoLiS (m)					
	Contorno original	Contorno final		Contorno original	Contorno final
B35	0,688	0,637	B265	0,675	0,233
B49	1,051	0,481	B279	0,740	0,715
B61	0,392	0,163	B289	1,296	1,179
B167	0,184	0,160	B299	0,669	0,262
B203	0,393	0,295	B301	0,232	0,219
B252	0,325	0,270	B304	0,664	0,380
			B315	0,284	0,255

Neste caso, ao analisar esta métrica deve-se atentar que quanto menor o seu valor, melhor a adequação entre o contorno extraído e o contorno de referência. Com base nesses valores é possível perceber reduções significativas para as edificações B49, B61, B265, B299 e B304. Em contrapartida as edificações B35, B167, B279, B289, B301 e B315 apresentam reduções de menor magnitude. No entanto, pode-se notar que para todas as edificações analisadas a métrica PoLiS teve ser valor reduzido ao aplicar o método proposto, indicando que houve uma melhoria na determinação do contorno ao aplicar ao método proposto.

Capítulo 7

Conclusões e recomendações

7.1 Síntese do trabalho

Este trabalho abordou a mitigação de contornos oclusos de telhados de edificações por meio da exploração de nuvens de pontos fotogramétricas obtidas a partir de dois pontos de vistas, aéreo e terrestre. Nesse contexto foram exploradas as seguintes questões: Classificação da nuvem, por meio da determinação de atributos adequados e aplicação do classificador *Random Forest*; Detecção de oclusão por meio de análise da relação geométrica entre os contornos dos telhados e os contornos das árvores vizinhas; e Mitigação dos contornos oclusos por meio da integração das nuvens de pontos aérea e terrestre, considerando a delimitação de regiões de busca e a aplicação do algoritmo RANSAC.

Os trabalhos de extração de contornos de telhados têm sido explorados ao longo das últimas décadas, principalmente a partir de nuvem de pontos LiDAR e imagens de alta resolução. Neste trabalho, por outro lado, optou-se por explorar nuvem de pontos fotogramétrica, especificamente as obtidas a partir de RPAS, por estas consistirem em um conjunto de dados relativamente novo e ainda pouco explorado para tal finalidade. Além disso, a mitigação dos contornos oclusos foi realizada por meio da exploração da complementariedade de nuvens fotogramétricas aérea e terrestre. Para tal, a seguinte hipótese foi proposta: *“Os limites de telhados em regiões oclusas, decorrentes da presença de vegetação, podem ser obtidos a partir da integração das nuvens de pontos fotogramétricas aéreas e terrestres e da aplicação de técnicas de modelagem de superfícies”*.

No contexto da classificação da nuvem de pontos aérea foi explorada a extração de atributos radiométricos e geométricos, bem como sua complementariedade para fins de identificação das classes de interesse (telhado e árvores). Na sequência foram propostas duas etapas

de refinamento dos resultados da classificação, uma visando eliminar pontos presentes em regiões caracterizadas por planos verticais, outra visando a eliminação de pontos em regiões de sombra.

Na etapa de segmentação, extração de contornos e detecção de oclusões foram explorados o conceito de crescimento de regiões e o algoritmo α -shape. Para tal, na segmentação foram considerados limiares de distância no plano e vertical, os quais foram definidos empiricamente a partir de medidas de densidade da nuvem de pontos e separação mínima esperada entre as edificações vizinhas. Na extração de contornos foram exploradas duas alternativas de definição do parâmetro α : a primeira considera a estimativa de um valor de α com base na densidade médias do segmento; a segunda considera a aplicação de um valor de α fixo para todos os grupamentos determinados. Por fim, a detecção de oclusão foi realizada a partir de análises das relações geométricas entre os pontos pertencentes aos contornos extraídos das edificações e as regiões de influência das árvores vizinhas.

A etapa final do método consiste na busca por pontos na nuvem de pontos terrestre que complementem as regiões oclusas do ponto de vista aéreo. Nessa etapa foram explorados os conceitos de MOBB e RANSAC para a delimitação da região de busca e para segmentação da edificação nos planos que a compõem e seleção de pontos de interesse. A região de busca foi determinada pela intersecção entre a MOBB de cada plano ocluso e a região de influência da árvore causadora da oclusão.

A metodologia proposta foi aplicada considerando nuvens de pontos fotogramétricas obtidas por RPAS e por sistema de mapeamento móvel. É imprescindível para aplicação do método que ambas as nuvens estejam em um mesmo sistema de referência, sendo que possíveis desalinhamentos entre as nuvens impactarão de forma direta os resultados do método.

7.2 Conclusões

Nesta Seção serão apresentados os pontos positivos e negativos das etapas que compõem o método proposto, bem como as conclusões.

7.2.1 Classificação de nuvem de pontos fotogramétricas em ambiente urbano

A complexidade de ambientes urbanos dificulta a tarefa de identificação dos diferentes objetos que os compõem, principalmente a partir de métodos automáticos. Nesta Tese a

complementariedade de dados radiométricos e geométricos foi explorada para fins de classificação de nuvem de pontos fotogramétrica em ambiente urbano.

Complementariedade dos dados radiométricos e geométricos na classificação:

Pontos positivos:

- a investigação acerca dos atributos geométricos e radiométricos atestou a contribuição de seu uso combinado para fins de classificação de nuvem de pontos fotogramétrica em ambiente urbano. A classificação que explorou o uso combinado dos atributos atingiu valores de acurácia global e índice *Kappa* de 0,98 e 0,98, respectivamente. Esses valores foram significativamente superiores àqueles obtidos para as classificações em que foram explorados apenas os atributos radiométricos, atingindo valores de acurácia global e índice *Kappa* de 0,80 e 0,77, respectivamente. Os resultados foram ainda mais significativos se comparados aos atingidos pela classificação que considerou apenas os atributos geométricos, a qual atingiu valores de acurácia global e índice *Kappa* de 0,74 e 0,68, respectivamente. A complementariedade dos atributos radiométricos e geométricos foi atestada até mesmo para o experimento que considerou apenas o atributo geométrico altura combinado aos radiométricos, no qual obteve-se resultado compatível ao experimento que considerou todos os atributos analisados, atingindo acurácia global e índice *Kappa* de 0,98 e 0,97, respectivamente.

Pontos negativos:

- os atributos geométricos são impactados por ruídos presentes nas nuvens de pontos fotogramétricas; e
- o atributo altura necessita de um processo prévio de filtragem para a extração do modelo digital do terreno.

Refinamento dos resultados da classificação para as classes telhados e árvores:

Pontos positivos:

- a abordagem proposta para eliminação de pontos gerados em região de sombra incorreu na eliminação de pontos nas copas das árvores e pontos espúrios entre edificações vizinhas, contribuindo, por fim, para os processos subsequentes de

segmentação das edificações. Esse refinamento resultou na eliminação de aproximadamente 25% dos pontos classificados como árvores e 8,40% dos pontos classificados como edificação; e

- a abordagem proposta para eliminação de pontos em regiões plano-verticais ajudou na eliminação de pontos espúrios, caracterizados por regiões de alta dispersão. Nesse processo, além dos pontos espúrios, foram eliminados pontos nas fachadas das edificações. Assim como o processo de refinamento de sombra, os resultados contribuíram para a segmentação da nuvem de pontos, facilitando a separabilidade entre as edificações vizinhas.

Pontos negativos:

- ambos os processos necessitam da definição de valores para os limiares aplicados. O limiar para o refinamento de sombra foi explorado no trabalho de Pessoa *et al.* (2019b). O limiar aplicado no refinamento de pontos em região plano-vertical considerou as características geométricas das edificações da área de interesse, sendo definido pelo ângulo máximo de inclinação dos telhados; e
- o refinamento de pontos em região de sombra aplicado sobre os pontos classificados como árvores incorreu na perda de informação, afetando o processo de segmentação.

7.2.2 Detecção de regiões de oclusão em edificações, causadas por árvores

Segmentação da nuvem de pontos aérea:

Pontos positivos:

- A aplicação do algoritmo de *Region Growing* (RG) considerando 2 limiares para a separação dos aglomerados referentes às edificações atingiu resultados satisfatório, potencializados pela aplicação das abordagens de refinamento dos resultados da classificação.

Pontos negativos:

- ainda que o RG tenha obtido resultados satisfatórios, algumas edificações contíguas não puderam ser segmentadas de forma automática, sendo necessário intervenções manuais. Deste modo, pode-se considerar que em ambientes onde a

descontinuidade entre as edificações contíguas não é percebida, o método apresenta limitação.

Deteccção de contornos iniciais:

Nessa etapa foi utilizado o algoritmo α -shape considerando duas abordagens para estimativa do parâmetro α , α fixo e α variante com base na densidade média do segmento da edificação sob análise.

Pontos positivos:

- Ambas as abordagens foram capazes de extrair o contorno externo da edificação. No entanto, a abordagem que considera o α fixo se mostrou mais adequada para os dados explorados nesta Tese;
- A alta densidade da nuvem de pontos aérea explorada permitiu a utilização de um valor de α fixo igual a 0,5 m. Tal valor permite a extração de detalhes e reentrâncias dos telhados e ao mesmo tempo tem baixa ocorrência de geração de contornos internos inexistentes. Nesse caso, os efeitos da variação de densidade da nuvem de pontos ao longo das edificações não foram suficientes para prejudicar os resultados da abordagem que considerou α fixo.

Pontos negativos:

- Os testes apontaram para diferentes valores de α devido a variações bruscas de densidade da nuvem de pontos, sendo a média e desvio-padrão para os valores de α estimados igual a 0,402 m e 0,342 m, respectivamente. Assim, a aplicação da abordagem que considera α variante se mostrou inviável para os dados utilizados nesta Tese.

Deteccção de oclusão:

Foram testados diferentes valores de *buffer* para a deteção de oclusões a partir da análise da relação geométrica entre os pontos de contorno das edificações e das árvores. A aplicação do *buffer* teve como objetivo contornar possíveis perdas de informação nas regiões de transição entre a copa da árvore e os telhados das edificações.

Pontos positivos:

-
- foi possível detectar as oclusões com nível de acerto e completeza na ordem de 0,731 e 0,936, respectivamente. Destaca-se que, para trabalhos de detecção de oclusão a completeza deve ser priorizada em detrimento do nível de acerto, visto que falsas detecções geram menos prejuízos; e
 - o *buffer* da árvore utilizado no processo de detecção pôde ser utilizado nas etapas subsequentes para a delimitação da região de busca visando a mitigação dos contornos oclusos.

Pontos negativos:

- os valores de *buffer* são determinados empiricamente. Para tal, pode-se considerar o espaçamento médio dos pontos da nuvem como critério de seleção; e
- o método não é capaz de detectar toda a região de uma determinada oclusão. Esse efeito é resultado da perda de informação na região de transição entre a copa da árvore e o telhado das edificações.

7.2.3 Uso combinado de nuvens de pontos para a extração dos contornos oclusos

Extração de planos:

Pontos positivos:

- a técnica RANSAC foi capaz de extrair todos os planos dos telhados das edificações, com exceção daqueles em que a quantidade de pontos não foi suficiente para caracterização de sua geometria; e
- os parâmetros dos planos ajustados são úteis para o processo subsequente de seleção de pontos de interesse para a reconstrução dos contornos oclusos.

Definição da região de busca e seleção dos pontos na nuvem terrestre:

Pontos positivos:

- a MOBB se mostrou adequada na etapa da delimitação da região de interesse, juntamente com a região de influência da árvore. As duas regiões, quando utilizadas em conjunto, limitaram adequadamente a região de busca, auxiliando a seleção de pontos de interesse;

-
- o processo de busca por pontos de interesse foi capaz de lidar com grande quantidade de dados. A quantidade de dados é crítica devido à alta densidade da nuvem de pontos terrestre, em média 1000 p/m² no caso dos dados utilizados; e
 - a seleção de pontos com base na pertinência aos planos das faces dos telhados possibilitou a reconstrução das regiões de oclusão.

Pontos negativos:

- a MOBB é afetada quando há perdas significativas de parte da edificação; e
- oclusões que afetam toda a face de um telhado, impossibilitando a extração do plano que a define, não podem ser tratadas pelo método.

Extração do contorno final:

Pontos positivos:

- o método foi capaz de reconstruir áreas oclusas de diferentes dimensões, atingindo ganho relativo médio de completeza na ordem de 10%. Além disso, para algumas edificações os valores de ganho relativo de completeza foram superiores a 20%;
- no que se refere a áreas reconstruídas após a aplicação do método, destaca-se as superiores a 20 m², podendo estas serem consideradas oclusões de grandes dimensões; e
- a extração de contornos foi capaz de lidar com as diferentes densidades das duas nuvens de pontos, mesmo para o caso em que a área reconstruída apresentava grandes vazios de pontos.

Pontos negativos:

- o método é limitado à reconstrução de oclusões mais próximas às fachadas, visto que as oclusões mais afastadas são de difícil visualização; e
- as nuvens de pontos fotogramétricas terrestres apresentam ruídos nas regiões de sombra e homogêneas, características frequentes nas regiões de oclusão.

7.3 Recomendações

Como recomendações para trabalhos futuros, sugere-se:

-
- aplicar o método proposto considerando nuvem terrestre oriunda de Sistemas de Varredura LASER;
 - testar a complementaridade dos dados radiométricos e geométricos sobre dados LiDAR aerotransportado;
 - explorar técnicas de correção das nuvens de forma automatizada, possibilitando assim, maior flexibilidade para o método. Para tal, pode-se explorar processos para seleção de pontos de interesse que auxiliem o registro; e
 - realizar o refinamento dos contornos obtidos pelo algoritmo α -shape a partir da combinação destes com contornos extraídos sobre imagens aéreas, por exemplo.

REFERÊNCIAS

- AASEN, H.; BUKART, A.; BOLTEN, A.; BARETH, G. Generating 3D hyperspectral information with lightweight UAV snapshot cameras for vegetation monitoring: From camera calibration to quality assurance. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 108, p. 245–259, 2015.
- ABDOLLAHI, A.; PRADHAN, B.; GITE, S.; ALAMRI, A. Building footprint extraction from high resolution aerial images using generative adversarial network (GAN) architecture. **IEEE Access**, v. 8, p. 209517–209527, 2020.
- ACAR, H.; KARSLI, F.; OZTURK, M.; DIHKAN, M. Automatic detection of building roofs from point clouds produced by the dense image matching technique. **International Journal of Remote Sensing**, v. 40(1), p. 138-155, 2019.
- ALI-SISTO, D.; PACKALEN, P. Forest Change Detection by Using Point Clouds From Dense Image Matching Together With a LiDAR-Derived Terrain Model. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 10, n. 3, p. 1197–1206, 2017.
- ALSHAWA, M. ICL: Iterative closest line A novel point cloud registration algorithm based on linear features. **Ekscentar**, n. 10, p. 53–59, 2007.
- AVBELJ, J.; MÜLLER, R.; BAMLER, R. A Metric for Polygon Comparison and Building Extraction Evaluation. **IEEE Geoscience and Remote Sensing Letters**, v. 12, n. 1, p. 170–174, 2015.
- AWRANGJEB, M.; FRASER, C. S.; GUOJUN LUA. Integration of lidar data and orthoimage for automatic 3D building roof plane extraction. **IEEE International Conference on Multimedia and Expo (ICME)**, San Jose, CA, USA: IEEE, jul. 2013. Disponível em: <<http://ieeexplore.ieee.org/document/6607612/>>. Acesso em: 30 abr. 2021
- AWRANGJEB, M.; FRASER, C. S.; LU, G. Building change detection from LiDAR point cloud data based on connected component analysis. **ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. II-3/W5, p. 393–400, 2015.
- AWRANGJEB, M.; RAVANBAKHS, M.; FRASER, C. S. Automatic detection of residential buildings using LIDAR data and multispectral imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, n. 5, p. 457–467, 2010.

AWRANGJEB, M.; ZHANG, C.; FRASER, C. S. Automatic Reconstruction of Building Roofs Using LIDAR and Multispectral Imagery. **International Conference on Digital Image Computing: Techniques and Applications**, Noosa, QLD, Australia: IEEE, dez. 2011. Disponível em: <<http://ieeexplore.ieee.org/document/6128643/>>. Acesso em: 30 abr. 2021.

_____. Automatic extraction of building roofs using LIDAR data and multispectral imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 83, p. 1–18, 2013.

AXELSSON, P. DEM generation from laser scanner data using adaptive TIN models. **International archives of photogrammetry and remote sensing**, v. 33, n. 4, p. 110–117, 2000.

BALTSAVIAS, E. P. A comparison between photogrammetry and laser scanning. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, n. 2–3, p. 83–94, 1999a.

_____. Airborne laser scanning: basic relations and formulas. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, n. 2–3, p. 199–214, 1999b.

BAREQUET, G.; HAR-PELED, S. Efficiently Approximating the Minimum-Volume Bounding Box of a Point Set in Three Dimensions. **Journal of Algorithms**, v. 38, n. 1, p. 91–109, 2001.

BEHMANN, J.; MAHLEIN, A. K.; RUMPF, T.; ROMER, C.; PLUMER, L. A review of advanced machine learning methods for the detection of biotic stress in precision crop protection. **Precision Agriculture**, v. 16, n. 3, p. 239–260, 2015.

BERTAN, E.; GOKMEN, M.; MOREAU, G. Automatic 3D Roof Reconstruction using Digital Cadastral Map, Architectural Knowledge and an Aerial Image. **IEEE International Symposium on Geoscience and Remote Sensing**, Denver, CO, USA: IEEE, jul. 2006. Disponível em: <<http://ieeexplore.ieee.org/document/4241512/>>. Acesso em: 30 abr. 2021.

BESL, P. J.; MCKAY, N. D. **Method for registration of 3-D shapes** (P. S. Schenker, Ed.). Em: **ROBOTICS – DL TENTATIVE**. Boston, MA: 30 abr. 1992. Disponível em: <<http://proceedings.spiedigitallibrary.org/proceeding.aspx?articleid=981454>>. Acesso em: 30 abr. 2021.

BITELLI, G.; DUBBINI, M.; ZANUTTA, A. Terrestrial laser scanning and digital photogrammetry techniques to monitor landslide bodies. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 35, n. B5, p. 246–251, 2004.

BLAIS, F. Review of 20 years of range sensor development. **Journal of Electronic Imaging**, v. 13, n. 1, p. 231, 2004.

BRASIL, P. DA R. **Decreto no 8.764 de 10 de maio de 2016**. Institui o Sistema Nacional de Gestão de Informações Territoriais e regulamenta o disposto no art. 41 da Lei no 11.977, de 7 de julho de 2009. Brasília. 2016.

BREIMAN, L. Some properties of splitting criteria. **Machine Learning**, v. 24, n. 1, p. 41–47, 1996.

CARRILHO, A, C. **Extração e refinamento de contornos de telhados utilizando descritores geométricos e integração de dados LiDAR e imagens aéreas**. 2021. Tese (Doutorado em Ciências Cartográficas) - Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente.

CHAMPION, N.; ROTTEINSTEINER, F.; MATIKAINEN, L.; LIANG, X.; HYYPPA, J.; OLSEN, B. P. A test of automatic building change detection approaches. **Proceedings of CMRT09**, p. 03–04, 2009.

CHAN, C.; TAN, S. Determination of the minimum bounding box of an arbitrary solid: an iterative approach. **Computers & Structures**, v. 79, n. 15, p. 1433–1449, 2001.

CHEN, C.; GAO, Y.; LI, Y. A feature-preserving point cloud denoising algorithm for LiDAR-derived DEM construction. **Survey Review**, v. 53, n. 377, p. 146–157, 2021.

CHEN, F.; SONG, M.; BROWN, G. Overview of three-dimensional shape measurement using optical methods. **Optical Engineering**, v. 39, n. 1, p. 10, 2000.

CHEN, Y.; CHENG, L.; LI, M.; WANG, J.; TONG, L.; YANG, K. Multiscale Grid Method for Detection and Reconstruction of Building Roofs from Airborne LiDAR Data. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 7, n. 10, p. 4081–4094, 2014.

CHLINGARYAN, A.; SUKKARIEH, S.; WHELAN, B. Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture: A review. **Computers and Electronics in Agriculture**, v. 151, p. 61–69, ago. 2018.

CHOMA, A.; RATCLIFF, C.; FRISINA, R. Evaluation of remote sensing technologies for high-resolution terrain mapping. **Proceedings of SSC 2005**, p. 751-760, 2005.

COLOMINA, I.; MOLINA, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. **ISPRS Journal of photogrammetry and remote sensing**, v. 92, p. 79–97, 2014.

CROCE, V.; CAROTI, G.; DE LUCA, L.; JACQUOT, K.; PIEMONTE, A.; VÉRON, P. From the semantic point cloud to heritage-building information modeling: A semiautomatic approach exploiting machine learning. **Remote Sensing**, v. 13, n. 3, p. 461, 2021.

DEMANTKÉ, J.; MALLET, C.; DAVID, N.; VALLET, B. Dimensionality based scale selection in 3D lidar point clouds. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 38, n. 5, p. W12, 2011.

FENG, M., ZHANG, T.; LI, S.; JIN, G.; XIA, Y. An improved minimum bounding rectangle algorithm for regularized building boundary extraction from aerial LiDAR point clouds with partial occlusions. **International Journal of Remote Sensing**, v. 41, n. 1, p. 300–319, 2020.

FERNANDES, V. J. M.; DAL POZ, A. P. A Markov-Random-Field Approach for Extracting Straight-Line Segments of Roofs From High-Resolution Aerial Images. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 9, n. 12, p. 5493–5505, 2016.

FILIPPELLI, S. K.; LEFSKY, M. A.; ROCCA, M. E. Comparison and integration of lidar and photogrammetric point clouds for mapping pre-fire forest structure. **Remote Sensing of Environment**, v. 224, p. 154–166, 2019.

FÖRSTNER, W.; GÜLCH, E. A fast operator for detection and precise location of distinct points, corners and centres of circular features. **Proc. ISPRS Intercommission Conference on Fast Processing of Photogrammetric Data**, Interlaken, 1987.

FRASER, C. S. Digital camera self-calibration. **ISPRS Journal of Photogrammetry and Remote sensing**, v. 52, n. 4, p. 149–159, 1997.

FRASER, C. S.; CRONK, S. A hybrid measurement approach for close-range photogrammetry. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 64, n. 3, p. 328–333, 2009.

GALO, M.; TOMMASELLI, A. M. G. **Calibração de Câmaras**, In: PITERI, M. A.; RODRIGUES, J. C. (Eds), Fundamentos de Visão Computacional, Presidente Prudente, pp. 53–112, 2011.

GAO, L.; ZHAO, Y.; HAN, J.; LIU, H. Research on Multi-View 3D Reconstruction Technology Based on SFM. **Sensors**, v. 22, n. 12, p. 4366, 2022.

GILANI, S. A. N.; AWRANGJEB, M.; LU, G. Fusion of lidar data and multispectral imagery for effective building detection based on graph and connected component analysis. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XL-3/W2, p. 65–72, 2015.

GILANI, S. A. N.; AWRANGJEB, M.; LU, G. Robust building roof segmentation using airborne point cloud data. **IEEE International Conference on Image Processing (ICIP)**. Anais...Phoenix, AZ, USA: IEEE, set. 2016. Disponível em: <<http://ieeexplore.ieee.org/document/7532479/>>. Acesso em: 30 abr. 2021.

GUERRA-HERNÁNDEZ, J. COSENZA, D. N.; RODRIGUEZ, L. C. E.; SILVA, M.; TOMÉ, M.; DÍAZ-VARELA, R. A.; GONZÁLEZ-FERREIRO, E. Comparison of ALS-and UAV (SfM)-derived high-density point clouds for individual tree detection in Eucalyptus plantations. **International Journal of Remote Sensing**, v. 39, n. 15–16, p. 5211–5235, 2018.

GUMHOLD, S.; WANG, X.; MACLEOD, R. S. Feature extraction from point clouds. **Proceedings of 10th International Meshing Roundtable (IMR 2001)**, p. 293-305, 2001.

HAALA, N.; KADA, M. An update on automatic 3D building reconstruction. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, n. 6, p. 570–580, 2010.

HABIB, A. F.; KERSTING, A. P.; RUIFANG, Z.; AL-DURGHAM, M.; KIM, C.; LEE, D. C. LiDAR strip adjustment using conjugate linear features in overlapping strips. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, p. 385–390, 2008.

HABIB, A. F.; BANG, K. I.; KERSTING, A. P.; CHOW, J. Alternative Methodologies for LiDAR System Calibration. **Remote Sensing**, v. 2, n. 3, p. 874–907, 2010.

HABIB, A.; MORGAN, M. Stability Analysis and Geometric Calibration of Off-the-Shelf Digital Cameras. **Photogrammetric Engineering & Remote Sensing**, v. 71, n. 6, p. 733–741, 2005.

HARRIS, C.; STEPHENS, M. A combined corner and edge detector. **Proceedings of the 4th Alvey Vision Conference (AVC88)**, Manchester, p. 147-151, 1988.

HARTFIELD, K. A.; LANDAU, K. I.; LEEUWEN, W. J. D. VAN. Fusion of High Resolution Aerial Multispectral and LiDAR Data: Land Cover in the Context of Urban Mosquito Habitat. **Remote Sensing**, v. 3, n. 11, p. 2364–2383, 2011.

HERMOSILLA, T.; RUIZ, L. A.; RECIO, J. A.; ESTORNELL, J. Evaluation of Automatic Building Detection Approaches Combining High Resolution Images and LiDAR Data. **Remote Sensing**, v. 3, n. 6, p. 1188–1210, 2011.

HIRSCHMULLER, H. Accurate and Efficient Stereo Processing by Semi-Global Matching and Mutual Information. **IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)**. Anais...San Diego, CA, USA: IEEE, 2005. Disponível em: <<http://ieeexplore.ieee.org/document/1467526/>>. Acesso em: 30 abr. 2021.

____. Stereo Processing by Semiglobal Matching and Mutual Information. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 30, n. 2, p. 328–341, 2008.

IQBAL, I. A.; OSBORN, J.; STONE, C.; LUCIEER, A. A comparison of ALS and dense photogrammetric point clouds for individual tree detection in radiata pine plantations. **Remote Sensing**, v. 13, n. 17, p. 3536, 2021.

ISENBURG, M. **LAStools—efficient LiDAR processing software**, version 141017, unlicensed. [s.l: s.n.].

JIN, X.; DAVIS, C. H. Automated Building Extraction from High-Resolution Satellite Imagery in Urban Areas Using Structural, Contextual, and Spectral Information. **EURASIP Journal on Advances in Signal Processing**, v. 2005, n. 14, p. 745309, 2005.

KORANNE, S. Boost C++ Libraries. Em: KORANNE, S. (Ed.). **Handbook of Open Source Tools**. Boston, MA: Springer US, 2011. p. 127–143.

LAI, X.; YANG, J.; LI, Y.; WANG, M. A building extraction approach based on the fusion of LiDAR point cloud and elevation map texture features. **Remote Sensing**, v. 11, n. 14, p. 1636, 2019.

LARY, D. J.; ALAVI, A. H.; GANDOMI, A. H.; WALKER, A. L. Machine learning in geosciences and remote sensing. **Geoscience Frontiers**, v. 7, n. 1, p. 3–10, 2016.

LEBERL, F.; IRSCHARA, A.; POCK, T.; MEIXNER, P.; GRUBER, M.; SCHOLZ, S.; WIECHERT, A. Point Clouds. **Photogrammetric Engineering & Remote Sensing**, v. 76, n. 10, p. 1123–1134, 2010.

LHUILIER, M.; QUAN, L. A quasi-dense approach to surface reconstruction from uncalibrated images. **IEEE transactions on pattern analysis and machine intelligence**, v. 27, n. 3, p. 418–433, 2005.

LI, Y.; WU, B. Relation-constrained 3D reconstruction of buildings in metropolitan areas from photogrammetric point clouds. **Remote Sensing**, v. 13, n. 1, p. 129, 2021.

LI, J.; ZHUANG, Y.; DONG, S.; GAO, P.; DONG, H.; CHEN, H.; CHEN, L.; Li, L. Hierarchical Disentangling Network for Building Extraction from Very High Resolution Optical Remote Sensing Imagery. **Remote Sensing**, v. 14, n. 7, p. 1767, 2022

LIN, J.; JING, W.; SONG, H.; CHEN, G. ESFNet: Efficient network for building extraction from high-resolution aerial images. **IEEE Access**, v. 7, p. 54285–54294, 2019.

LIU, Y.; ZHANG, Z.; ZHONG, R.; CHEN, D.; KE, Y.; PEETHAMBARAN, J.; CHEN, C.; SUN, L. Multilevel building detection framework in remote sensing images based on convolutional neural networks. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 11, n. 10, p. 3688–3700, 2018.

LIU, Y.; ZHOU, J.; QI, W.; LI, X.; GROSS, L.; SHAO, Q.; ZHAO, Z.; NI, L.; FAN, X.; LI, Z. ARC-Net: An efficient network for building extraction from high-resolution aerial images. **IEEE Access**, v. 8, p. 154997–155010, 2020.

LOWE, D. G. Distinctive Image Features from Scale-Invariant Keypoints. **International Journal of Computer Vision**, v. 60, n. 2, p. 91–110, 2004.

MAHPHOOD, A.; AREFI, H. Virtual first and last pulse method for building detection from dense LiDAR point clouds. **International Journal of Remote Sensing**, v. 41, n. 3, p. 1067–1092, 2020.

MALPICA, J. A.; ALONSO, M. C.; PAPÍ, F.; AROZARENA, A.; MATÍNEZ DE AGIRRE, A. Change detection of buildings from satellite imagery and lidar data. **International Journal of Remote Sensing**, v. 34, n. 5, p. 1652–1675, 2013.

MAN, Q.; DONG, P.; GUO, H. Pixel- and feature-level fusion of hyperspectral and lidar data for urban land-use classification. **International Journal of Remote Sensing**, v. 36, n. 6, p. 1618–1644, 2015.

MATAS, J.; CHUM, O.; URBAN, M.; PAJDLA, T. Robust wide-baseline stereo from maximally stable extremal regions. **Image and Vision Computing**, v. 22, n. 10, p. 761–767, 2004.

MATTHEWS, N. A. **Aerial and close-range photogrammetric technology: providing resource documentation, interpretation, and preservation**. [s.l.] US Department of the Interior, Bureau of Land Management, National ..., 2008.

MAYER, H. Automatic Object Extraction from Aerial Imagery—A Survey Focusing on Buildings. **Computer Vision and Image Understanding**, v. 74, n. 2, p. 138–149, 1999.

MENG, X.; CURRIT, N.; WANG, L.; YANG, X. Detect Residential Buildings from Lidar and Aerial Photographs through Object-Oriented Land-Use Classification. **Photogrammetric Engineering & Remote Sensing**, v. 78, n. 1, p. 35–44, 2012.

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

MIKOLAJCZYK, K.; TUYTELAARS, T.; SCHMID, C.; ZISSERMAN, A.; MATAS, J.; SCHAFFALITZKY, F.; KADIR, T.; GOOL, L. V. A Comparison of Affine Region Detectors. **International Journal of Computer Vision**, v. 65, n. 1–2, p. 43–72, 2005.

MIKOLAJCZYK, K.; SCHMID, C. Scale & Affine Invariant Interest Point Detectors. **International Journal of Computer Vision**, v. 60, n. 1, p. 63–86, 2004.

MIKOLAJCZYK, K.; SCHMID, C. An affine invariant interest point detector. **European conference on computer vision**. Anais...Springer, 2002.

MORAVEC, H. P. Techniques towards automatic visual obstacle avoidance. In: **Proceedings of the 5th Int. Joint Conference on Artificial Intelligence**. Cambridge, August, 1977. p. 584.

MOYANO, J.; NIETO-JULIÁN, J. E.; LENIN, L. M.; BRUNO, S. Operability of point cloud data in an architectural heritage information model. **International Journal of Architectural Heritage**, p. 1–20, 2021.

MUJA, M.; LOWE, D. **Flann-fast library for approximate nearest neighbors user manual**. Computer Science Department, University of British Columbia, Vancouver, BC, Canada, v. 5, 2009.

NÄSI, R.; HONKAVAARA, E.; BLOMQVIST, M.; LYYTIKAINEN-SAARENMAA, P.; HAKALA, T.; VILJANEN, N.; KANTOLA, T.; HOLOPAINEN, M. Remote sensing of bark beetle damage in urban forests at individual tree level using a novel hyperspectral camera from UAV and aircraft. **Urban Forestry & Urban Greening**, v. 30, p. 72–83, 2018.

NEX, F.; REMONDINO, F. UAV for 3D mapping applications: a review. **Applied geomatics**, v. 6, n. 1, p. 1–15, 2014.

NGUYEN, A.; LE, B. 3D point cloud segmentation: A survey. **6th IEEE Conference on Robotics, Automation and Mechatronics (RAM)**. Anais...Manila, Philippines: IEEE, nov. 2013. Disponível em: <<http://ieeexplore.ieee.org/document/6758588/>>. Acesso em: 26 nov. 2021.

OJOGBANE, S. S.; MANSOR, S.; KALANTAR, B.; KHUZAIMAH, Z. B.; SHAFRI, H. Z. M.; UEDA, N. Automated Building Detection from Airborne LiDAR and Very High-Resolution Aerial Imagery with Deep Neural Network. **Remote Sensing**, v. 13, n. 23, p. 4803, 2021.

PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V. Scikit-learn: Machine learning in Python. **Journal of machine Learning research**, v. 12, p. 2825–2830, 2011.

PESSOA, G. G.; AMORIM, A.; GALO, M.; GALO, M. DE L. B. T. Photogrammetric point cloud classification based on geometric and radiometric data integration. **Boletim de Ciências Geodésicas**, v. 25 (SPE), 2019a.

PESSOA, G. G.; SANTOS, R. C.; CARRILHO, A. C.; GALO, M.; AMORIM, A. Urban scene classification using features extracted from photogrammetric point clouds acquired by UAV. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XLII-2/W13, p. 511–518, 2019b.

PFEIFER, N.; KÖSTLI, A.; KRAUS, K. Interpolation and filtering of laser scanner data-implementation and first results. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 32, p. 153–159, 1998.

RAU, J.-Y.; JHAN, J.-P.; HSU, Y.-C. Analysis of Oblique Aerial Images for Land Cover and Point Cloud Classification in an Urban Environment. **IEEE Transactions on Geoscience and Remote Sensing**, v. 53, n. 3, p. 1304–1319, 2015.

RAUSCH, C.; HAAS, C. Automated shape and pose updating of building information model elements from 3D point clouds. **Automation in Construction**, v. 124, p. 103561, 2021.

REMONDINO, F. From point cloud to surface: the modeling and visualization problem. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XXXIV-5/W10, 11p., 2003.

REMONDINO, F.; EL-HAKIM, S. Image-based 3D Modelling: A Review: Image-based 3D modelling: a review. **The Photogrammetric Record**, v. 21, n. 115, p. 269–291, 2006.

SANTOS, R. C. **Extração e regularização de contornos de tralhados de edificações a partir de dados LiDAR usando o algoritmo alpha-shape e cd-spline**. 2019. Tese (Doutorado em Ciências Cartográficas) – Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente.

SANTOS, R. C. DOS; PESSOA, G. G.; CARRILHO, A. C.; GALO, M. Automatic Building Boundary Extraction From Airborne LiDAR Data Robust to Density Variation. **IEEE Geoscience and Remote Sensing Letters**, v. 19, p. 1–5, 2020.

SANTOS, R. C. DOS; GALO, M.; CARRILHO, A. C. Extraction of building roof boundaries from LiDAR data using an adaptive alpha-shape algorithm. **IEEE Geoscience and Remote Sensing Letters**, v. 16, n. 8, p. 1289–1293, 2019.

SANTOS, R.; GALO, M.; CARRILHO, A. Building boundary extraction from LIDAR data using a local estimated parameter for alpha shape algorithm. **International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences**, v. 42, n. 1, 2018.

SANTOS, R. C. DOS; HABIB, A. F.; GALO, M. Weighted Iterative CD-Spline for Mitigating Occlusion Effects on Building Boundary Regularization Using Airborne LiDAR Data. **Sensors**, v. 22, n. 17, p. 6440, 2022.

SCHONBERGER, J. L.; FRAHM, J.-M. Structure-from-motion revisited. **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**, Las Vegas, NV, USA, p. 4104-4413, 2016

SENSEFLY. **User Manual S110 RGB/NIR/RE Camera**. 2014. Disponível em: [http://94.177.201.161/documentUAV/camera%20manual/\[ENG\]_2014_user_manual_s110_v3.pdf](http://94.177.201.161/documentUAV/camera%20manual/[ENG]_2014_user_manual_s110_v3.pdf). Acesso em: 20 ago. 2022.

SENSORMAP. **Sensormap ficha técnica SMM**. 2015. Disponível em: <http://www.sensormap.com.br/wp-content/uploads/2015/10/Sensormap-Ficha-T%C3%A9cnica-SMM.pdf>. Acesso em: 20 ago. 2022.

SHAN, J.; TOTH, C. K. **Topographic laser ranging and scanning: principles and processing**. Second edition ed. Boca Raton: Taylor & Francis, CRC Press, 2018.

SINGH, K. K.; VOGLER, J. B.; SHOEMAKER, D. A.; MEENTEMEYER, R. K. LiDAR-Landsat data fusion for large-area assessment of urban land cover: Balancing spatial resolution, data volume and mapping accuracy. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 74, p. 110–121, 2012.

SITHOLE, G. Filtering of laser altimetry data using a slope adaptive filter. **International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences**, v. XXXIV-3/W4, Annapolis, MD, p. 203-210, 2001.

SITHOLE, G.; VOSSELMAN, G. Experimental comparison of filter algorithms for bare-Earth extraction from airborne laser scanning point clouds. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 59, n. 1–2, p. 85–101, 2004.

SOHN, G.; DOWMAN, I. Data fusion of high-resolution satellite imagery and LiDAR data for automatic building extraction. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 62, n. 1, p. 43–63, 2007.

SOKOLOVA, M.; JAPKOWICZ, N.; SZPAKOWICZ, S. Beyond Accuracy, F-Score and ROC: A Family of Discriminant Measures for Performance Evaluation. In: SATTAR, A.; KANG, B. (Eds.).

AI 2006: Advances in Artificial Intelligence. Berlin, Heidelberg: Springer Berlin Heidelberg, 2006. v. 4304p. 1015–1021.

SOTOODEH, S. Outlier detection in laser scanner point clouds. **International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences**, Vol. XXXVI, Part 5, Dresden 25-27 Setembro, 2006.

SOUZA, G. H. B. DE; AMORIM, A. Parcelas espaciais e nuvem de pontos: viabilidade e possibilidades de integração de dados para o cadastro 3D. **Revista Brasileira de Cartografia**, v. 67, n. 2, 2015.

ULLO, S. L.; ZARRO, C.; WOJTOWICZ, K.; MEOLI, G.; FOCARETA, M. LiDAR-based system and optical VHR data for building detection and mapping. **Sensors**, v. 20, n. 5, p. 1285, 2020.

VENEZIANO, D.; HALLMARK, S.; SOULEYRETTE, R. **Comparison of lidar and conventional mapping methods for highway corridor studies.** Final Report, Center for Transportation Research and Education (CTRE), Iowa State University, Outubro, 2002.

VOSSelman, G.; MAAS, H.-G. (EDS.). **Airborne and terrestrial laser scanning.** Dunbeath: Whittles Publishing, 2010.

WALLACE, L.; LUCIEER, A.; MALENOVSKY, Z.; TURNER, D.; VOPENKA, P. Assessment of forest structure using two UAV techniques: A comparison of airborne laser scanning and structure from motion (SfM) point clouds. **Forests**, v. 7, n. 3, p. 62, 2016.

WANG, J.; SHAN, J. Segmentation of LiDAR point clouds for building extraction. **American Society for Photogramm. Remote Sens. Annual Conference**, Baltimore, MD. Anais...2009

WANG, S.; GOU, Q.; SUN, M. Simple Building Reconstruction from Lidar Data and Aerial Imagery. **2nd International Conference on Remote Sensing, Environment and Transportation Engineering.** Anais...Nanjing, Jiangsu, China: IEEE, jun. 2012. Disponível em: <<http://ieeexplore.ieee.org/document/6260726/>>. Acesso em: 30 abr. 2021.

WANG, Y. AUTOMATIC EXTRACTION OF BUILDING OUTLINE FROM HIGH RESOLUTION AERIAL IMAGERY. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 3, 2016.

WEHR, A.; LOHR, U. Airborne laser scanning - an introduction and overview. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, n. 2–3, p. 68–82, 1999.

WEINMANN, M.; JUTZI, B.; HINZ, S.; MALLET, C. Semantic point cloud interpretation based on optimal neighborhoods, relevant features and efficient classifiers. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 105, p. 286–304, 2015.

WEINMANN, M. JUTZI, B.; MALLET, C.; WIRNMANN, M. Geometric features and their relevance for 3D point cloud classification. **ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. IV-1/W1, p. 157–164, 2017.

WIEDEMANN, C.; HEIPKE, C.; MAYER, H.; JAMET, O. Empirical evaluation of automatically extracted road axes. In: **Empirical evaluation techniques in computer vision**. [s.l.] Citeseer, 1998. v. 12p. 172–187.

XIONG, B.; ELBERINK, S. O.; VOSSELMAN, G. Building modeling from noisy photogrammetric point clouds. **ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 2, n. 3, p. 197, 2014.

XU, J.; WAN, Y.; YAO, F. A Method of 3D Building Boundary Extraction from Airborne LIDAR Points Cloud. **Symposium on Photonics and Optoelectronics**. Anais...Chengdu, China: IEEE, jun. 2010. Disponível em: <<https://ieeexplore.ieee.org/document/5504457/>>. Acesso em: 30 abr. 2021.

XU, Y.; STILLA, U. Toward building and civil infrastructure reconstruction from point clouds: A review on data and key techniques. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 14, p. 2857–2885, 2021.

YAN, W. Y. Scan line void filling of airborne LiDAR point clouds for hydroflattening DEM. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 14, p. 6426–6437, 2021.

YWATA, M. S. Y.; DAL POZ, A. P.; SHIMABUKURO, M. H.; & OLIVEIRA, H. C. Snake-based model for automatic roof boundary extraction in the object space integrating a high-resolution aerial images stereo pair and 3D roof models. **Remote Sensing**, v. 13, n. 8, p. 1429, 2021.

YU, Y.; LIU, X.; BUCKLES, B. P. A Residential Building Reconstruction Method and Its Evaluation. **12th International Conference on Computer-Aided Design and Computer Graphics**. Anais...Jinan, Colombia: IEEE, set. 2011. Disponível em: <<http://ieeexplore.ieee.org/document/6062832/>>. Acesso em: 30 abr. 2021.

ZHANG, J.; LIN, X. Filtering airborne LiDAR data by embedding smoothness-constrained segmentation in progressive TIN densification. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 81, p. 44–59, 2013.

____. Advances in fusion of optical imagery and LiDAR point cloud applied to photogrammetry and remote sensing. **International Journal of Image and Data Fusion**, v. 8, n. 1, p. 1–31, 2017.