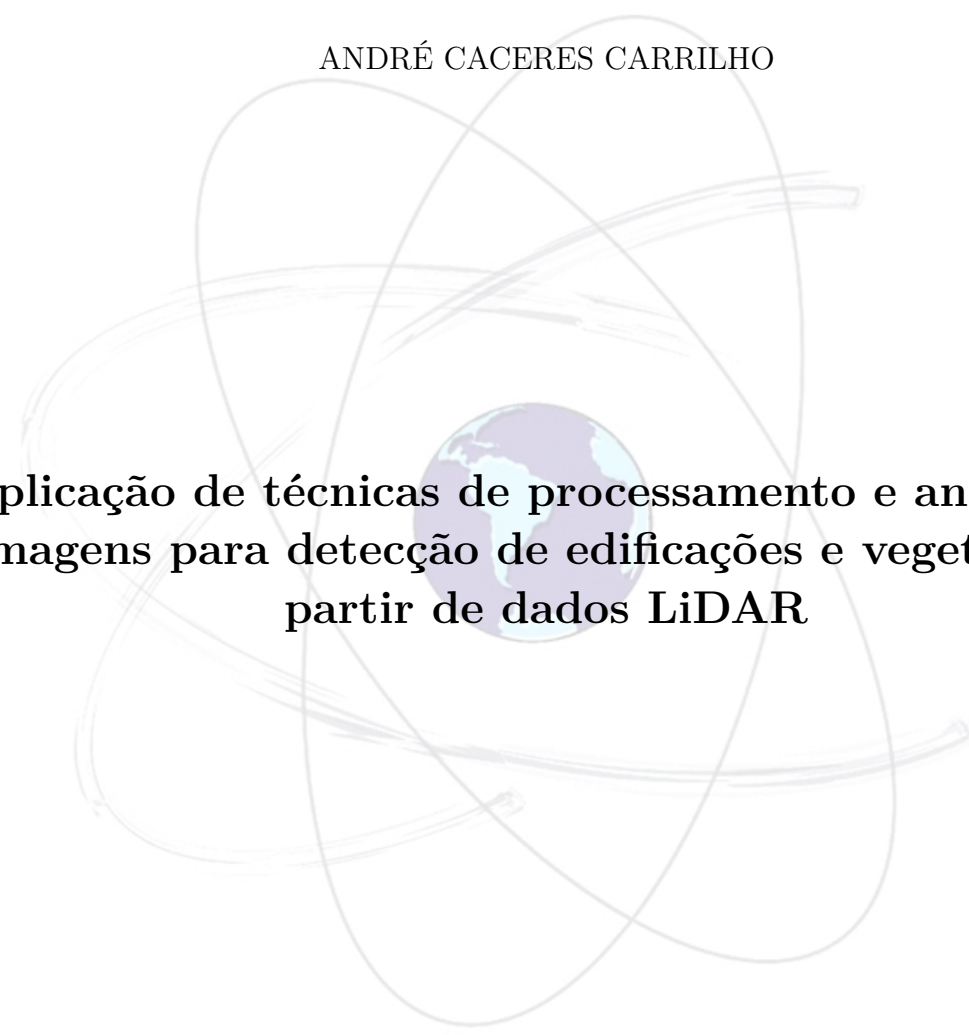




UNIVERSIDADE ESTADUAL PAULISTA "JÚLIO DE MESQUITA FILHO"
Programa de Pós Graduação em Ciências Cartográficas
Campus de Presidente Prudente

ANDRÉ CACERES CARRILHO

A faint, light blue graphic in the background features a central globe with several overlapping, hand-drawn style orbital or elliptical lines around it, suggesting a theme of global navigation or data processing.

**Aplicação de técnicas de processamento e análise de
imagens para detecção de edificações e vegetação a
partir de dados LiDAR**

PRESIDENTE PRUDENTE
2016

UNIVERSIDADE ESTADUAL PAULISTA "JÚLIO DE MESQUITA FILHO"
Programa de Pós Graduação em Ciências Cartográficas
Campus de Presidente Prudente

ANDRÉ CACERES CARRILHO

**Aplicação de técnicas de processamento e análise de
imagens para detecção de edificações e vegetação a
partir de dados LiDAR**

Dissertação apresentada ao Programa de Pós
Graduação em Ciências Cartográficas da Fa-
culdade de Ciências e Tecnologia - UNESP,
como requisito para a obtenção do título de
Mestre em Ciências Cartográficas.

Orientador: **Prof. Dr. Mauricio Galo**

PRESIDENTE PRUDENTE
2016

Carrilho, André Caceres.

C312a Aplicação de técnicas de processamento e análise de imagens para
detecção de edificações e vegetação a partir de dados LiDAR / André Caceres

Carrilho. - Presidente Prudente : [s.n], 2016

72 f.

Orientador: Mauricio Galo

Dissertação (mestrado) - Universidade Estadual Paulista, Faculdade de Ciências e Tecnologia

Inclui bibliografia

1. Classificação de dados LASER. 2. Morfologia Matemática. 3. RANSAC. I. Galo, Mauricio. II. Universidade Estadual Paulista. Faculdade de Ciências e Tecnologia. III. Título.

Termo de aprovação



UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Campus de Presidente Prudente

BANCA EXAMINADORA



Prof. Dr. MAURÍCIO GALO
(ORIENTADOR)



Prof. Dr. DANIEL RODRIGUES DOS SANTOS
(UFPR)



Prof. Dr. ALUIR PORFÍRIO DAL POZ
(UNESP/FCT)



ANDRÉ CÁ CERES CARRILHO

Presidente Prudente (SP), 16 de fevereiro de 2016.

Resultado: APROVADO

Dedicatória

À minha mãe Maria Isabel.

À minha tia Angela.

Ao meu irmão Bruno.

À minha namorada Fernanda.

Agradecimentos

Agradeço ao professor Dr. Mauricio Galo, pela diligência durante a orientação, pelos ensinamentos passados e pela paciência.

Aos professores e funcionários do Departamento de Cartografia da FCT/UNESP, pelo apoio e subsídio para o desenvolvimento deste trabalho.

Aos professores Dr. Aluir Porfírio Dal Poz, Dr. Mauricio Araújo Dias por todas as contribuições durante o exame de qualificação.

Aos professores Dr. Daniel Rodrigues dos Santos e Dr. Aluir Porfírio Dal Poz pelas sugestões feitas na defesa da dissertação.

À todos os companheiros da pós-graduação, especialmente aos que desde a graduação estudaram comigo, por tornar o ambiente amistoso.

À empresa Sensormap Geotecnologia pela disponibilização das imagens aéreas e dos dados de varredura a LASER utilizados nos experimentos.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa para a realização do curso de mestrado.

Resumo

As nuvens de pontos provindas de Sistemas de Varredura a LASER (*Light Amplification by Stimulated Emission of Radiation*) Aerotransportados (SVLA) representam a superfície com um grande detalhamento, sendo registrada a vegetação e as feições antrópicas, como edificações e rodovias, por exemplo. A automação da tarefa de classificação da nuvem de pontos é importante para a redução de custos em aplicações práticas relacionadas a atividades de mapeamento. Esta dissertação tem por objetivo principal o estudo, implementação e avaliação de técnicas de processamento e análise de imagens visando a classificação da nuvem de pontos LiDAR (*Light Detection and Ranging*), e a obtenção, de forma automática, do MDT (Modelo Digital do Terreno) e dos pontos pertencentes a edificações e vegetação. Inicialmente são apresentados os conceitos necessários para o entendimento do método proposto, o qual é detalhado na sequência, assim como os conjuntos de dados utilizados para as avaliações. Além da revisão conceitual sobre tópicos como Morfologia Matemática, Análise de Componentes Principais e algoritmo RANSAC, estudou-se a necessidade de redução da quantidade de iterações do RANSAC e uma alternativa para obtenção de alguns dos parâmetros do método *a priori*. Foram realizados experimentos sobre a escolha do interpolador (para a geração da grade regular) e para a seleção da forma e dimensão do elemento estruturante (usado nas operações morfológicas). A classificação final foi avaliada em termos de completeza e nível de acerto, calculadas com relação a referências geradas manualmente.

Palavras-chave: LiDAR. Classificação. Morfologia Matemática. Análise de Componentes Principais. RANSAC.

Abstract

The point clouds acquired by ALS (Airborne LASER Scanning) systems represent the surface with great level of detail, recording both natural vegetation and anthropic features, such as buildings and roads, for example. The automation's task of point clouds classification is important to reduce costs in practical applications related to mapping activities and production. This work is primarily focused in the study, implementation and evaluation of image processing and analysis techniques, aiming the automatic cloud point classification, generation of the DTM (Digital Terrain Model) and the detection of roof plane and vegetation points. Besides the conceptual review about Mathematical Morphology, Principal Component Analysis and RANSAC (Random Sample Consensus), it was studied the need to reduce the quantity of iterations and an alternative to obtain some of the parameters required by RANSAC algorithm considering one preliminary classification based on Principal Component Analysis. Some experiments were conducted in order to select both the interpolation method (to generate the grid) and the shape and size of the structuring element (used in the morphological operations). The final classification was evaluated in terms of completeness and correctness, computed with respect to a manually generated reference.

Keywords: LiDAR. Classification. Mathematical Morphology. Principal Component Analysis. RANSAC.

Lista de Figuras

2.1	Exemplos de padrões de amostragem da superfície.	19
2.2	Distinção entre um MDS amostrado por SVLA e o MDT filtrado.	20
2.3	Representações de superfícies comumente utilizadas para dados altimétricos.	21
2.4	Construção de uma <i>Quadtree</i> para um conjunto de pontos no plano.	24
2.5	Exemplos de elementos estruturantes de dimensão 7x7: Cruz, Cruz com “X” e Círculo.	26
2.6	Dilatação e erosão de uma estrutura em uma imagem binária por um elemento estruturante quadrado 2x2.	27
2.7	Abertura e fechamento de uma estrutura em uma imagem binária por um elemento estruturante quadrado.	28
2.8	Quantidade de iterações do algoritmo RANSAC para o ajuste de planos ($m = 3$), variando a probabilidade da amostra conter <i>outliers</i>	32
2.9	Autovalores relacionados as estruturas: borda, plano e quina.	34
3.1	Malha regular (MDS) obtido a partir da interpolação dos dados de SVLA e imagem orbital do centro de Stuttgart-DE.	36
3.2	Malha regular (MDS) obtido a partir da interpolação dos dados de SVLA e imagem aérea de um bairro de Presidente Prudente-SP.	37
3.3	Fluxograma ilustrando o procedimento de preparação dos dados.	39
3.4	Processo de limiarização aplicado ao resultado da abertura morfológica para a obtenção do MDT.	40
3.5	Fluxograma ilustrando os passos da pré-classificação.	41
3.6	Aplicação de limiar de área mínima aos segmentos de telhado.	42
3.7	Fluxograma ilustrando o procedimento de refinamento da classificação.	43
4.1	Comparação dos interpoladores utilizando os dados de Stuttgart-DE.	45
4.2	Comparação dos interpoladores utilizando os dados de Presidente Prudente.	46
4.3	Gráfico ilustrando o ganho de rendimento com o uso de <i>Quadtree</i> pelo número de pontos.	48
4.4	Fluxograma com o procedimento utilizado para comparar os resultados da filtragem por Morfologia Matemática com os resultados do LAStools.	49
4.5	Imagens aéreas das regiões de estudo para a comparação da filtragem.	50
4.6	Gráficos comparativos da média e desvio-padrão da diferença para cada formato de Elemento Estruturante.	51
4.7	Comparação da classificação com a referência considerando os dados de Stuttgart-DE.	53
4.8	Comparação da classificação com a referência considerando os dados de Presidente Prudente.	53
4.9	Detalhe referente à redução na densidade dos dados de Presidente Prudente.	55

4.10 Detecção dos planos de telhados com RANSAC. Situações corretas e problemáticas. Dados de Presidente Prudente.	57
--	----

Lista de Tabelas

2.1	Características das representações de superfícies.	21
4.1	Diferenças média e máxima entre as altitudes interpoladas.	47
4.2	Geração de malha regular. Melhoria no tempo de processamento com o uso de <i>Quadtree</i> para nuvens de pontos de diferentes tamanhos.	48
4.3	Valores de média e desvio-padrão para as diferenças. Considerou-se os valores médios dos resultados entre as três dimensões de EE avaliadas. . . .	51
4.4	Análise quantitativa em termos de completeza e nível de acerto das malhas regulares classificadas, para os dois conjuntos de dados.	54
4.5	Análise quantitativa em termos de completeza (<i>C.</i>), nível de acerto (<i>N.A.</i>) e qualidade (<i>Q.</i>), considerando a redução na densidade da nuvem de pontos.	56
C.1	Diferenças diretas e em módulo para a filtragem do terreno das três regiões. EE: Círculo, dimensão 27 m x 27 m.	70
C.2	Diferenças diretas e em módulo para a filtragem do terreno das três regiões. EE: Círculo, dimensão 37 m x 37 m.	70
C.3	Diferenças diretas e em módulo para a filtragem do terreno das três regiões. EE: Círculo, dimensão 47 m x 47 m.	70
C.4	Diferenças diretas e em módulo para a filtragem do terreno das três regiões. EE: Cruz com “X”, dimensão 27 m x 27 m.	71
C.5	Diferenças diretas e em módulo para a filtragem do terreno das três regiões. EE: Cruz com “X”, dimensão 37 m x 37 m.	71
C.6	Diferenças diretas e em módulo para a filtragem do terreno das três regiões. EE: Cruz com “X”, dimensão 47 m x 47 m.	71
C.7	Diferenças diretas e em módulo para a filtragem do terreno das três regiões. EE: Cruz, dimensão 27 m x 27 m.	71
C.8	Diferenças diretas e em módulo para a filtragem do terreno das três regiões. EE: Cruz, dimensão 37 m x 37 m.	72
C.9	Diferenças diretas e em módulo para a filtragem do terreno das três regiões. EE: Cruz, dimensão 47 m x 47 m.	72

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Considerações iniciais	14
1.2	Objetivos	16
1.3	Estrutura do trabalho	17
2	FUNDAMENTAÇÃO TEÓRICA	18
2.1	Sistema de varredura a LASER	18
2.2	Representação digital de superfícies	19
2.2.1	Distribuição irregular	21
2.2.2	Redes de triângulos irregulares	21
2.2.3	Curvas de nível	22
2.2.4	Malha regular	22
2.2.5	Estrutura hierárquica: <i>Quadtree</i>	23
2.2.6	Interpolação de altitudes para geração de malhas regulares	24
2.3	Morfologia matemática	25
2.3.1	Operadores morfológicos fundamentais	26
2.3.2	Outras operações morfológicas	29
2.4	Algoritmo RANSAC	30
2.4.1	Variantes do algoritmo RANSAC	31
2.5	Classificação por análise de componentes principais	33
2.6	Segmentação por crescimento de regiões	34
2.7	Elementos de avaliação quantitativa	35
3	MATERIAL E MÉTODO	36
3.1	Material	36
3.2	Método de classificação proposto	38
4	EXPERIMENTOS E DISCUSSÕES DOS RESULTADOS	44
4.1	Descrição dos experimentos	44
4.2	Comparação dos interpoladores para a geração de malhas regulares	44
4.2.1	Melhoria no tempo de processamento para a geração de malhas regulares utilizando <i>Quadtree</i>	48
4.3	Comparação dos elementos estruturantes para a filtragem dos dados LASER	49
4.4	Avaliação quantitativa da classificação obtida pelo método proposto	52
4.4.1	Efeito da redução na densidade para os dados de Presidente Prudente	55
4.4.2	Refinamento da detecção de planos de telhados com RANSAC	56
5	CONCLUSÕES	58

	13
REFERÊNCIAS	60
Apêndice A Descrição dos programas executáveis criados	65
A.1 Filtragem com abertura morfológica	65
A.2 Comparação de grades regulares	65
A.3 Classificação de nuvem de pontos	65
A.4 Cálculo dos elementos de avaliação quantitativa	66
Apêndice B Leitura de dados no formato LAS	67
Apêndice C Resultados adicionais do segundo experimento	70

1 INTRODUÇÃO

1.1 Considerações iniciais

Os Sistemas de Varredura LASER (*Light Amplification by Stimulated Emission of Radiation*) Aerotransportados (SVLA) possibilitam a aquisição de dados da superfície terrestre com detalhamento suficiente para discernir alvos pequenos e próximos (Lohr, 1998). Por definição, subentende-se que a amostragem obtida por SVLA corresponde a um Modelo Digital de Superfície (MDS), por registrar a vegetação e as feições antrópicas (como edificações e rodovias, por exemplo), além dos pontos do terreno.

A informação contida em um Modelo Digital do Terreno (MDT) é limitada aos pontos do solo e suas formas particulares, como cordilheiras e bacias hidrográficas, por exemplo (El-Sheimy, 2005). O MDT é um produto desejável, pois pode ser utilizado para diversas finalidades na cartografia, como a geração de curvas de nível e a produção de ortomagem, onde os objetos acima da superfície (edificações, por exemplo) são desconsiderados.

O procedimento de obtenção do MDT (filtragem) a partir dos dados LiDAR (*Light Detection and Ranging*) consiste na determinação de quais retornos dos pulsos LASER atingem o chão. Na literatura encontram-se diversos métodos para a filtragem desses dados. Sithole e Vosselman (2004), Meng et al (2010) apresentam revisões sobre o tema, dando algumas diretrizes quanto às formas de avaliação (performance) dos métodos. Meng et al (2010) separam os filtros em seis classes, sendo uma delas referente aos que tem embasamento na teoria de Morfologia Matemática.

Os filtros baseados na teoria de Morfologia Matemática são desenvolvidos a partir de operações de erosão, dilatação, abertura e fechamento (Lohmann et al, 2000), utilizados na tentativa de remover os objetos que não pertencem ao chão. Lindenberg (1993) apresenta a utilização da teoria da morfologia matemática para a filtragem de dados LiDAR. Outros trabalhos apresentam métodos baseados na operação de abertura morfológica (Lohmann et al, 2000; Peixoto e Centeno, 2009; Pacheco et al, 2011), nos quais uma etapa inicial para a geração de malhas regulares foi necessária, tornando possível a interpretação dos dados LiDAR estruturados na forma de uma função $Z = f(x, y)$ como imagens digitais.

Vosselman (2000) e Sithole (2001) apresentam um método de filtragem baseado na declividade, no qual a distinção entre os pontos pertencentes ao terreno e as demais feições é feita utilizando a operação morfológica de erosão. Roggero (2001) adapta o método proposto Vosselman (2000) e Sithole (2001), modificando a forma do elemento estruturante, que passa a ser adaptativo ao relevo do terreno, e adiciona uma etapa final

na qual os pontos são classificados a partir de suas distâncias à aproximação inicial do MDT obtida pelo filtro morfológico.

A teoria da Morfologia Matemática lida com a forma e as dimensões de feições presentes nas imagens digitais (Serra, 1982). Nesse contexto, as propriedades do Elemento Estruturante (forma e dimensão) são importantes para a remoção dos objetos indesejados no processo de filtragem (Meng et al, 2010). Kilian et al (1996) enfatizam a importância da escolha correta da dimensão do elemento estruturante para a remoção dos elementos não relevantes para a topografia. Os mesmos autores discutem sobre a utilização de sistemas que registram mais de um retorno do pulso para a filtragem de áreas de vegetação (devido à penetração do pulso na copa das árvores).

Operações para a detecção de vegetação e edificações são importantes, pois estes resultados subsidiam diversas tarefas, como por exemplo as operações fotogramétricas de geração de ortoimagens verdadeiras, onde é necessário determinar as áreas de oclusão, tornando possível que o algoritmo busque em outras imagens o valor do tom de cinza para pixels pertencentes a essas regiões. Tasha-kurdi et al (2008) destaca a importância da classificação da nuvem de pontos em terreno, vegetação e edificações para a construção automática de modelos 3D para cidades.

Segundo Moussa e El-Sheimy (2010), a automação da tarefa de classificação da nuvem de pontos é importante, pois o processamento manual é demorado e pode implicar em custos adicionais para aplicações práticas. Uma das alternativas para a detecção de vegetação e edificações é a utilização do algoritmo RANSAC (*RANdom SAmple Consensus*) com modelos matemáticos adequados para a superfície de cada feição.

Tasha-Kurdi et al (2008) e Tittmann et al (2011) mostram a aplicação de uma versão modificada do algoritmo RANSAC utilizando paraboloides elípticos como modelo matemático para modelagem da copa das árvores, sendo possível extrair informações biológicas da vegetação utilizando modelos de regressão com dados dendométricos extraídos em campo. Brenner et al (2001), Forlani et al (2006), Yan et al (2012) apresentam métodos para extração de planos de telhados de edificações utilizando o algoritmo RANSAC.

Outras possibilidades para a classificação de dados LiDAR envolvem a utilização de técnicas de segmentação ou transformação de variáveis (como Análise de Componentes Principais). Forlani et al (2006) e Calberg et al (2009) apresentam métodos de classificação de nuvens de pontos LiDAR utilizando dentre outras técnicas variações da segmentação por crescimento de regiões, estendida para o caso tridimensional. Filin (2002) e Shi e Zakhor (2011) apresentam métodos de classificação de nuvens de pontos baseado em Análise de Componentes Principais.

Por conta da grande quantidade de dados (nuvens de pontos densas), certos processamentos tornam-se demorados. Para mitigar este problema, alguns trabalhos abordam

a utilização de estruturas hierárquicas, como a *Quadtree*. Du e Lee (2012) apresentam um método para compressão de dados LASER. Os mesmos autores (DU e LEE, 2013) trabalharam com a modelagem de edificações baseado em *Quadtrees*. Li et al (2010) apresentam um método de filtragem iterativo para áreas de floresta, baseado em *Quadtrees* adaptativas.

Deste modo, com base no contexto colocado, propõe-se neste trabalho uma adaptação dos métodos encontrados na literatura, de modo a obter um procedimento para a classificação de nuvem de pontos LiDAR em suas três classes principais: MDT (terreno), edificações e vegetação. Inicialmente, tem-se a etapa de preparação (pré-processamento), que envolve a leitura dos dados, geração de uma *Quatree* (estrutura hierárquica) a interpolação da malha regular (estrutura matricial necessária para a aplicação dos operadores morfológicos).

A filtragem da nuvem de pontos (e obtenção do MDT) é feita com a operação de abertura morfológica. Uma etapa final semelhante a apresentada por Roggero (2001) é efetuada para o refinamento da filtragem. A detecção dos pontos pertencentes às edificações e vegetação divide-se em duas etapas, a primeira envolvendo uma pré-classificação dos dados por Análise de Componentes Principais e Segmentação por Crescimento de Regiões, e a segunda com o refinamento da classificação utilizando o RANSAC para a detecção dos planos de telhados.

1.2 Objetivos

O propósito central deste trabalho consiste no estudo, implementação e avaliação de técnicas de processamento e análise de imagens visando a classificação da nuvem de pontos LiDAR e a obtenção, de forma semiautomática, do MDT e dos pontos pertencentes a edificações e vegetação.

Os objetivos específicos deste trabalho são:

- Integrar os conceitos da teoria da Morfologia Matemática, juntamente com o algoritmo RANSAC, Análise de Componentes Principais e Segmentação por Crescimento de Regiões, visando o desenvolvimento de um método para a classificação da nuvens de pontos LASER;
- Manipular e organizar os dados LASER em estrutura hierárquica (*Quadtree*) visando otimizar a busca de pontos LASER na tarefa de geração da malha regular;
- Realizar experimentos com o método desenvolvido, utilizando dados reais, assim como avaliar os resultados obtidos de maneira quantitativa.

1.3 Estrutura do trabalho

Esta dissertação é composta de cinco capítulos, referências e as informações adicionais divididas em anexos e apêndices. O primeiro capítulo trata da introdução e tem o intuito de situar o leitor, dando um panorama geral sobre o que será abordado, assim como os objetivos (geral e específicos) do trabalho.

O segundo capítulo aborda de forma sucinta a fundamentação teórica sobre os conceitos envolvidos no trabalho. Os seguintes tópicos são apresentados: Sistemas de Varredura a LASER, representação de superfícies, Morfologia Matemática, algoritmo RANSAC, Análise de Componentes Principais, Segmentação por Crescimento de Regiões e os elementos de avaliação quantitativa.

No terceiro capítulo apresenta-se o material utilizado, isto é: a origem e as característica dos dados, os *softwares* e bibliotecas empregados nas implementações. Na sequência do terceiro capítulo o método de classificação proposto é detalhado.

O quarto capítulo trata da descrição dos experimentos e os resultados obtidos com o método proposto. Dentre os experimentos, são feitos estudos sobre a escolha de alguns dos parâmetros do método. A avaliação quantitativa dos resultados e algumas análises são apresentadas, assim como uma breve discussão.

No último capítulo tem-se as conclusões sobre os resultados obtidos para os experimentos realizados e uma breve discussão abordando a execução do trabalho como um todo.

2 FUNDAMENTAÇÃO TEÓRICA

Esta seção apresenta a fundamentação teórica que engloba os principais conceitos necessários para o desenvolvimento deste trabalho, tais como: Sistema de varredura a LASER, representação digital de superfícies, algoritmo RANSAC, Análise de Componentes Principais e segmentação por crescimento de regiões.

2.1 Sistema de varredura a LASER

O princípio de funcionamento de um Sistema de Varredura (ou Perfilamento) a LASER consiste na medição de distâncias a partir da emissão de pulsos por um sistema óptico-mecânico e a recepção de seus retornos. Pelo fato do sistema emitir os pulsos, ou seja, ser independente de fontes de radiação externas (como o Sol, por exemplo), ele é classificado como um sistema ativo. De acordo com Wehr e Lohr (1999), um sistema LiDAR pode ser subdividido nas seguintes unidades principais: Sistema de varredura a LASER; Sistema de posicionamento e orientação; e Unidade de controle e processamento.

Segundo Baltasvias (1999), para a medida de distâncias, dois princípios fundamentais podem ser aplicados: medição pelo tempo de propagação do pulso LASER; medição da diferença de fase, sendo que este último é aplicado em equipamentos que emitem luz de forma contínua. A forma mais simples de medição de distância (R) é a determinação pelo tempo de propagação (t) entre o pulso emitido e o recebido.

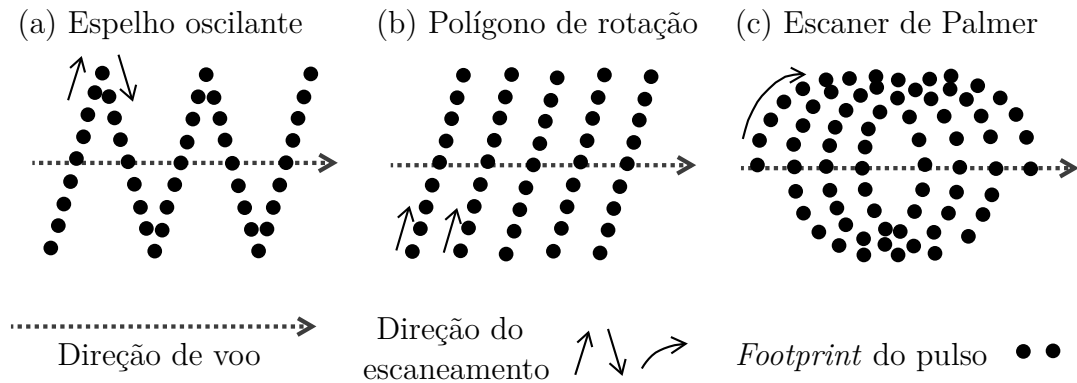
A unidade (ou sistema) de varredura a LASER é composta pelo emissor de feixes LASER, espelho de varredura, receptor eletro-óptico e o detector/contador de tempo (WEHR e LOHR, 1999). O posicionamento e a orientação são feitos utilizando DGPS (*Differential Global Positioning System* – Sistema Diferencial de Posicionamento Global) ou RTK (*Real Time Kinematic* – Cinemático em Tempo Real) que opera em conjunto e de modo sincronizado com um INS (*Inertial Navigation System* – Sistema de Navegação Inercial). As observações do sistema GNSS contribuem para a remoção dos erros sistemáticos do INS e vice-versa.

O sistema de posicionamento e orientação permite estimar a posição (X, Y, Z) e orientação (ω, ϕ, κ) da plataforma e conseqüentemente do sensor no momento da medição da distância. Conhecida a posição e orientação do sensor, é possível determinar as coordenadas tridimensionais do ponto no terreno a partir da distância obtida pela unidade de medida de distâncias.

O sistema de varredura é encarregado de direcionar o feixe LASER ao terreno, de modo a amostrar os pontos seguindo um determinado padrão. Na Figura 2.1 são apresentadas algumas das configurações apresentadas pelos pulsos LASER projetados

na superfície, para três mecanismos de varredura diferentes: (a) espelho oscilante; (b) polígono de rotação; e (c) escaner de Palmer.

Figura 2.1 - Exemplos de padrões de amostragem da superfície.



Fonte: Adaptado de Fernandez-Dias et al (2014).

Na especificação de um SVLA duas frequências estão envolvidas na amostragem dos pontos no terreno. A primeira é a frequência de varredura, que representa o número de varreduras por segundo, e a frequência de emissão de pulsos, que é a quantidade de pulsos emitidos por unidade de tempo. Estas duas frequências devem ser configuradas no sistema, levando em conta outros fatores como a velocidade da aeronave, a altura de voo e a densidade de pontos amostrados desejável.


2.2 Representação digital de superfícies

Encontram-se na literatura diversas definições para modelos digitais de representação da superfície terrestre. A terminologia Modelo Digital de Elevação (MDE) refere-se a uma maneira mais abrangente da representação, podendo conter tanto a informação do terreno quanto as feições acima dele, desta forma proporciona uma ideia genérica sobre os dados. Segundo Li et al (2004) a palavra “elevação” enfatiza uma medida de altitude acima de um datum vertical. Conforme pode ser visto em El-Sheimy et al (2005), a expressão MDE normalmente refere-se a um arranjo regular de elevações, como padrões retangulares ou hexagonais acima do terreno. Peckham e Jordan (2007) entendem o MDE como um tipo mais básico do Modelo Digital do Terreno (MDT).

De forma geral, entende-se o Modelo Digital de Superfície (MDS) como a superfície do terreno acrescida de quaisquer feições existentes sobre ela, como vegetação e edificações (feições antrópicas), por exemplo (LI et al, 2004). Deste modo, o MDS contém apenas a maior altitude de cada ponto.

Para El-Sheimy et al (2005) a informação de elevação contida no Modelo Digital do Terreno é limitada aos pontos no solo, isto é, representa a superfície real do terreno, entretanto, algumas feições como cordilheiras e bacias hidrográficas podem ser inseridas na forma de linhas de quebra (*breaklines*). Peckham e Jordan (2007) definem o MDT como um arranjo ordenado de números que representam a distribuição espacial dos atributos do terreno. Na Figura 2.2 tem-se a distinção entre um MDS amostrado por SVLA e o MDT filtrado.

Figura 2.2 - Distinção entre um MDS amostrado por SVLA e o MDT filtrado.




Fonte: Elaborada pelo autor.

Outro conceito importante se refere ao Modelo Digital de Superfície normalizado (MDSn), que representa a elevação absoluta das feições acima do terreno (vegetação e edificações). Desta forma, o MDSn pode ser obtido a partir da subtração entre o MDS e o MDT (MENDERES; ERENER; SARP, 2015). Uma vez que para o MDSn a referência é o terreno, todos os processamentos independem do relevo, isto é, são feitos diretamente sobre a vegetação e as feições antrópicas.

A representação de superfícies em meios digitais pode ser feita com diversas estruturas de dados. As mais comuns distinguem-se por suas características, isto é, a amostragem dos pontos da superfície (original ou reamostrada), se é ou não estruturada, e se apresenta ou não regularidade. A Figura 2.3 ilustra as principais estruturas de dados: pontos distribuídos irregularmente (nuvem de pontos), TIN (*Triangular Irregular Network* ou Redes de triângulos irregulares), curvas de nível e malha regular.

Figura 2.3 - Representações de superfícies comumente utilizadas para dados altimétricos.



Fonte: Adaptado de Abdul-Rahman e Desa (1996).

As representações ilustradas na Figura 2.3 podem ser classificadas pelos critérios citados anteriormente. Na Tabela 2.1 tem-se as características das representações destas superfícies.

Tabela 2.1 - Características das representações de superfícies.

Representação	Amostragem	Estruturada	Regularidade
Distribuição irregular	Original	Não	Não
TIN	Original	Sim (Rede)	Não
Curvas de nível	Reamostrada	Sim (Curvas)	Não
Malha regular	Reamostrada	Sim (Malha)	Sim

2.2.1 Distribuição irregular

Esta é a representação mais simples, basicamente armazena a superfície a partir de uma lista de coordenadas dos pontos amostrais (ABDUL-RAHMAN e DESA, 1996). As técnicas de aquisição dos dados podem ser topográficas (levantamentos por estação total, teodolito ou rastreamento de satélites da constelação GNSS – *Global Navigation Satellite System*), por técnicas fotogramétricas, escaneamento LASER, entre outros. Por ser muito simples, esta representação não define a topologia diretamente, ou seja, torna-se necessário efetuar processamentos adicionais para a obtenção das relações entre os pontos (cálculos de distâncias e ângulos).

2.2.2 Redes de triângulos irregulares

Redes de triângulos irregulares são compostas por conjuntos de triângulos contíguos e sem sobreposição. O interior de cada triângulo aproxima a superfície por um plano. A construção da malha triangular sempre segue algum critério bem definido. Na

triangulação de Delaunay, por exemplo, a condição é de que nenhum vértice deve estar contido no círculo circunscrito a qualquer triângulo da rede (ABDUL-RAHMAN e DESA, 1996).

As linhas de quebra (ou *breaklines*) são estruturas que auxiliam a representação de feições que definem discontinuidades na superfície. Podem ser utilizadas juntamente com as representações TIN, malhas regulares ou curvas de nível. Geralmente definem feições de hidrografia, fundos de vale ou cristas (GARCÍA-TEJERO, 1997).

2.2.3 Curvas de nível

Este tipo de representação do terreno geralmente é utilizado em cartas topográficas. As curvas de nível são isolinhas de mesma altitude, isto é, todos os seus pontos possuem a mesma altitude no terreno (IMHOF, 2007). Nesta representação, em projeção ortogonal, as curvas podem ser obtidas como a interseção da superfície do terreno com planos horizontais (GARCÍA-TEJERO, 1997).

A separação vertical entre duas linhas consecutivas é denominada equidistância vertical, cujo valor é relacionado à escala do produto cartográfico (IMHOF, 2007). O traçado das curvas de nível obedece a algumas regras: são suaves (não possuem quebras ou quinas); nunca se cruzam; quanto mais próximas, mais inclinado é o terreno, dentre outras.

As curvas de nível são classificadas em curvas mestras (ou principais, geralmente com traço mais espesso) e secundárias. A conversão para outras estruturas pode ser realizada a partir da interpolação (VEIGA, ZANETTI e FAGGION, 2012).

2.2.4 Malha regular

Segundo Felgueiras e Câmara (2001) a malha regular é um modelo digital que aproxima a superfície por um poliedro de faces triangulares, cujos vértices (pontos) são distribuídos regularmente sobre a superfície. Os eixos da malha geralmente são paralelos aos do sistema de referência utilizado, tornando mais simples o armazenamento da estrutura de dados, podendo ser feito de forma matricial (DE WULF et al, 2012).

O parâmetro crucial a ser estipulado para esta representação refere-se ao espaçamento entre os pontos. Idealmente o espaçamento deve ser menor ou equivalente ao grau de separação das amostras iniciais, de modo a preservar as características do terreno (FELGUEIRAS e CÂMARA, 2001).

Por ser um modelo simples (o que corresponde a ter um processamento mais ágil) e exigir menos espaço de armazenamento, o modelo de malha regular é mais indicado

para aplicações em tempo real (DE WULF et al, 2012). Entretanto, a necessidade de interpolação dos dados originais para a geração da malha regular acarreta na inserção de erros nas altitudes.

Segundo De Wulf et al (2012) outro ponto negativo das malhas regulares se dá pela redundância de informações em regiões planas ou falta de informação para detalhes mais específicos, como por exemplo em regiões mais acidentadas, que naturalmente requerem uma amostragem com maior densidade.

A geração da malha regular consiste na determinação dos seus parâmetros básicos (espaçamento, coordenadas do ponto inicial, número de linhas e colunas) e da interpolação dos valores de altitude para cada ponto.

Para Felgueiras e Câmara (2001) o processo de interpolação pode ser dividido em: global, quando são utilizadas todas as amostras possíveis, ou local, quando as amostras utilizadas são limitadas a uma vizinhança preestabelecida. Quando tem-se amostras em grandes quantidades ou não homogêneas a interpolação global é menos aconselhada, devido às dificuldades de processamento computacional e precisão do modelo.

2.2.5 Estrutura hierárquica: *Quadtree*

Pelo fato de algumas representações de superfícies não armazenarem as relações topológicas diretamente (como no caso da nuvem de pontos), torna-se necessária a utilização de estruturas adicionais que permitam a definição direta (sem a necessidade de processamento adicional) da topologia.

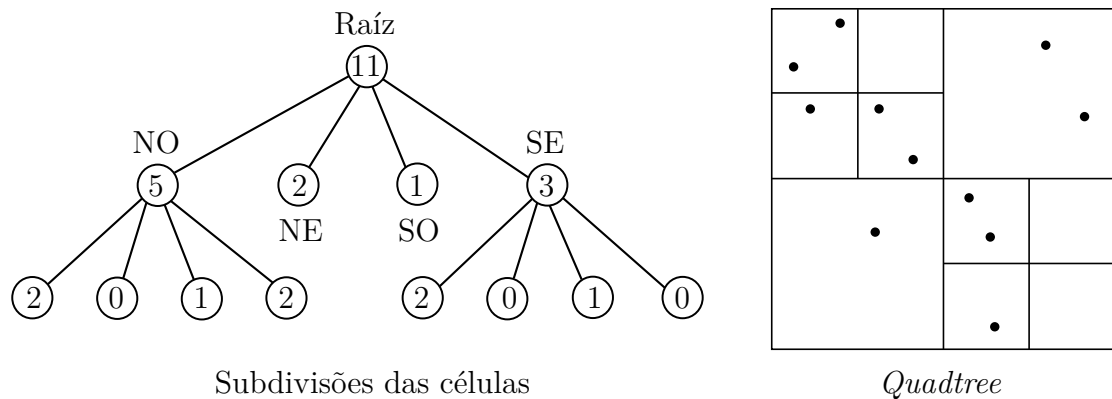
Existem diversas estruturas hierárquicas usadas para representar dados espaciais, tais como BSP (*Binary Space Partitioning*), *Quadtree* e *Octree*. Embora muitas vezes relacionada a representação de dados bidimensionais (NONATO, 2000), a *Quadtree* também pode ser utilizada para a representação de dados em espaços multidimensionais, como no caso de dados LiDAR, ou seja, um espaço tridimensional.

Segundo Nonato (2000) as *Quadtrees* descrevem um TAD (Tipo Abstrato de Dados) em formato de árvore, cuja característica principal é a decomposição recursiva do espaço em quatro nós (quadrantes) de igual dimensão (um quarto do nó de nível superior na árvore). As regiões delimitadoras dos nós não precisam ser necessariamente quadradas, podendo ser retangulares ou alguma forma arbitrária que satisfaça as regras topológicas.

Este tipo de estrutura auxilia a consulta e a busca de pontos próximos (vizinhos) em procedimentos de interpolação, como no caso da geração de uma malha regular a partir de uma nuvem de pontos. Ao invés de calcular a distância entre o ponto interpolado e todos os pontos da nuvem, basta consultar quais são os mais próximos na estrutura em árvore criada, reduzindo o custo computacional.

O principal parâmetro necessário para a geração de uma *Quadtree* para um conjunto de dados é a capacidade (n) de cada célula, isto é, qual o número máximo de pontos que uma célula é capaz de conter sem que seja necessário subdividi-la. A Figura 2.4 apresenta o procedimento de construção de uma *Quadtree* para um conjunto de pontos no plano com $n = 2$.

Figura 2.4 - Construção de uma *Quadtree* para um conjunto de pontos no plano.



Fonte: Adaptado de Agarwal et al (2006).

Como pode ser visto em Samet (1990), outra possibilidade para a construção de uma *Quadtree* é a definição do nível de subdivisão máximo (ao invés da capacidade das células). A consulta a pontos vizinhos pode ser feita de modo recursivo ou linear, dependendo da implementação utilizada ser de ponteiros ou sequência (*array*).

2.2.6 Interpolação de altitudes para geração de malhas regulares

Por conta da não coincidência da posição dos elementos da malha regular com os dados amostrados é necessário interpolar as altitudes. Na literatura encontram-se alguns métodos para a interpolação, como vizinho mais próximo, inverso do quadrado da distância euclidiana e a krigagem.

Para Macedo et al (2001), o interpolador média móvel ponderada calcula o valor da altitude de cada ponto da malha a partir da média ponderada dos vizinhos mais próximos, porém atribui pesos variados para cada ponto amostrado através de uma função na forma $w(x, y)$.

$$h_i = \frac{\sum_{j=1}^n w_{ij} h_j}{\sum_{j=1}^n w_{ij}} \quad (1)$$

onde: h_i é o valor de altitude de um ponto da malha, h_j é a altitude de um ponto da

amostra e w_{ij} é o peso da observação (fator de ponderação, que pode ser feita em função do inverso do quadrado da distância, por exemplo).

Macedo et al (2001) apontam que este estimador determinístico pode considerar a organização espacial do atributo para a definição do raio de busca dos vizinhos. Outras possibilidades podem ser consideradas, como a determinação do raio considerando um número fixo de pontos em seu interior, ou com base no conceito de entropia (YANG e DONG, 2013).

Segundo Felgueiras e Câmara (2001), as variações deste interpolador assumem as possibilidades quanto ao número de pontos vizinhos utilizados e quanto a função de ponderação. Considerando o fator de ponderação $w_{ij} = 1/n$ para todas as amostras vizinhas, tem-se a média aritmética.

A interpolação por vizinho mais próximo (*Nearest Neighbor*) pode ser definido como a utilização de apenas uma amostra vizinha a cada ponto da malha. Este interpolador deve ser considerado quando há interesse em manter os valores das amostras originais, evitando gerar valores intermediários (FELGUEIRAS e CÂMARA, 2001).

Outra função de ponderação leva em conta o inverso da potência da distância euclidiana entre o ponto da malha (cuja altitude está sendo interpolada) e o ponto da amostra (cuja altitude está sendo contabilizada):

$$w_{ij} = d_{ij}^{-k} \quad (2)$$

onde: k é a potência da distância e d_{ij} é a distância euclidiana no plano horizontal entre ponto i da malha regular ao ponto amostral j .

2.3 Morfologia matemática

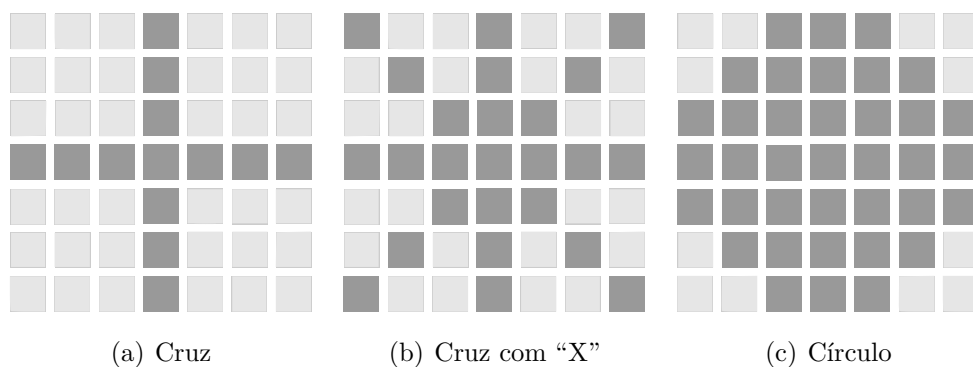
A Morfologia Matemática (MM) é o estudo de estruturas geométricas (forma) presentes numa imagem a partir de ferramentas matemáticas (SERRA, 1982), e é baseada na teoria de conjuntos. O princípio básico consiste em extrair informações relativas à geometria e à topologia de conjuntos desconhecidos de uma imagem a partir do elemento estruturante (EE).

O EE é um conjunto completamente definido e conhecido, que é comparado, a partir de uma transformação (união, intersecção, complementação, ou a combinação delas), aos conjuntos desconhecidos da imagem (GONZALES e WOODS, 2008).

Ao trabalharmos com imagens, é importante que o EE seja descrito em uma estrutura matricial. Usualmente é comum o uso de matrizes de dimensões ímpares, posicionando a origem em seu elemento central. Outras possibilidades para dimensões e

posicionamento da origem podem ser exploradas. São diversas as possibilidades de se montar o EE, as mais simples são em formato de cruz (e cruz com “X”), preenchimento completo do retângulo, formato de disco, formato de losango, entre outros. A Figura 2.5 apresenta alguns exemplos de EEs com dimensão 7x7.

Figura 2.5 - Exemplos de elementos estruturantes de dimensão 7x7: Cruz, Cruz com “X” e Círculo.



Fonte: Elaborada pelo autor.

2.3.1 Operadores morfológicos fundamentais

As operações fundamentais da MM são a translação e a reflexão, as quais quando combinadas resultam nas operações de erosão e dilatação (SERRA, 1982). A erosão e a dilatação servem de base para diversas operações morfológicas, sendo que as principais são a abertura e o fechamento (PEIXOTO e CENTENO, 2009). Outras operações podem ser compostas, tais como (GONZALES e WOODS, 2008): afinamento, *hit-or-miss*, fechamento de buracos, extração de bordas, segmentação *watershed*, entre outras.

Como visto em Peixoto e Centeno (2009), esses operadores podem ser utilizados em imagens binárias ou de nível de cinza. Em imagens de nível de cinza eles correspondem aos valores máximos e mínimos nas combinações dos valores dos pixels.

Os conceitos básicos para as operações morfológicas são provenientes da teoria de conjuntos. Para um conjunto B pertencente ao \mathbb{Z}^2 (conjunto dos números inteiros no espaço bidimensional), as operações de “reflexão” e “translação por um ponto z ” são definidas (GONZALEZ e WOODS, 2008) respectivamente por:

$$\begin{aligned} \hat{B} &= \{w | w = -b, \text{ para } b \in B\} \\ (B)_z &= \{c | c = b + z, \text{ para } b \in B\} \end{aligned} \quad (3)$$

onde: b é um elemento do conjunto B ; w é um elemento do conjunto \hat{B} , obtido pela

operação de reflexão; e c é um elemento do conjunto $(B)_z$, obtido pela operação de translação por um ponto z .


Considerando A e B como sendo dois conjuntos pertencentes ao \mathbb{Z}^2 , a erosão binária e dilatação binária de A por B são definidas (GONZALEZ e WOODS, 2008), respectivamente, por:

$$\begin{aligned} A \ominus B &= \{z | (B)_z \cap A^c = \emptyset\} \\ A \oplus B &= \{z | (\hat{B})_z \cap A \neq \emptyset\} \end{aligned} \quad (4)$$

onde: A^c é o complemento do conjunto A . O símbolo \cap representa a intersecção de conjuntos. Os símbolos \ominus e \oplus representam as operações de erosão e dilatação, respectivamente. Os conjuntos resultantes das operações morfológicas de dilatação e erosão são compostos por elementos z .

A Figura 2.6 ilustra uma estrutura binária (original) e os resultados da aplicação das operações dilatação e erosão por um EE quadrado de dimensão 2x2. É possível verificar que a dilatação resulta em uma estrutura cujas bordas são estendidas com relação à estrutura original, o contrário ocorre para o resultado da erosão.

Figura 2.6 - Dilatação e erosão de uma estrutura em uma imagem binária por um elemento estruturante quadrado 2x2.



Fonte: Elaborada pelo autor.

Para o caso de imagens em tons de cinza, pode-se escrever essas duas operações de outra forma. Considerando uma imagem f e um elemento estruturante b , a erosão e dilatação em tons de cinza de f por b no ponto (x, y) são definidas (GONZALEZ e WOODS, 2008) por:

$$\begin{aligned} [f \ominus b](x, y) &= \min_{(s,t) \in b} \{f(x + s, y + t)\} \\ [f \oplus b](x, y) &= \max_{(s,t) \in b} \{f(x - s, y - t)\} \end{aligned} \quad (5)$$

onde: (s, t) designam os índices do ponto no elemento estruturante.

Os sinais negativos nos índices (s, t) da operação de dilatação na Equação 5 se devem pelo fato da utilização do elemento estruturante após a operação de reflexão com relação ao elemento central: $\hat{b} = b(-x, -y)$.

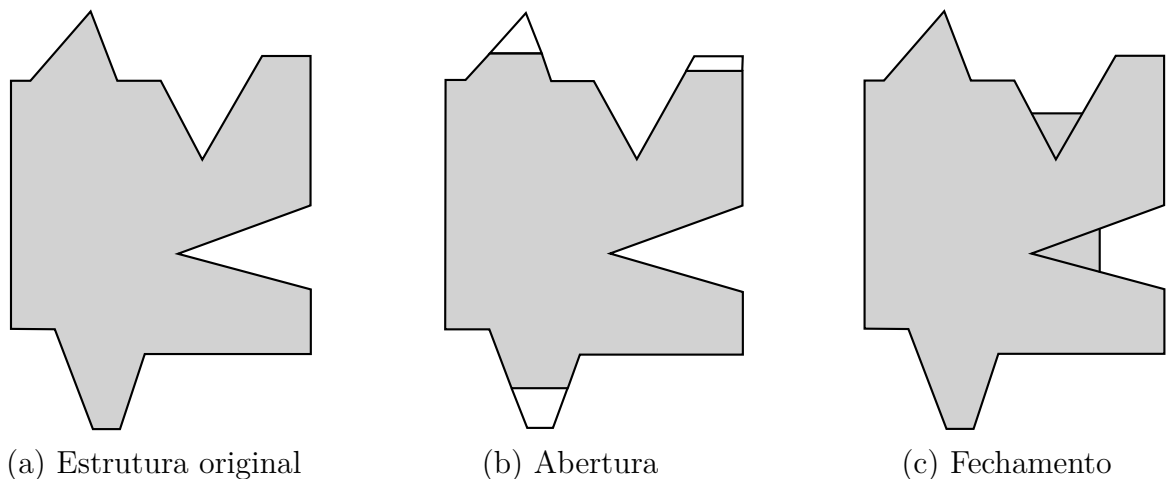
No caso de imagens digitais, f e b são conjuntos pertencentes ao \mathbb{Z}^3 (conjunto dos números inteiros no espaço tridimensional). Para uma malha regular de pontos, considera-se f e b pertencentes ao \mathbb{R}^3 .

As expressões para as operações de abertura e fechamento em imagens de tons de cinza são definidas (GONZALEZ e WOODS, 2008), respectivamente, por:

$$\begin{aligned} f \circ b &= (f \ominus b) \oplus b \\ f \bullet b &= (f \oplus b) \ominus b \end{aligned} \quad (6)$$

As operações abertura e fechamento possuem uma interpretação geométrica simples. Supondo uma imagem $f(x, y)$ ela pode ser vista como uma superfície 3D, isto é, os valores de intensidade são interpretados como alturas acima do plano-xy, descrito em termos dos valores de coluna e linha (GONZALES e WOODS, 2008). A Figura 2.7 ilustra os efeitos das operações de abertura e fechamento em uma estrutura binária.

Figura 2.7 - Abertura e fechamento de uma estrutura em uma imagem binária por um elemento estruturante quadrado.



Fonte: Adaptado de Goutsias e Heijmans (2000).

A operação de erosão determina o mínimo local (em elevação) dentro de uma janela (elemento estruturante), na qual a superfície inicial do terreno é produzida, processo similar ao filtro de bloco mínimo (WACK e WIMMER, 2002). A operação de dilatação atribui o máximo local da vizinhança ao elemento processado, recuperando os detalhes da superfície original (SOHN e DOWNMAN, 2008).

Essa concepção pode ser aplicada para analisar uma superfície gerada a partir de uma nuvem de pontos (WEIDNER e FÖRSTNER, 1995), onde ao invés de uma imagem digital tem-se uma malha regular, isto é, os valores de tons de cinza são substituídos pelas altitudes.

2.3.2 Outras operações morfológicas

Além das operações básicas mostradas anteriormente, a teoria de morfologia matemática dispõe de diversos outros operadores, tais como a transformada *Hit-or-Miss*, operador de detecção de bordas, afinamento e espessamento de bordas, segmentação *watershed*, entre outras (SERRA, 1982). A seguir serão vistas algumas destas operações, que tem potencial de aplicação na filtragem de MDS.

A transformada *Hit-or-Miss* serve como base para a detecção de formas. Esta transformação é baseada na operação de erosão, entretanto, são necessários dois elementos estruturantes para a localização pontual da forma desejada, como destacado por Zhao e Daut (1991).

Seja um conjunto A que contenha alguns subconjuntos distintos (formas). Seja um desses subconjuntos (denotado por F) uma forma de interesse contida no conjunto A . Seja C um elemento estruturante totalmente preenchido, cujas dimensões são ligeiramente superiores ao do subconjunto F . A diferença $F - C$ é denominada fundo local de F . Chamando $B = (B_1, B_2)$ de modo que $B_1 = F$ e $B_2 = F - C$, tem-se a transformação *Hit-or-Miss* binária que localiza as ocorrências de F em A (GONZALEZ e WOODS, 2008):

$$A \otimes B = (A \ominus B_1) \cap (A^c \ominus B_2) \quad (7)$$

A operação de detecção de bordas é comumente feita por operadores, como o de Sobel, Roberts, Canny, Prewitt e Laplaciano (ACHARJYA, DAS e GHOSHAL, 2012). Entretanto, a detecção de bordas também pode ser feita utilizando os conceitos de Morfologia Matemática.

Tomando B como um elemento estruturante totalmente preenchido e de dimensão 3×3 , por exemplo, as bordas de um conjunto A , denotada por $B(A)$ podem ser obtidas pela diferença entre o conjunto A e o resultado da erosão de A por B (GONZALEZ e WOODS, 2008).

A operação de segmentação *watershed* considera a imagem como uma superfície topográfica, sendo que as coordenadas linha e coluna (i, j) se relacionam com as coordenadas planimétricas e o valor do tom de cinza é diretamente proporcional a altitude do ponto (POLIDORIO et al, 2005). O processamento é feito do ponto mais baixo ao mais

elevado, por meio de uma técnica de inundação (*flooding*). A definição das regiões se dá pela área inundada em cada vale.

Conforme o relevo é inundado, isto é, a cada iteração do processamento é necessário verificar se há regiões que passaram a se conectar. Neste caso é necessário elevar (aumentar os valores de tons de cinza) das bordas que separam essas regiões (NASCI-MENTO, 2013).

Segundo Polidorio et al (2005), um problema quanto ao uso deste operador refere-se à sensibilidade de ruídos, resultando em uma grande quantidade de regiões (supersegmentação dos objetos).

2.4 Algoritmo RANSAC

Fischler et al (1981) propuseram o algoritmo RANSAC (*RANdom SAmples Con-sensus*) como uma abordagem geral para a estimação de parâmetros, projetada para lidar com conjuntos de dados com grandes quantidades de observações incorretas (*outliers*). Segundo Derpanis (2010), ao contrário de algoritmos como o Método dos Mínimos Quadrados (MMQ) e Estimadores-M, os quais foram adotados pela comunidade de visão computacional a partir da literatura de estatística, o RANSAC foi desenvolvido pela própria comunidade de visão computacional.

O RANSAC é uma técnica que gera soluções candidatas usando a quantidade mínima de observações necessárias para estimar os parâmetros de um dado modelo matemático predefinido. Ao contrário dos métodos convencionais, que utilizam a maior quantidade de dados possíveis para obter a solução inicial, o RANSAC usa o menor conjunto de dados, na tentativa de acrescentar iterativamente as observações corretas (*inliers*) a um conjunto consistente (consenso). Assumindo que o modelo matemático foi definido, na sequência é feita a descrição do algoritmo com base em Derpanis et al. (2010):

1. Selecionar aleatoriamente a menor quantidade de observações necessárias para estimar os parâmetros do modelo matemático;
2. Solucionar os parâmetros do modelo matemático para esse conjunto de dados;
3. Determinar quantas das observações (z_i) do conjunto inicial atendem ao critério estabelecido;
4. Se a quantidade de observações z_i for maior que o conjunto consenso, infere-se que a solução atual é melhor e deve tomar seu lugar. Caso a iteração atual não for a última, retorna-se ao primeiro passo;

5. Ao atingir o limite de iterações, deve-se estimar por mínimos quadrados os parâmetros do modelo utilizando todos as observações do consenso.

Segundo Derpanis et al (2010), a quantidade de iterações é escolhida como sendo alta o suficiente para garantir, com uma probabilidade p (geralmente selecionada como $(0, 99)$), que ao menos um dos conjuntos de observações selecionados não contenha observações incorretas. Assumindo que u seja a probabilidade de que uma dada observação atenda ao critério adotado (seu valor não é conhecido *a priori*, mas pode ser estimado com base nas características dos dados), adotando $v = 1 - u$ como a probabilidade de que a observação não atenda ao critério, e que m represente a quantidade de pontos mínima para estimar os parâmetros do modelo, a quantidade de iterações mínima $N(p, v, m)$ será dada (DERPANIS, 2010) por:

$$N = \frac{\log(1 - p)}{\log(1 - (1 - v)^m)} \quad (8)$$

Como é possível verificar, o cálculo da quantidade de iterações estimada pela Equação 8 não leva em conta o tamanho do conjunto de dados, tornando o algoritmo vantajoso mesmo para nuvens de pontos densas. Tasha-kurdi et al. (2007) citam que o RANSAC é mais eficiente quando comparado à transformada de Hough 3D, sendo esta mais sensível aos parâmetros de segmentação.

2.4.1 Variantes do algoritmo RANSAC

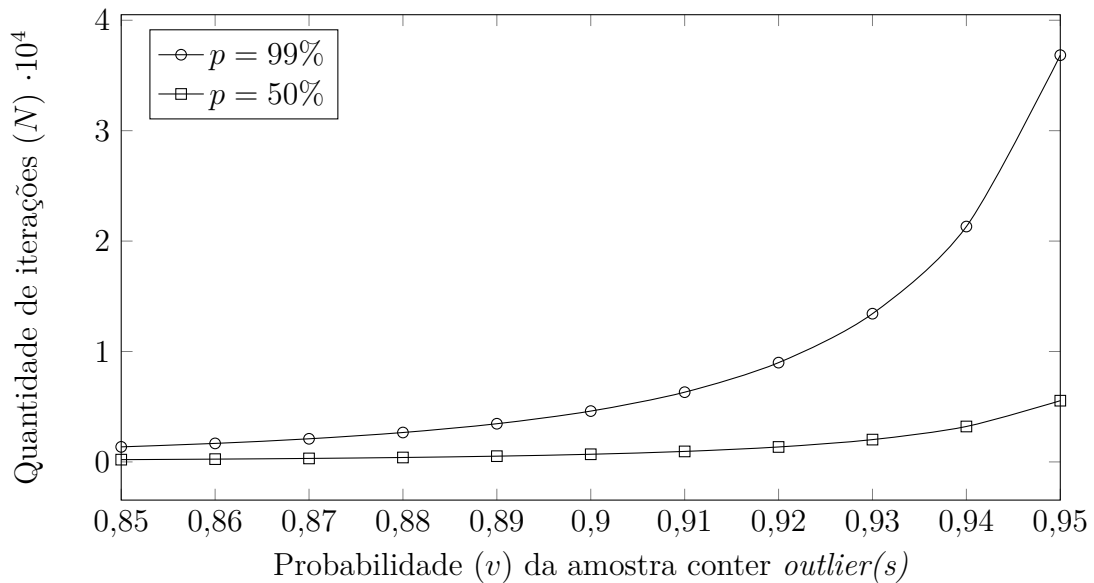
Os variantes do algoritmo RANSAC buscam melhorar e otimizar o processamento realizado pelo método originalmente proposto. Por ser baseado na seleção de conjuntos de amostras aleatórias e verificação da adequação dos dados iniciais aos parâmetros estimados, o aperfeiçoamento do método pode ser feito a partir de duas abordagens. Algumas estratégias buscam otimizar a seleção dos conjuntos de amostras enquanto outras apresentam formas de verificar os modelos estimados com testes mais eficientes.

Segundo Raguram et al (2008) o algoritmo RANSAC permite estimar a solução correta mesmo para amostras com grandes quantidades de *outliers*, entretanto o número de iterações necessárias aumenta exponencialmente, comprometendo o custo computacional. Uma maneira de aperfeiçoar o método é reduzir a quantidade de iterações sem comprometer a robustez da estimação do modelo.

A Figura 2.8 apresenta um gráfico, obtido a partir da Equação 8, para $m = 3$, onde é possível verificar o aumento no número de iterações dependendo da probabilidade (p) de que ao menos um dos conjuntos de observações selecionados não contenha *outliers*. Geralmente estipula-se o valor desta probabilidade entre 90% e 99% (TASHA-KURDI et

al, 2007). O gráfico mostra as curvas com probabilidades $p = 50\%$ e $p = 99\%$, ilustrando o aumento exponencial da quantidade de iterações quando o valor de v tende a 1,00 para $p = 99\%$.

Figura 2.8 - Quantidade de iterações do algoritmo RANSAC para o ajuste de planos ($m = 3$), variando a probabilidade da amostra conter *outliers*.



Fonte: Elaborada pelo autor.

Quando as informações sobre o conjunto de dados são vagas ou inexistentes, normalmente estipula-se um valor alto para a probabilidade v de modo a ter um maior número de iterações, proporcionando uma maior chance de que um dos conjuntos de amostras selecionados aleatoriamente seja composta apenas por *inliers*.

No caso de aplicações onde são disponíveis as informações sobre o conjunto de dados (ou é possível extraí-las), pode-se estipular parâmetros mais coerentes na determinação do número de iterações e realizar a seleção das amostras de forma mais inteligente. Raguram et al (2008) apresenta um exemplo de aplicação do RANSAC para a orientação relativa de pares de imagens estereoscópicas, onde os algoritmos iniciam o processamento pelos pares de pontos homólogos com maior correlação, ou seja, os que possuem maior probabilidade de estarem corretos (*inliers*), reduzindo a quantidade de iterações.

O PROSAC (*Progressive Sample Consensus*) é similar ao RANSAC, diferindo-se apenas na sequência de extração do conjunto de amostras. Os dados iniciais são ordenados segundo um critério de qualidade qualquer (como o de similaridade, no caso de pontos homólogos em imagens), e a formação do conjunto de amostras é feita em ordem decrescente (RAGURAM et al, 2008).

Outro variante, o Lo-RANSAC (*Locally Optimized RANSAC*), opera sobre um novo conjunto de dados contendo apenas os *inliers* referentes à melhor solução obtida até então, porém realizando menos iterações. Segundo Raguram et al (2008), esta abordagem permite que o método atinja convergência mais rápida e apresenta maior robustez para amostras de dados afetadas por ruídos.

Tasha-Kurdi et al (2007) propõem uma variação do algoritmo RANSAC para a detecção de planos de telhados de edificações, adicionando um parâmetro referente ao número máximo de pontos pertencentes ao mesmo plano. O valor deste parâmetro pode ser deduzido da densidade da nuvem de pontos e da predição da área total ocupada por todos os telhados.

2.5 Classificação por análise de componentes principais

A Análise de Componentes Principais (ACP, do termo em inglês: *Principal Component Analysis* - PCA) é uma técnica de transformação de variáveis utilizada para encontrar componentes lineares de variáveis correspondentes por meio de cálculo de autovalores (ordenados de forma decrescente) e correspondentes autovetores de uma matriz de variâncias-covariâncias (MVC) ou de uma matriz de coeficientes de correlação entre variáveis (MINGOTI, 2007). De acordo com Landim (2011), é a mais antiga técnica de ordenação estudada e aplicada na solução de diversos problemas em Geociências, sendo fundamentada nos conceitos estatísticos e na teoria de álgebra linear.

Esta técnica consiste em uma transformação linear de n variáveis originais, normalmente correlacionadas entre si, em n novas variáveis não correlacionadas. As novas variáveis, denominadas de componentes principais, são geradas de modo que a primeira nova variável computada seja responsável pela maior variação possível no conjunto de dados; a segunda, pela maior variação possível restante, e assim por diante, até que toda a variação do conjunto tenha sido explicada (MINGOTI, 2007).

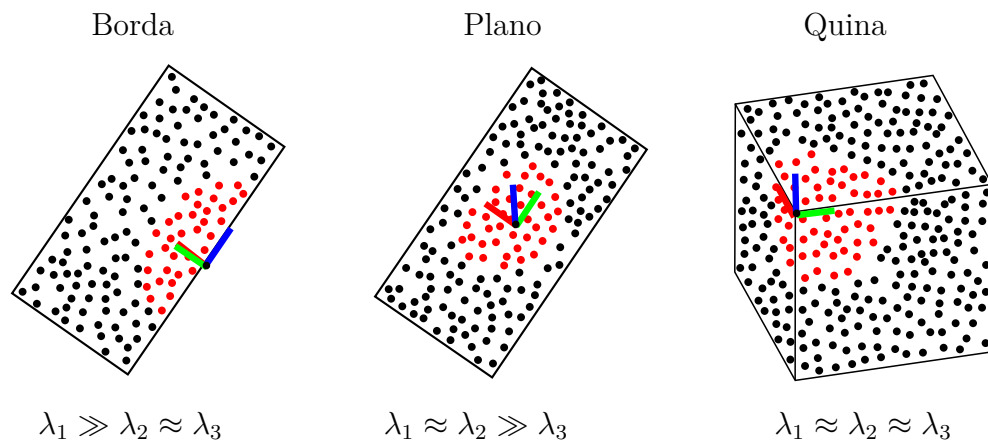
Considera-se cada variável medida como um eixo de variabilidade, sendo que os dados são transformados de modo a descrever a mesma variabilidade total existente, com o mesmo número de eixos originais, porém não mais correlacionados entre si. A posição espacial dos pontos permanece a mesma, mudam-se os eixos originais por uma transformação (THEODORIDIS e KOUTROUMBAS, 2009, p. 331).

No contexto de classificação de dados, a ACP pode ser utilizada como ferramenta para o reconhecimento de padrões a partir das propriedades estatísticas dos dados. Segundo Shi e Zakhor (2011), a ideia básica da classificação da nuvem de pontos utilizando ACP consiste em determinar as relações numéricas dos autovalores ($\lambda_1, \lambda_2, \lambda_3$) da Matriz de Variâncias e Covariâncias (MVC) de um subconjunto de pontos (considera-se

uma vizinhança a um ponto central).

As relações numéricas entre os autovalores permitem inferir sobre as estruturas (primitivas geométricas) presentes no contexto considerado (JUTZI e GROSS, 2009). A Figura 2.9 apresenta algumas estruturas e as relações entre os autovalores que indicam suas ocorrências.

Figura 2.9 - Autovalores relacionados as estruturas: borda, plano e quina.



Fonte: Figuras das estruturas adaptadas de Lichti (2009)¹. Relações entre os autovalores adaptadas de Shi e Zakhor (2011).

Na prática, a comparação numérica dos autovalores requer a utilização de limiares, pois a aritmética de ponto flutuante acarreta em alguns resíduos por conta de arredondamentos nas operações, impossibilitando a comparação direta (exata) entre duas variáveis. Deste modo, considerando dois limiares σ_{XY} e σ_Z , o teste para verificar se os autovalores correspondem a uma região plana pode ser escrito pela Equação 9:

$$\begin{cases} |\lambda_1 - \lambda_2| < \sigma_{XY} \\ |\lambda_3| < \sigma_Z \end{cases} \quad (9)$$

2.6 Segmentação por crescimento de regiões

As técnicas de segmentação por crescimento de regiões partem do princípio de que partes da imagem com características semelhantes devem pertencer a uma mesma entidade da imagem, e a união destas compõem uma região. Os pixels (regiões) que possuem propriedades similares são agrupados em segmentos. Uma medida de distância

¹LICHTI, D. Apresentação no Colóquio Brasileiro de Ciências Geodésicas - CBCG, Curitiba/PR, 2009.

(similaridade) deve ser empregada, assim como um critério (limiar) para o agrupamento espacial dos pixels (PIZARRO, CAMUNELLO e MANTELLI, 2005).

A vizinhança do pixel analisado pode ser definida a partir da conectividade da estrutura matricial, isto é, quais pixels adjacentes serão utilizados (EFFORD, 2000).

2.7 Elementos de avaliação quantitativa

Como pode ser visto em Wiedemann et al (1998) a avaliação quantitativa dos resultados pode ser feita com base nos índices de completeza e no nível de acerto. Adaptando este conceitos para o contexto em questão (classificação de nuvem de pontos), tem-se: A completeza (C) é o índice que mede a porcentagem da área de uma classe nos dados de referência, também classificados como sendo da mesma classe por meio do método proposto. Já o nível de acerto (A) representa a porcentagem dos pontos identificados como pertencentes a uma classe e que realmente fazem parte de tal classe.

$$C = \frac{n_{Ref}^{Rot}}{n_{Ref}} \quad e \quad A = \frac{n_{Ref}^{Rot}}{n^{Rot}}; \quad C, A \in [0, 1]. \quad (10)$$

onde: n_{Ref}^{Rot} representa o número de pontos rotulados em uma determinada classe, que pertencem a essa classe na referência; n_{Ref} corresponde ao número de pontos pertencentes a essa classe na referência; e n^{Rot} é o número de pontos rotulados a essa classe.

A qualidade (Q) é um índice do resultado final que leva em conta os valores da completeza e do nível de acerto. Apesar de não ter uma interpretação direta como a dos demais índices (completeza e nível de acerto), a qualidade generaliza a avaliação quantitativa em um único valor.

$$Q = \frac{CA}{C - CA + A} \quad Q \in [0, 1] \quad (11)$$

Os dados de referência podem ser obtidos manualmente, com base no conhecimento sobre o terreno disponível (visitas a campo e/ou imagens aéreas, por exemplo), ou utilizando resultados de classificação obtidos por outros softwares. Sithole e Vosselman (2004) apresentam um estudo no qual a referência utilizada nas análises quantitativas foi gerada manualmente.


3 MATERIAL E MÉTODO

3.1 Material

Os dados utilizados neste projeto são provenientes de duas fontes distintas. Inicialmente utilizou-se os dados LASER disponibilizados pela ISPRS (*International Society for Photogrammetry and Remote Sensing*) referentes a voos realizados pela empresa Fotonor-AS em um campo de testes em Vaihingen an der Enz e no centro de Stuttgart, ambos situados na Alemanha. Utilizou-se também dados disponibilizados pela empresa Sensormap Geotecnologia referentes a um voo realizado em Presidente Prudente-SP.

A aquisição dos dados da ISPRS foi feita no fim de 1999 com um LASER scanner modelo Teledyne Optech© ALTM 1210. Foram gravados o primeiro e último retorno de cada pulso. Os arquivos selecionados para serem utilizados neste trabalho apresentam densidade média² de 0,9 *pontos/m²*. A Figura 3.1 apresenta um dos arquivos contendo uma porção da região central de Stuttgart-DE.

Figura 3.1 - Malha regular (MDS) obtido a partir da interpolação dos dados de SVLA e imagem orbital do centro de Stuttgart-DE.



(a) Malha regular (Vizinho mais próximo: 0,50 m)



(b) Imagem aérea (out/2000)

Fonte: Dados LASER: *ISPRS Comission III, Working Group III/3*³. Imagem orbital: Google™ Earth.

Os dados disponibilizados pela Sensormap Geotecnologia foram adquiridos a partir de um voo realizado no dia 16 de dezembro de 2014. O sistema de varredura utilizado foi o RIEGL© modelo LMS Q680i. Os arquivos selecionados apresentam densidade mé-


²Densidade média calculada com o *lasinfo*, que difere do valor nominal informado nos metadados (0,67 *pontos/m²*)

³*ISPRS Test on extracting DEMs from point clouds: a comparison of existing automatic filters*. Disponível em: <<http://www.itc.nl/isprswgIII-3/filtertest/>>. Acesso em: 05 de jan. de 2014.

dia de 14,9 *pontos/m²*. A Figura 3.2 ilustra o recorte de uma das faixas do voo realizado contendo uma região de Presidente Prudente-SP.

Para a implementação dos algoritmos utilizou-se o Ambiente de Desenvolvimento Integrado (*Integrated Development Environment - IDE*) Code::Blocks versão 13.12 (<http://www.codeblocks.org/>). A geração dos arquivos executáveis foi feita com o compilador GCC/G++ (*Gnu Compiler Collection*) MinGW-w64. Escolheu-se este compilador devido ao fato da geração dos arquivos executáveis ser em 64 *bits*, o que permite ao aplicativo trabalhar com grandes arquivos de dados (milhões de pontos) sem que o Sistema Operacional limite a alocação de memória (1,8 GB nos executáveis 32 *bits*).

Figura 3.2 - Malha regular (MDS) obtido a partir da interpolação dos dados de SVLA e imagem aérea de um bairro de Presidente Prudente-SP.



(a) Malha regular (Vizinho mais próximo: 0,50 m)

(b) Imagem aérea (dez/2014)

Fonte: Dados LASER e imagens aéreas cedidas pela empresa Sensormap Geotecnologia em 2014.

A implementação foi feita na linguagem C++11 (ou C++0x) utilizando a STL (*Standard Template Library*) e os conceitos de Programação Orientada a Objetos (POO) e o paradigma de Programação Genérica, visando tornar o código modular e reutilizável. Além disso, algumas funções de primitivas gráficas da biblioteca OpenGL (*Open Graphics Library - www.opengl.org*) foram utilizadas para facilitar a visualização de alguns resultados.

A etapa de preparação que envolve o pré-processamento dos arquivos de dados e o recorte de regiões a partir de seus limites, foi realizada com o uso de algumas ferramentas do conjunto de aplicativos denominado LAsTools (www.rapidlasso.com/lastools/). Para a delimitação dos limites dos polígonos a serem recortados utilizou-se o aplicativo FugroViewerTM 2.0 (<http://www.fugroviewer.com/>).

3.2 Método de classificação proposto

O método proposto consiste de três partes principais: preparação dos dados; pré-classificação; e refinamento da classificação. Todos os subprocessos são executados em sequência, sem a interferência do operador, que por sua vez tem a possibilidade de estipular o valor de alguns parâmetros *a priori*:

- Espaçamento da malha regular;
- Limite de pontos de cada nó da *Quadtree*;
- Interpolador para a geração da malha regular;
- Dimensão e forma do EE para a filtragem do MDS;
- Dimensão da vizinhança (raio do círculo) para a classificação por ACP;
- Limiares para os autovalores (σ_{XY} e σ_Z);
- Limiar de área mínima para o Crescimento de Regiões; e
- Limiar de distância ao plano para a aplicação do algoritmo RANSAC.

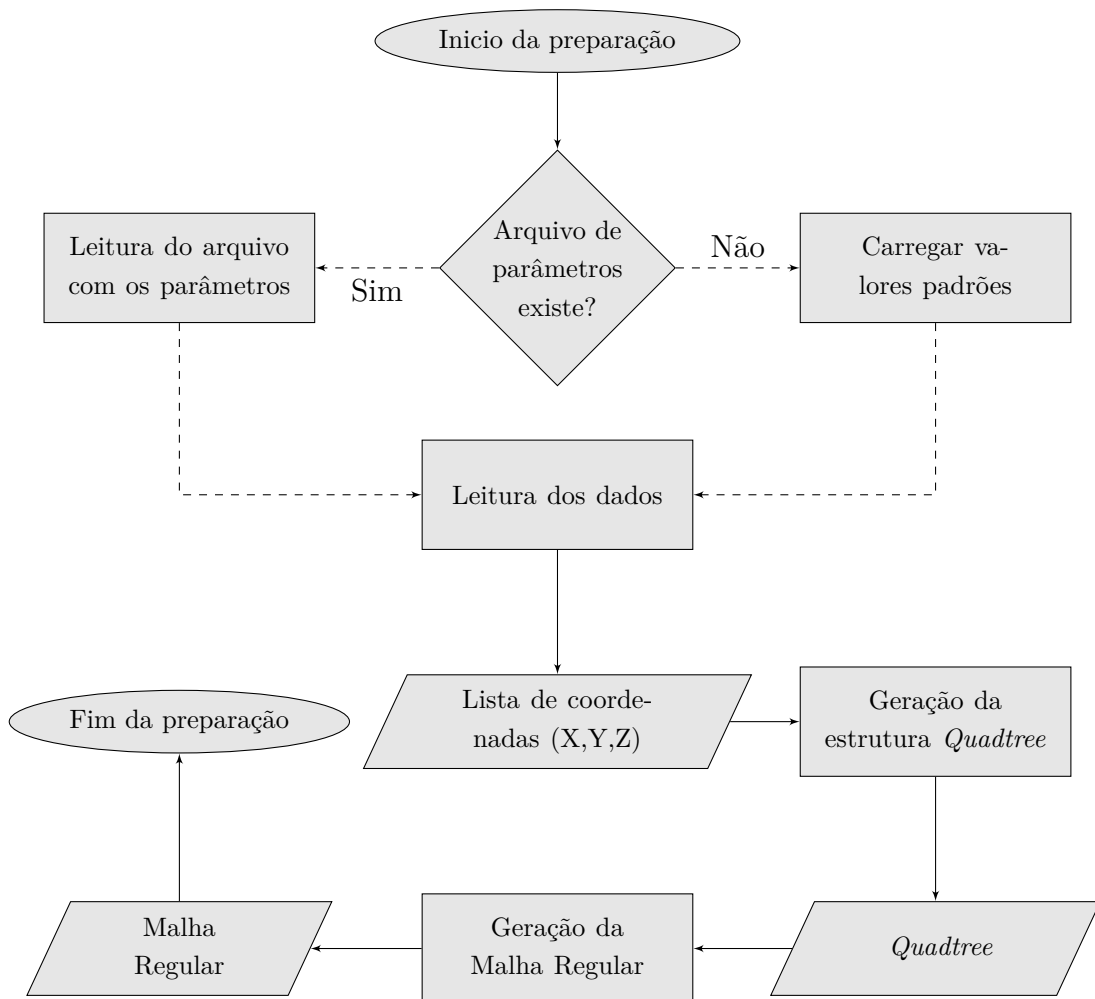
Tais parâmetros devem ter seus valores definidos em um arquivo separado, em formato XML (Apêndice A.3). Para o caso do operador não gerar o arquivo com os parâmetros, os valores padrão serão utilizados. Os valores padrão foram definidos de modo empírico, utilizando diferentes conjuntos de dados, com o intuito de proporcionar um funcionamento genérico para o executável.

O valor do espaçamento da malha regular foi definido arbitrariamente como 1 m, e pode ser alterado pelo usuário caso não esteja compatível com a taxa de amostragem original. Chegou-se ao valor de pontos limite para cada nó da *Quadtree* a partir da tentativa de minimizar a quantidade de subdivisões necessárias para armazenar a nuvem de pontos. As escolhas do interpolador (para a geração das malhas regulares), da dimensão e forma do EE para a filtragem do MDS, foram feitas a partir de experimentos detalhados nos itens 4.2 e 4.3 deste trabalho. Os valores dos demais limiares para as classificações foram escolhidos a partir de análises visuais dos resultados das classificações feitas durante a implementação do método.

A etapa de preparação dos dados, detalhado pelo fluxograma da Figura 3.3, consiste na geração da estrutura *Quadtree* e malha regular. Inicialmente é feita a delimitação da nuvem de pontos, isto é, obtenção da caixa envolvente (a partir das coordenadas mínimas e máximas) e na sequência, a geração da *Quadtree* é feita de forma automática a partir subdivisão recursiva desse volume, considerando o limite de pontos para cada nó, definido *a priori*.

Finalizada a criação da *Quadtree*, dá-se início à geração da malha regular, representada por uma estrutura matricial, obtendo o valor de cada elemento a partir da

Figura 3.3 - Fluxograma ilustrando o procedimento de preparação dos dados.



Fonte: Elaborada pelo autor.

interpolação das altitudes na nuvem de pontos. A consulta das altitudes, no entanto, é feita pela *Quadtree*, considerando uma pequena vizinhança, o que torna o processo mais rápido.

A malha regular resultante (MDS), quando entendida como uma imagem, admite a aplicação dos operadores da Morfologia Matemática. Neste sentido, inicia-se a etapa de pré-classificação, buscando primeiramente obter o MDT, ou seja, rotular quais pontos do MDS pertencem ao terreno.


A aplicação do operador abertura morfológica resulta numa malha regular (MDS^A) que se aproxima ao relevo do terreno. Uma alternativa mais rigorosa para a obtenção do MDT pode ser vista em Roggero (2001), na qual aplica-se uma limiarização que leva em conta o valor absoluto da diferença entre as altitudes de elementos correspondentes entre as duas malhas (MDS original e o resultado da operação de abertura, MDS^A). O valor

desta diferença ($\Delta h_{(i,j)}$), pode ser avaliado a partir de um limiar (δ_h), dessa maneira, o ponto $MDS_{(i,j)}$ é considerado como terreno quando a seguinte condição for verdadeira:

$$\Delta h_{(i,j)} = |MDS_{(i,j)} - MDS_{(i,j)}^A| < \delta_h \quad (12)$$

caso contrário, considera-se o valor de altitude $MDS_{(i,j)}^A$ para o ponto em questão. A Figura 3.4 apresenta o processo de limiarização aplicado ao resultado da abertura morfológica para a obtenção do MDT.

Figura 3.4 - Processo de limiarização aplicado ao resultado da abertura morfológica para a obtenção do MDT.



Fonte: Elaborada pelo autor.

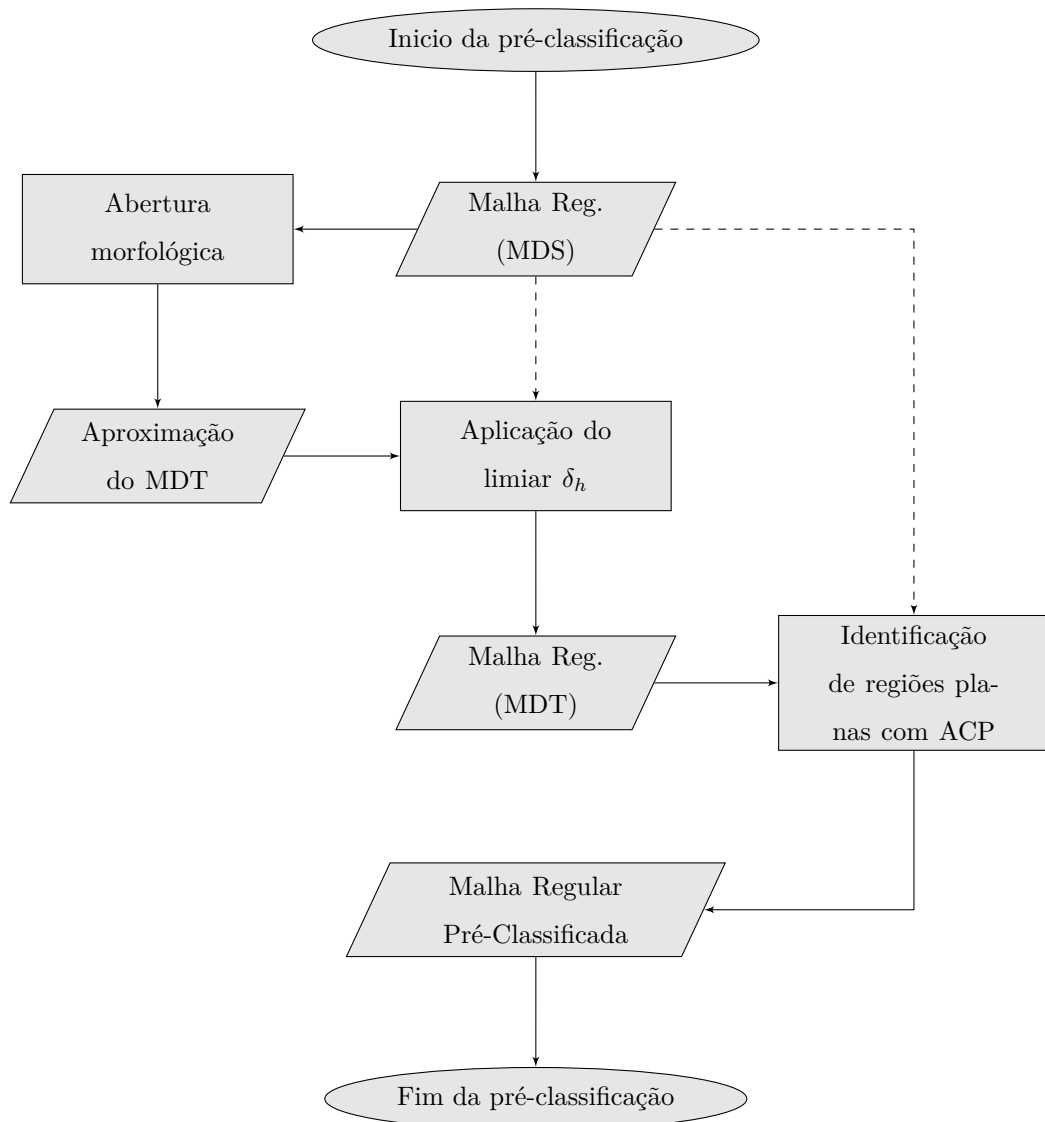
Após a obtenção do MDT, faz-se uma rotulação dos pontos do MDS em pertencentes ou não a planos, utilizando a Análise de Componentes Principais. Para a rotulação de um ponto considera-se uma vizinhança, tendo assim um subconjunto de pontos formando uma região. A escolha da vizinhança pode ser feita de modos diferentes, como por exemplo: considerando uma quantidade de pontos próximos fixa ou uma esfera de raio arbitrado por algum critério.

Com as coordenadas (X,Y,Z) dos pontos desta região, calcula-se a MVC e os respectivos autovalores. A partir da comparação numérica dos autovalores, dada pela Equação 9, utilizando os limiares estipulados, rotula-se o ponto central da região como sendo pertencente ou não a uma estrutura plana.

Os pontos que não foram rotulados como parte do MDT durante a filtragem, ou pertencentes às estruturas planas na aplicação de Análise de Componentes Principais, são rotulados como vegetação. O contraponto desta abordagem se dá pela rotulação errônea de objetos antrópicos não planares como pertencentes à vegetação, tais como placas de sinalização, infraestrutura elétrica (fiação), entre outros.

Ao final da etapa de pré-classificação, ilustrada na Figura 3.5, tem-se uma malha regular, que além da informação de elevação, apresenta os pontos rotulados dentre três classes: terreno, edificações (telhados) ou vegetação. Embora seja uma classificação aproximada, esta etapa permite estimar as probabilidades *a priori* necessárias para o cálculo do número limite de iterações do algoritmo RANSAC (Equação 8).

Figura 3.5 - Fluxograma ilustrando os passos da pré-classificação.



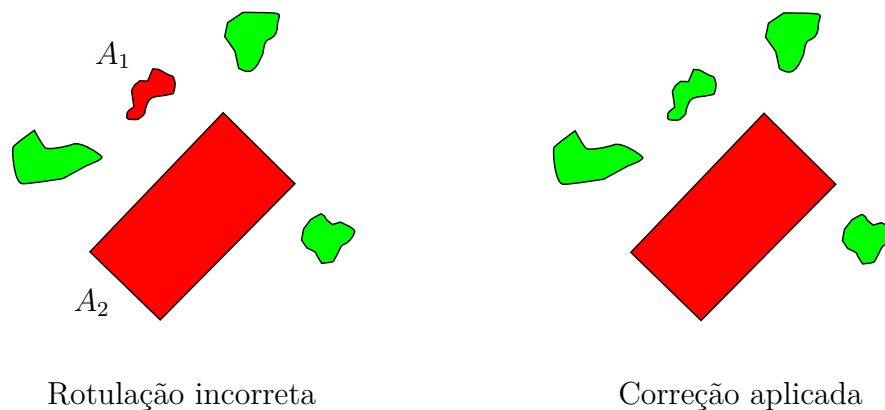
Fonte: Elaborada pelo autor.

Previamente à utilização do algoritmo RANSAC, verificou-se a necessidade de um processamento adicional, cujo intuito é a remoção de pequenas regiões (algumas copas de árvores) classificadas erroneamente como telhados. Para solucionar esse problema, optou-se por utilizar a segmentação por crescimento de regiões aplicada aos segmentos

de telhados gerados pela Análise de Componentes Principais, desta maneira, as regiões com área inferior a um determinado limiar são removidos da classe telhado, e seus pontos passam a ter o rótulo vegetação. Uma abordagem similar pode ser vista em (MOUSSA e EL-SHEIMY, 2010).

A Figura 3.6 ilustra um exemplo onde é mostrada uma região na qual um segmento rotulado erroneamente como telhado é identificado por possuir área inferior a um limiar estabelecido ($A_1 < A_{min}$). Na sequência uma correção é aplicada de modo a reclasificar todos os pontos do segmento como vegetação.

Figura 3.6 - Aplicação de limiar de área mínima aos segmentos de telhado.



Fonte: Elaborada pelo autor.

Na última etapa do processo (refinamento da classificação), é aplicado o algoritmo RANSAC em cada segmento da classe telhado. Tais segmentos podem conter um ou mais planos, dependendo das estruturas geométricas dos telhados. Deste modo, para cada telhado, aplica-se o algoritmo RANSAC iterativamente (removendo os pontos do consenso ao término de cada iteração), até que todos os pontos tenham sido designados a um plano ou não seja possível ajustar nenhum plano aos pontos restantes.

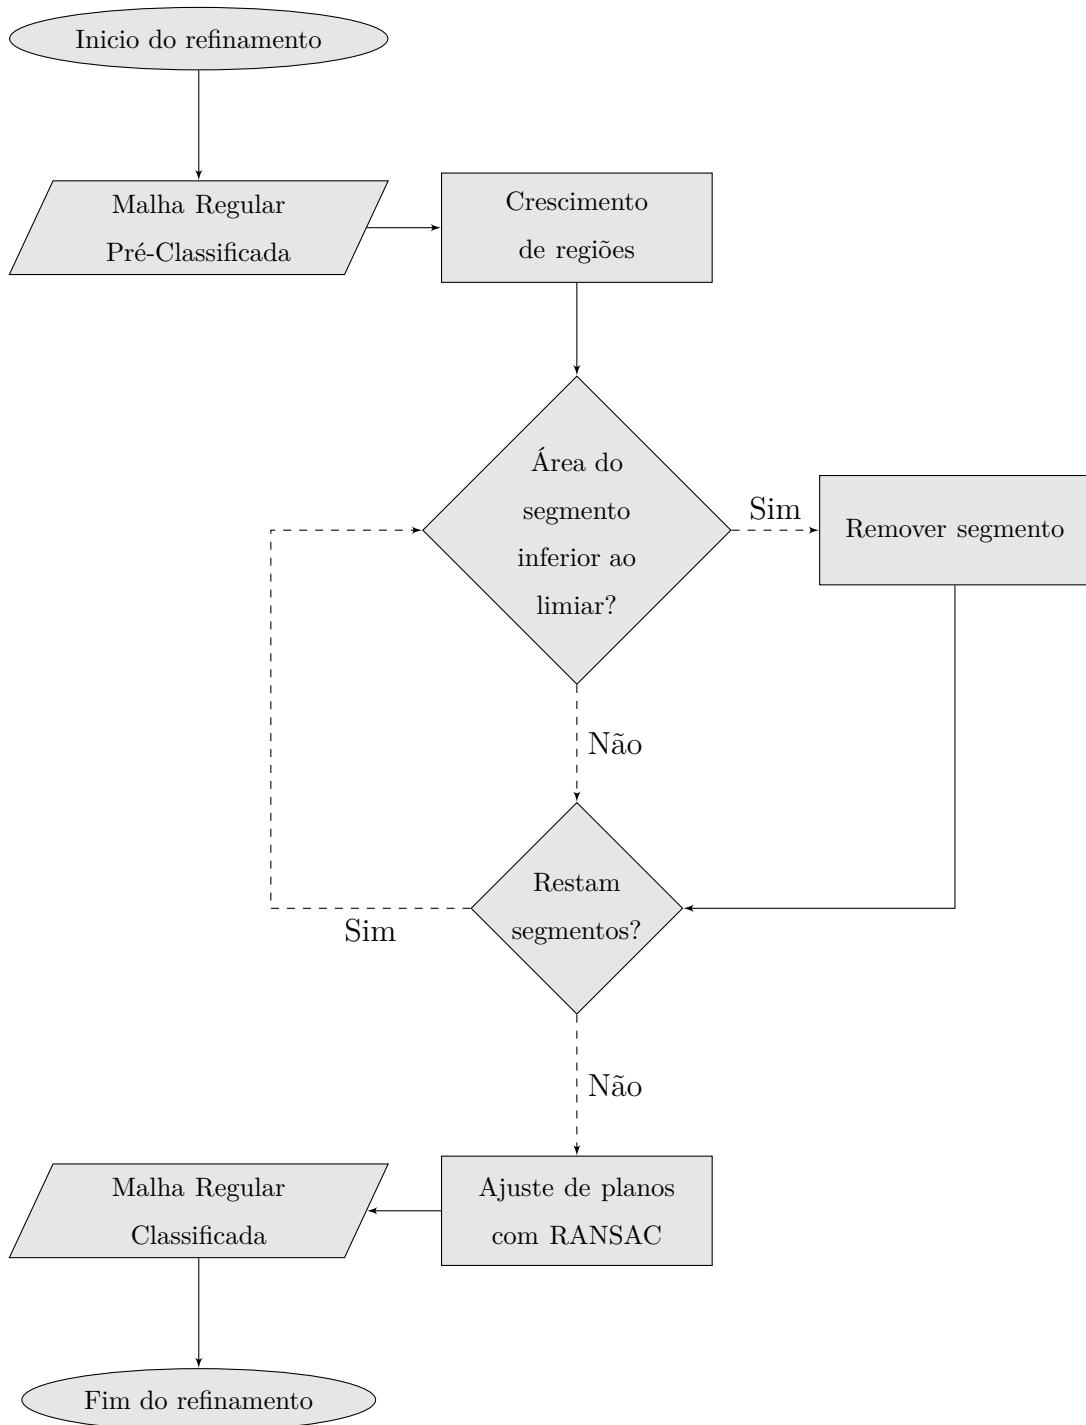
Para evitar problemas numéricos durante os cálculos (acarretados pela ordem de grandeza das coordenadas), translada-se todos os pontos do segmento para a origem do sistema de referência adotado. Após a aplicação do algoritmo RANSAC, tem-se uma lista de planos (vetor normal e o parâmetro d) para cada telhado.

A avaliação dos autovalores (realizada na pré-classificação) apresenta resultados equivocados nas bordas dos telhados, pois alguns pontos de outras feições podem estar presentes na vizinhança do ponto estudado. Para mitigar estes efeitos, todos os pontos designados aos planos pelo algoritmo RANSAC são rotulados como telhados.

Com isso, tem-se uma malha regular classificada, onde cada elemento da matriz

possui a informação de elevação e o rótulo (qual classe o ponto pertence). A Figura 3.7 apresenta o fluxograma com a etapa de refinamento da classificação.

Figura 3.7 - Fluxograma ilustrando o procedimento de refinamento da classificação.



Fonte: Elaborada pelo autor.

4 EXPERIMENTOS E DISCUSSÕES DOS RESULTADOS

Para a avaliação do método proposto, realizou-se três experimentos distintos: dois com o intuito de identificar particularidades sobre quais os efeitos que alguns parâmetros podem ocasionar aos resultados; e um para avaliar quantitativamente a classificação resultante da implementação. A seguir, os experimentos serão detalhados.

4.1 Descrição dos experimentos

O primeiro experimento tem o intuito de comparar os interpoladores vizinho mais próximo (*Nearest Neighbour*) e inverso do quadrado da distância euclidiana aplicados à geração de malhas regulares. A análise dos resultados deste experimento almejou a seleção do interpolador cujas características fossem relevantes para as etapas de detecção e extração de feições do método de classificação proposto.

No segundo experimento, buscou-se comparar a forma e a dimensão do elemento estruturante para a tarefa de filtragem da nuvem de pontos LASER utilizando a operação de abertura morfológica. Os dados de referência adotados na comparação foram obtidos com as ferramentas do LAStools.

O terceiro experimento foi realizado com o objetivo de avaliar quantitativamente os resultados da classificação da nuvem de pontos LASER utilizando o método proposto. Neste caso, entretanto, os dados de referência (classificação) foram gerados manualmente. No mesmo contexto, estudou-se os efeitos nos resultados da classificação ocasionados pela redução da densidade dos dados de Presidente Prudente.

4.2 Comparação dos interpoladores para a geração de malhas regulares

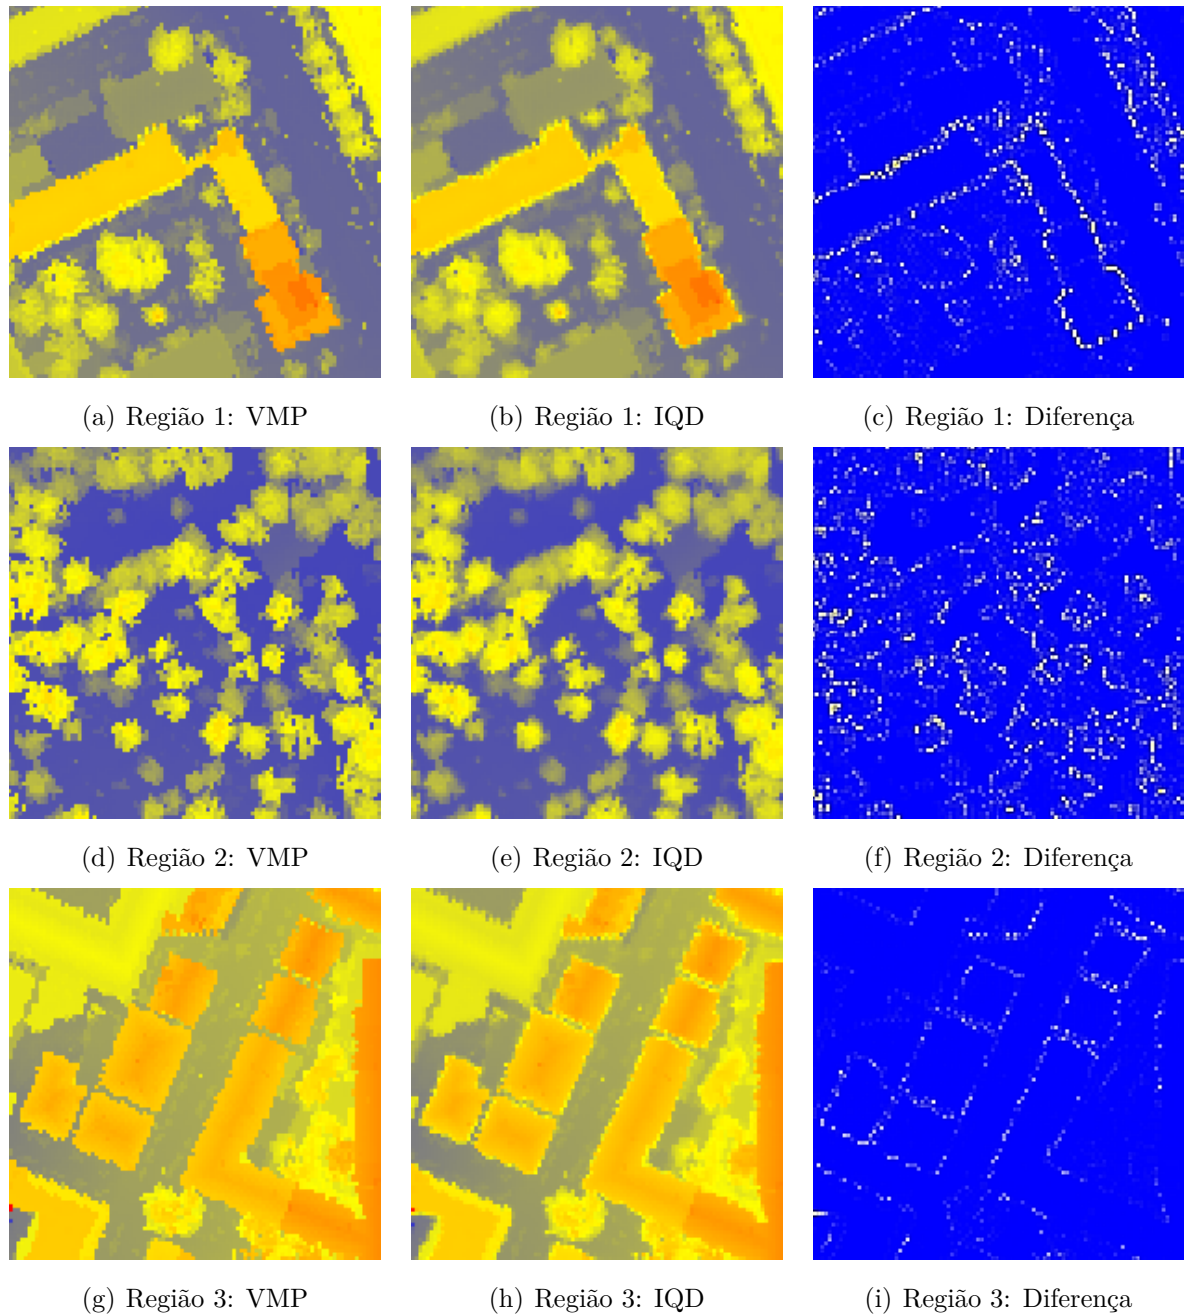
A análise dos interpoladores na geração de malhas regulares considerou três situações: região mista (S_1), com vegetação e edificações em proporções semelhantes; região com predominância de vegetação (S_2); e região com predominância de edificações (S_3). Dois arquivos de dados foram utilizados, um do centro de Stuttgart-DE (ISPRS) e o outro de uma porção de Presidente Prudente-SP (Sensormap).

Para cada conjunto de dados, gerou-se duas malhas regulares (considerando o mesmo espaçamento: 1,00 m), uma com o interpolador vizinho mais próximo (VMP) e a outra com o interpolador inverso do quadrado da distância (IQD). Uma terceira malha regular foi obtida a partir do valor absoluto da diferença entre as duas primeiras, a fim

de avaliar a discrepância entre elas.

As Figuras 4.1 e 4.2 ilustram a comparação realizada entre os dois interpoladores. A cor para cada ponto é obtida pela interpolação com base na altitude, isto é, os pontos mais baixos em tons azulados e os mais altos em tons de vermelho.

Figura 4.1 - Comparação dos interpoladores utilizando os dados de Stuttgart-DE.

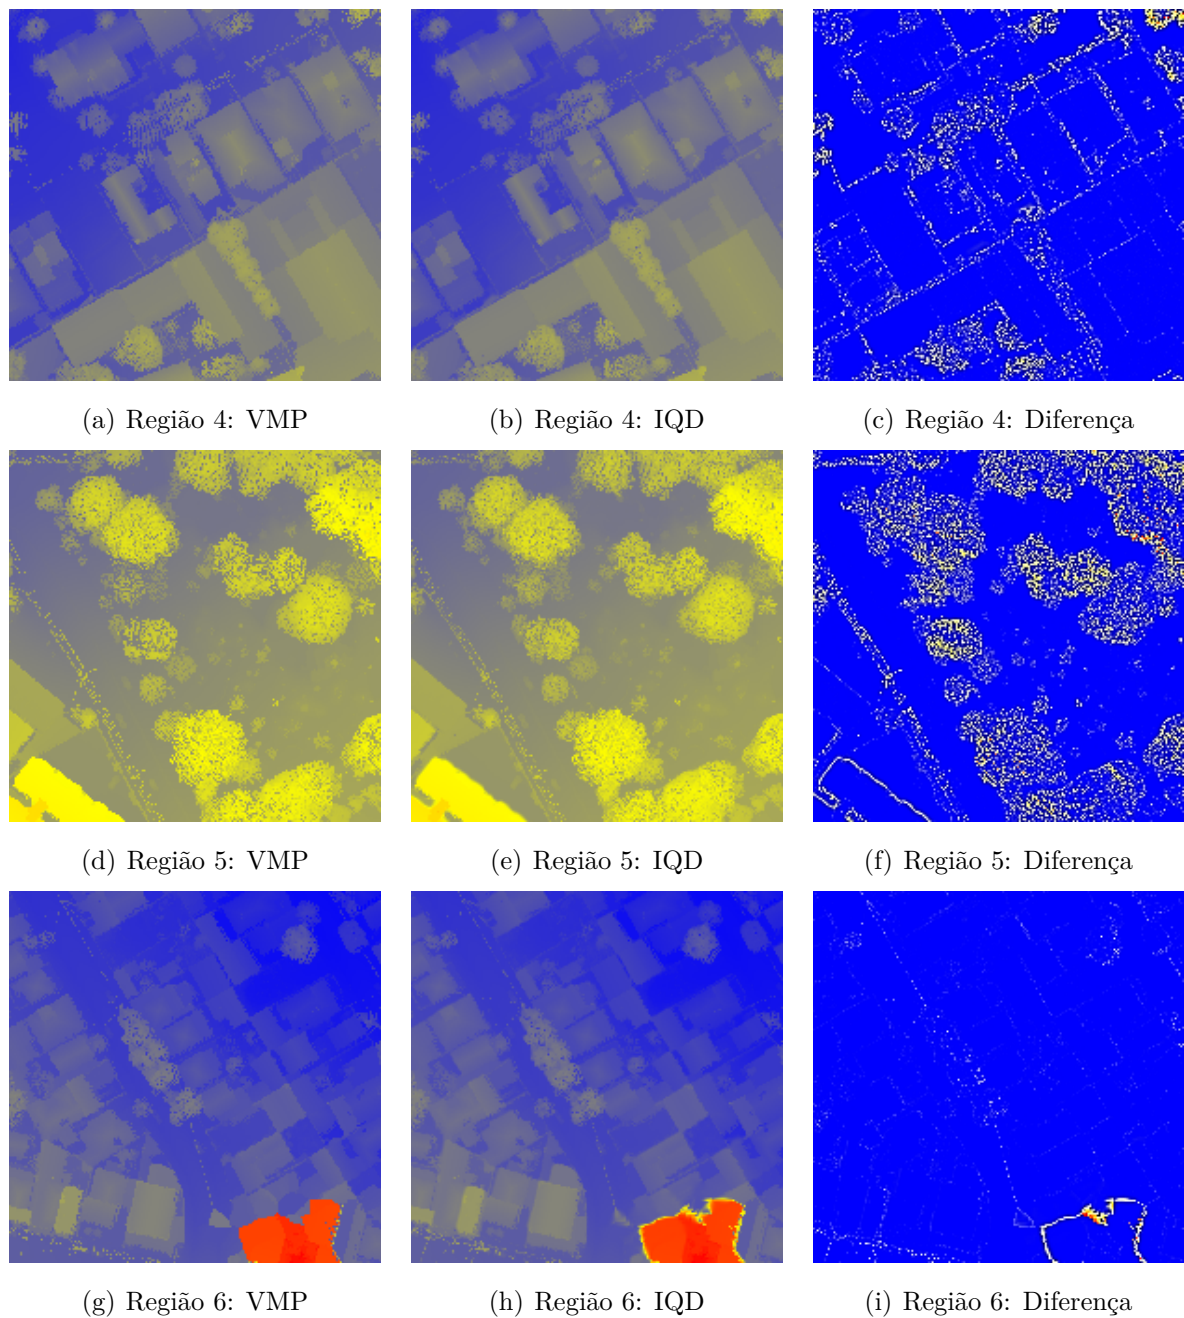


Fonte: Elaborada pelo autor.

Para cada uma das situações analisadas considerou-se um recorte de 100 m por 100 m nas malhas regulares. As regiões 1, 2 e 3 foram recortadas dos dados de

Stuttgart, enquanto que as regiões 4, 5 e 6 foram recortadas dos dados de Presidente Prudente. Por se tratar de dois arquivos de locais diferentes, buscou-se realizar recortes que apresentem características similares em cada conjunto de dados. Deste modo, as regiões 1 e 4 correspondem à situação S_1 , as regiões 2 e 5 à situação S_2 e as regiões 3 e 6 à situação S_3 .

Figura 4.2 - Comparação dos interpoladores utilizando os dados de Presidente Prudente.



Fonte: Elaborada pelo autor.

Observa-se as maiores diferenças (pontos amarelados e avermelhados) presentes

nas bordas das feições, ou seja, onde há um gradiente elevado. Outra característica notável é que as diferenças são maiores para as bordas das feições mais altas.

Na Tabela 4.1 encontram-se as diferenças média e máxima, estimadas para cada tipo de região (ou classe), a partir das diferenças determinadas ponto a ponto. Como pode ser visto, as maiores médias encontram-se nas regiões com predominância de vegetação, o que pode ser explicado pela maior quantidade de pontos com gradiente elevado (borda e interior das copas das árvores).

Para as regiões mistas e com predominância de edificações, onde ocorrem feições com padrões homogêneos (planos) e de grande dimensão em área (telhados e as vias), observou-se uma diminuição do valor médio da diferença para os dois conjuntos de dados.

A região 6 apresenta uma particularidade referente a uma edificação de altura desproporcional às demais (no entorno), o que influenciou principalmente no valor da diferença máxima (52,83 *m*).

Tabela 4.1 - Diferenças média e máxima entre as altitudes interpoladas.

Arquivo de dados	Região	Diferença [<i>m</i>]	
		Média	Máxima
Stuttgart	1 - Mista	0,504	18,170
	2 - Vegetação	0,740	15,887
	3 - Edificações	0,547	27,511
Presidente Prudente	4 - Mista	0,310	13,950
	5 - Vegetação	0,935	17,166
	6 - Edificações	0,379	52,829

O interpolador inverso do quadrado da distância tende a suavizar as bordas das feições, isto é, as regiões com gradiente elevado. Já o interpolador vizinho mais próximo preserva altitudes originais presentes na nuvem de pontos, embora em certos casos elas não correspondam exatamente às posições em que foram atribuídas.

Em aplicações de ajuste de primitivas à superfície (planos de telhados, por exemplo), a suavização introduzida pelo interpolador inverso do quadrado da distância pode acarretar em problemas nas regiões de borda, portanto, o interpolador vizinho mais próximo é mais indicado.

4.2.1 Melhoria no tempo de processamento para a geração de malhas regulares utilizando *Quadtree*


Com o intuito de validar a contribuição da estrutura *Quadtree* para a geração de malhas regulares, contabilizou-se o tempo de processamento desta etapa para arquivos com diferentes quantidades de pontos. Cada arquivo foi processado duas vezes (com e sem a *Quadtree*), e os resultados obtidos estão apresentados na Tabela 4.2.

Tabela 4.2 - Geração de malha regular. Melhoria no tempo de processamento com o uso de *Quadtree* para nuvens de pontos de diferentes tamanhos.

Número de pontos	Tempo de processamento [s]		Ganho (t_{SQ}/t_{CQ})
	Com <i>Quadtree</i> (t_{CQ})	Sem <i>Quadtree</i> (t_{SQ})	
188.168	1,14	481,99	422,4
539.874	1,95	1.245,20	637,6
3.060.879	6,88	8.445,46	1.228,2
6.228.651	27,24	193.394,40	7.099,1

O acréscimo do número de pontos acarreta em processamentos mais demorados para as duas situações estudadas, entretanto, este aumento no tempo de execução ocorre em taxas menores quando se utiliza de *Quadtrees*. Observa-se também que o ganho aumenta conforme a quantidade de pontos cresce, o que evidencia a eficiência da implementação com a estrutura *Quadtree*. A Figura 4.3 apresenta o gráfico do ganho de rendimento com o uso de *Quadtree* pelo número de pontos.

Figura 4.3 - Gráfico ilustrando o ganho de rendimento com o uso de *Quadtree* pelo número de pontos.



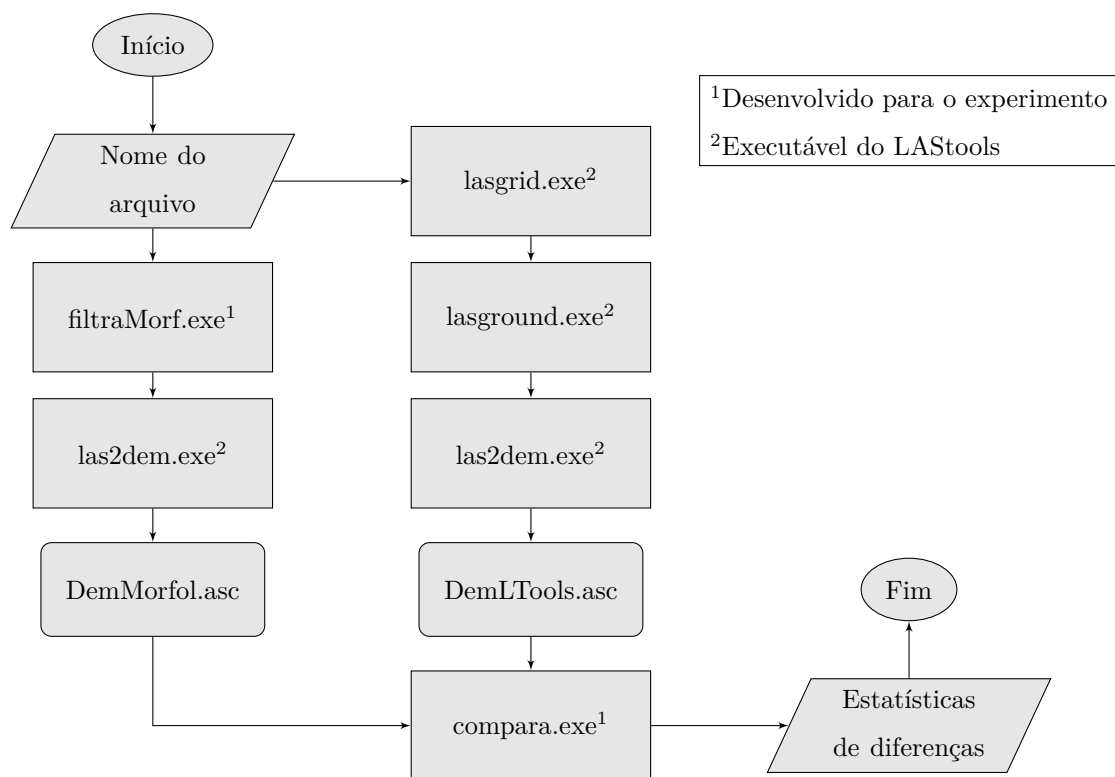
Fonte: Elaborada pelo autor.

Deste modo, assim como constatado em outros trabalhos (Liu et al, 2008; Kovač, 2009; Gluck, 2014), verifica-se a utilidade e o benefício no uso da estrutura *Quadtree* para tarefas que envolvem a manipulação de dados LiDAR, como a geração de malhas regulares. As melhorias envolvem a redução de recursos computacionais necessários para consultas à vizinhança do ponto a ser processado.

4.3 Comparação dos elementos estruturantes para a filtragem dos dados LASER

O objetivo deste experimento consiste na comparação de formas e dimensões do elemento estruturante na filtragem da nuvem de pontos LASER utilizando a operação de abertura morfológica. Os MDTs obtidos foram comparados com os resultados obtidos com as ferramentas do LAStools, considerados como referência. A Figura 4.4 apresenta a sequência de operações adotadas para a realização do experimento.

Figura 4.4 - Fluxograma com o procedimento utilizado para comparar os resultados da filtragem por Morfologia Matemática com os resultados do LAStools.



Fonte: Elaborada pelo autor.

Para facilitar a execução dos processamentos, gerou-se dois executáveis. O pri-

meiro (`filtraMorf.exe`) que realiza a filtragem utilizando a operação de abertura morfológica, já o segundo (`compara.exe`) compara dois arquivos contendo as duas malhas regulares com os MDTs obtidos pela filtragem morfológica e pelo LAStools.

De modo a compatibilizar a operação com o LAStools, os argumentos recebidos pelos programas são similares aos das ferramentas `lasground.exe` e `lasdiff.exe`. Uma descrição mais detalhada sobre os executáveis pode ser vista no Apêndice A.

Com relação às regiões de estudo foram consideradas três situações: região com predominância de edificações; região com predominância de vegetação; e região mista, com edificações e vegetação em proporções semelhantes. A Figura 4.5 apresenta as imagens aéreas referentes às três regiões adotadas.

Figura 4.5 - Imagens aéreas das regiões de estudo para a comparação da filtragem.



Fonte: Elaborada pelo autor.

Considerando as três regiões de estudo, aplicou-se o procedimento ilustrado na Figura 4.4 com o espaçamento da malha regular de 1 m, por conta de limitações na quantidade de pontos impostas nas versões gratuitas do LAStools. Com relação à filtragem, aplicou-se o operador de abertura com EEs de três formas distintas: Círculo, Cruz com “X” e Cruz. Para cada forma do EE foram utilizadas três dimensões: 27 m x 27 m, 37 m x 37 m e 47 m x 47 m.

Os valores máximos, mínimos, médios e os desvios-padrão das diferenças diretas e em módulo estão dispostos nas Tabelas C.1 a C.9 (Apêndice C). Para sumarizar a análise calculou-se as médias dos resultados de cada forma do EE em cada região (Tabela 4.3).

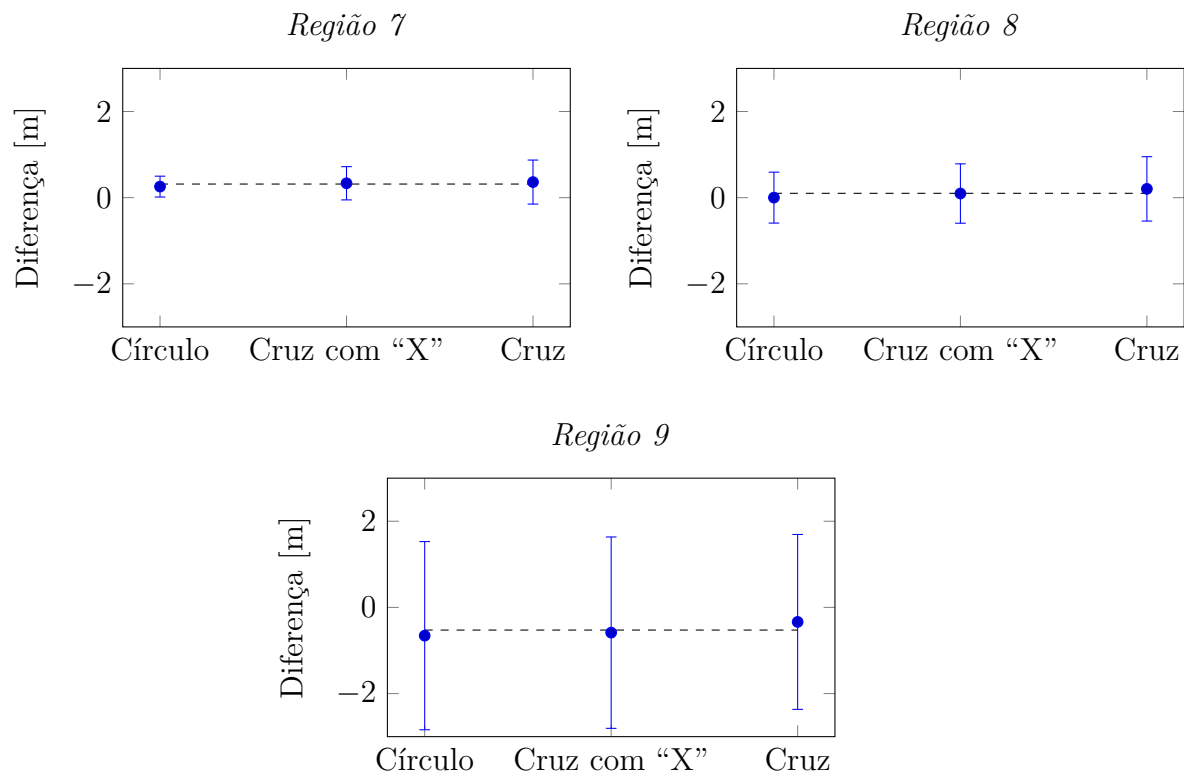
A Figura 4.6 apresenta os gráficos comparativos da média e desvio-padrão da diferença para cada formato de EE. Para as regiões 7 e 8, o EE círculo foi o que obteve os melhores resultados (menores valores de média e de desvio-padrão das diferenças). Já para a região 9 o melhor resultado obtido foi com o EE cruz.

Tabela 4.3 - Valores de média e desvio-padrão para as diferenças. Considerou-se os valores médios dos resultados entre as três dimensões de EE avaliadas.

	Círculo		Cruz com "X"		Cruz	
	Média [m]	D.P. [m]	Média [m]	D.P. [m]	Média [m]	D.P. [m]
Região 7	0,257	0,242	0,334	0,386	0,362	0,511
Região 8	0,001	0,591	0,096	0,689	0,204	0,747
Região 9	-0,656	2,184	-0,586	2,221	-0,337	2,030

De modo geral, os resultados obtidos pela filtragem utilizando morfologia matemática são próximos aos obtidos pelo método adotado pelo LAsTools. A forma e a dimensão do EE interferem na qualidade final do MDT filtrado, sendo que o formato de círculo foi o que apresentou melhores resultados.

Figura 4.6 - Gráficos comparativos da média e desvio-padrão da diferença para cada formato de Elemento Estruturante.



Fonte: Elaborada pelo autor.

A geometria das edificações também é um fator importante para a escolha do EE adequado. Na região 9 observa-se que os desvios-padrão são mais próximos, para os diferentes padrões de EE, diferente do que ocorre nas regiões 7 e 8 onde o EE círculo resulta nos menores desvios. Deste modo, considerando as diferentes regiões, pode-se assumir que o EE círculo pode ser o escolhido para a realização desta filtragem.

Analisando os valores de desvio-padrão, percebe-se que a região 9 apresenta valores maiores que as outras duas regiões. Essa diferença é atribuída ao fato de que ao contrário da operação de abertura morfológica, o LAStools não foi capaz de filtrar todas as edificações.

4.4 Avaliação quantitativa da classificação obtida pelo método proposto

O terceiro experimento tem o objetivo de avaliar quantitativamente os resultados da classificação da nuvem de pontos LASER utilizando o método proposto. A classificação de referência utilizada para o cálculo dos elementos de avaliação quantitativa foi gerada manualmente, com base em uma análise visual da nuvem de pontos e das imagens aéreas dos locais.


As classificações dos arquivos de dados foram realizadas com o executável `classifica.exe` (Apêndice A.3), utilizando os seguintes parâmetros:

- Espaçamento da malha regular: 0,50 *m*;
- Limite de pontos de cada nó da *Quadtree*: 300;
- Interpolador para a geração da malha regular: Vizinho mais próximo;
- Dimensão e forma do EE para a filtragem do MDS: Círculo com diâmetro de 47 *m*;
- Dimensão da vizinhança (raio do círculo) para a classificação por ACP: 3,50 *m*;
- Limiar de área mínima para o Crescimento de Regiões: 37,50 *m*²; e
- Limiar de distância ao plano para o RANSAC: 0,10 *m*.

A Figura 4.7 ilustra os resultados obtidos pelo método proposto com os parâmetros informados e a classificação de referência gerada manualmente, referentes aos dados de Stuttgart. A partir de uma análise visual, é possível identificar que assim como em outros trabalhos vistos na literatura, o método proposto apresenta dificuldades de classificação nas bordas dos telhados, principalmente em situações complexas onde pode ocorrer ambiguidades devido à presença de vegetação nos entornos das edificações.

Apesar da utilização do interpolador vizinho mais próximo para a geração da malha regular (ao invés do inverso do quadrado da distância), e do refinamento da detecção de planos com o algoritmo RANSAC, algumas bordas de telhados são rotuladas erroneamente como vegetação, e vice-versa, em poucos casos.

Figura 4.7 - Comparação da classificação com a referência considerando os dados de Stuttgart-DE.




(a) Resultado da classificação automática

(b) Referência gerada manualmente

Fonte: Elaborado pelo autor.

A Figura 4.8 apresenta os resultados obtidos pelo método proposto e a classificação de referência gerada manualmente, referentes aos dados de Presidente Prudente. Observa-se que mesmo com a aplicação do limiar de área mínima algumas copas de árvores possuem pontos rotulados erroneamente como telhados.

Figura 4.8 - Comparação da classificação com a referência considerando os dados de Presidente Prudente.



(a) Resultado da classificação automática

(b) Referência gerada manualmente

Fonte: Elaborado pelo autor.

A Tabela 4.4 apresenta os valores de completude e nível de acerto para as duas regiões, onde é possível verificar que das três classes, o terreno foi o que mais se aproximou dos dados de referência, ou seja, houve maior confusão entre as classes vegetação e edificações (telhados).

Tabela 4.4 - Análise quantitativa em termos de completeza e nível de acerto das malhas regulares classificadas, para os dois conjuntos de dados.

Arquivo de dados	Classe	Métrica	Valor
Stuttgart	Telhados	Completeza	0,7081
		Nível de acerto	0,9082
	Vegetação	Completeza	0,9445
		Nível de acerto	0,7476
	Terreno	Completeza	0,9526
		Nível de acerto	0,9852
Presidente Prudente	Telhados	Completeza	0,9118
		Nível de acerto	0,9229
	Vegetação	Completeza	0,9404
		Nível de acerto	0,9079
	Terreno	Completeza	0,9889
		Nível de acerto	0,9986

Os melhores resultados obtidos correspondem aos dados de Presidente Prudente/SP, nos quais os valores das métricas foram superiores a 90%. A classe terreno foi a que mais se aproximou da referência para os dois conjuntos de dados (Presidente Prudente e Stuttgart).

Para os dados de Stuttgart-DE, o pior resultado encontrado ocorreu na classe telhados, na qual a completeza foi de 0,7081, isto é, 29,19% dos pontos de telhados na classificação de referência deixaram de ser rotulados à esta classe pelo método. O nível de acerto da classe vegetação também foi baixo, apenas 74,76%.

A diferença entre os valores obtidos para os dois conjuntos de dados se justifica pela maior densidade nas nuvens de pontos de Presidente Prudente e por conta da complexidade dos telhados das edificações de Stuttgart ser maior, isto é, presença de pequenos objetos que confundem-se com o ruído dos dados LASER. Para estes casos outras abordagens podem ser aplicadas, seja no sentido de simplificação da geometria ou no adensamento da amostragem da nuvem de pontos.

Resultados similares podem ser vistos em Hermosilla et al (2011), em que o nível de acerto para a detecção de edificações variou de 50,00% e 71,90% até próximo a 100,00%, dependendo do método aplicado e da região estudada. Já em Buján et al (2012) os resultados da detecção de edificações apresentam nível de acerto entre 99,40% e 99,81%, a completeza, no entanto, foi de 92,57% na pior situação (baixa densidade de

pontos).

Os resultados apresentados por Hermosilla et al (2011) foram obtidos a partir da integração de dados radiométricos (imagens de alta resolução) e dados LiDAR. Duas abordagens são utilizadas: classificação por limiar e orientada a objetos. Buján et al (2012) utilizaram os conceitos de Support Vector Machines para integrar dados LiDAR e radiométricos provindos de ortoimagens.

Embora a comparação direta entre os valores não seja possível, por conta da diferença entre os dados utilizados e os algoritmos empregados, observa-se que a classificação obtida pelo método proposto apresenta resultados compatíveis com os relatados por outros autores.


4.4.1 Efeito da redução na densidade para os dados de Presidente Prudente

Por conta da grande diferença na taxa de amostragem dos dois conjuntos de dados, optou-se pela realização de avaliações adicionais, considerando a redução na densidade da nuvem de pontos de Presidente Prudente de modo a compatibilizar a densidade com os dados de Stuttgart.

Para reduzir a densidade da nuvem de pontos foi desenvolvido um executável que remove aleatoriamente 50% dos pontos originais, desta forma a densidade do arquivo é reduzida pela metade a cada iteração. A compatibilização das densidades entre os dois conjuntos de dados deu-se com a redução de um dezesseis-avos ($1/16$) da densidade original da nuvem de pontos de Presidente Prudente, resultando em $0,9 \text{ pontos}/m^2$.

A Figura 4.9 apresenta três recortes da mesma área de Presidente Prudente, em densidades distintas. Em (a) tem-se a densidade original, em (b) os dados possuem um quarto ($1/4$) da densidade original, isto é, $3,7 \text{ pontos}/m^2$ e em (c) um dezesseis-avos ($1/16$) da densidade original ou $0,9 \text{ pontos}/m^2$.

Figura 4.9 - Detalhe referente à redução na densidade dos dados de Presidente Prudente.



(a) $14,9 \text{ pontos}/m^2$

(b) $3,7 \text{ pontos}/m^2$

(c) $0,9 \text{ pontos}/m^2$

Fonte: Elaborada pelo autor.

Na Tabela 4.5 estão dispostos os valores dos índices de completeza, nível de acerto e qualidade calculados para as nuvens de pontos com densidades reduzidas. Observa-se a uma piora gradual nos resultados conforme a redução na densidade. A redução na densidade da nuvem de pontos teve pouco impacto para o índice nível de acerto da classe telhados, entretanto a qualidade da classificação da vegetação foi deteriorada, chegando em 56% no pior caso.

Tabela 4.5 - Análise quantitativa em termos de completeza (*C.*), nível de acerto (*N.A.*) e qualidade (*Q.*), considerando a redução na densidade da nuvem de pontos.

Densidade	Telhados			Vegetação			Terreno		
	<i>C.</i>	<i>N.A.</i>	<i>Q.</i>	<i>C.</i>	<i>N.A.</i>	<i>Q.</i>	<i>C.</i>	<i>N.A.</i>	<i>Q.</i>
7,4 pontos/m ²	0,87	0,90	0,79	0,84	0,79	0,69	0,93	0,94	0,89
3,7 pontos/m ²	0,85	0,88	0,77	0,79	0,74	0,62	0,91	0,92	0,84
1,9 pontos/m ²	0,84	0,88	0,76	0,77	0,71	0,59	0,89	0,90	0,81
0,9 pontos/m ²	0,82	0,88	0,74	0,75	0,69	0,56	0,88	0,89	0,79

Comparando os índices obtidos para a densidade de 0,9 pontos/m² com os resultados de Stuttgart (Tabela 4.4), observa-se que a completeza para a classe telhados é superior para os dados de Presidente Prudente (82% contra 70%), na mesma densidade. O nível de acerto permaneceu similar nas duas situações (88% e 90%).

Para as classes vegetação e terreno, tanto a completeza quanto o nível de acerto apresentaram-se melhores para os dados de Stuttgart. A análise destes resultados permite concluir que embora as classes vegetação e terreno tenham apresentado piores resultados para Presidente Prudente, a classificação de telhados das edificações foi melhor, pois estes são menos complexos quando comparados aos de Stuttgart.

No geral, percebe-se que ao reduzir a densidade a completeza decresce, como esperado. Em termos de nível de acerto, também observa-se uma redução, mas não tão significativa.

4.4.2 Refinamento da detecção de planos de telhados com RANSAC

Com relação ao refinamento da detecção de planos com o algoritmo RANSAC, foram analisadas algumas edificações do conjunto de dados de Presidente Prudente que apresentam telhados com geometrias diferentes. Gerou-se as representações dos planos em projeção perspectiva para uma inspeção visual.

A Figura 4.10 apresenta três situações referentes a detecção de planos de telhados com o algoritmo RANSAC, utilizando os dados de Presidente Prudente. Cada plano é

representado em uma cor distinta. Em (a) tem-se a detecção correta dos planos de duas edificações, já em (b) ocorrem problemas na edificação da esquerda. A terceira situação (c) ilustra um prédio cuja geometria do telhado acarreta na detecção incorreta dos planos.

Para as situações onde a detecção foi parcialmente correta ou incorreta, constata-se a necessidade de utilizar algum processamento adicional, como a avaliação de outro modelo matemático (não planar), ou então algum outro critério na seleção dos *inliers* no algoritmo RANSAC (além da distância entre o ponto e o plano).


Figura 4.10 - Detecção dos planos de telhados com RANSAC. Situações corretas e problemáticas. Dados de Presidente Prudente.




(a) Edificação 1




(b) Edificação 2




(c) Edificação 3



(d) Detecção correta



(e) Detecção parcialmente correta



(f) Detecção incorreta

Fonte: Elaborada pelo autor.

5 CONCLUSÕES

Neste trabalho foram revisados os conceitos necessários para o entendimento do método proposto, isto é, Sistemas de Varredura a LASER, estruturas para a representação de superfícies, interpoladores de dados, operadores de Morfologia Matemática, Análise de Componentes Principais, algoritmo RANSAC, segmentação por Crescimento de Regiões, e os elementos de avaliação quantitativa.

Para a geração de malhas regulares a partir de nuvens de pontos originalmente distribuídos de forma não regular, indicou-se o uso de estruturas hierárquicas como a *Quadtree*, que contribui na otimização do processamento, preservando as relações topológicas.

Quanto a comparação relativa entre os interpoladores vizinho mais próximo e inverso do quadrado da distância constatou-se que as maiores diferenças encontram-se nas regiões de borda, isto é, onde o gradiente de altura da malha regular possui resultante com valor elevado (regiões com variações abruptas no relevo).

Foram feitas algumas avaliações teóricas sobre a quantidade de iterações do algoritmo RANSAC e de como reduzi-la, seja pela utilização de um de seus variantes, ou obtendo informações *a priori* sobre as probabilidades envolvidas no cálculo. Uma alternativa para estimar esses valores é a utilização da Análise de Componentes Principais para realizar a pré-classificação da malha regular, permitindo deste modo a estimativa da área de algumas classes e portanto das probabilidades u e v .

Realizou-se experimentos para validar a aplicação de Morfologia Matemática para a filtragem de MDS, no qual foram comparados elementos estruturantes preenchidos com formato de disco, quadrado e em formato de cruz com “X”, em três dimensões diferentes. Observou-se a necessidade da escolha correta da dimensão do elemento estruturante para que as feições antrópicas e vegetação sejam removidas corretamente.

O formato círculo para o elemento estruturante foi o que apresentou melhores resultados para regiões de vegetação ou com edificações pequenas. Para áreas com grandes estruturas o elemento estruturante cruz foi o que mais se aproximou da filtragem feita pelo LAStools.

Observou-se que a filtragem de MDS utilizando Morfologia Matemática possui problemas ao ser aplicada a feições de grande extensão em área, como alguns telhados de edificações. Uma forma de contornar este problema é aumentando a dimensão do EE, entretanto, o aumento demasiado pode comprometer a qualidade do MDT resultante por conta da perda de detalhamento durante a operação de abertura morfológica.

Os resultados obtidos para a classificação dos dados mostraram que o método

proposto apresenta bons resultados, embora algumas situações possam ser problemáticas. Telhados com geometria complexa e copas de árvores muito grandes podem acarretar em ambiguidades na aplicação da Análise de Componentes Principais.

Como recomendações para trabalhos futuros, sugere-se a aplicação de operações para a análise da forma dos segmentos de telhados, como a assinatura, por exemplo. Essa abordagem pode ser útil para a rotulação correta dos pontos de borda dos telhados.

Por fim, sugere-se a aplicação do método para outros conjuntos de dados, como nuvens de pontos obtidas por outras técnicas fotogramétricas, como a correspondência de imagens aéreas. Além disso, propõe-se a avaliação de outros modelos matemáticos além de planos (tais como cilindros de seções circulares, seções elípticas e seções parabólicas) para a representação de edificações que apresentam telhados arcados.

Outras possibilidades que devem ser investigadas envolvem a integração das nuvens de pontos LiDAR com outras fontes de dados, como imagens ópticas por exemplo. A informação posicional acrescida da radiometria deve apresentar vantagens para a detecção das estruturas de interesse.

REFERÊNCIAS

- ABDUL-RAHMAN, A.; DESA, G. Identification of developable land using tin-based digital terrain modelling. *International Archives of Photogrammetry and Remote Sensing*, p. 7–11, 1996.
- ACHARJYA, P. P.; DAS, R.; GHOSHAL, D. Study and comparison of different edge detectors for image segmentation. *Global Journal of Computer Science and Technology Graphics and Vision*, p. 28–32, 2012.
- AGARWAL, P. K.; ARGE, L.; DANNER, A. From point cloud to grid dem: a scalable approach. *International Symposium on Spatial Data Handling*, p. 15, 2006.
- BALTSAVIAS, E. P. Airborne laser scanning: basic relations and formulas. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 54, n. 2, p. 199–214, 1999.
- BRENNER, C.; HAALA, N.; FRITSCH, D. Towards fully automated 3d city model generation. In: ABDELGUERFI, M. (Ed.) *3D Synthetic Environment Reconstruction*. Berlin: Kluwer Academic Publishers, 2001. p. 75–101.
- BUJÁN, S.; GONZÁLEZ-FERREIRO, E.; REYES-BUENO, F.; BARREIRO-FERNÁNDEZ, L.; CRECENTE, R.; MIRANDA, D. Land use classification from lidar data and ortho-images in a rural area. *The Photogrammetric Record*, v. 27, n. 140, p. 401–422, 2012.
- CARLBERG, M.; GAO, P.; CHEN, G.; ZAKHOR, A. Classifying urban landscape in aerial lidar using 3d shape analysis. *Image Processing (ICIP), 2009 16th IEEE International Conference on*, p. 1701–1704, 2009.
- DERPANIS, K. G. Overview of the ransac algorithm. 2010. Disponível em: http://www.cse.yorku.ca/~kosta/CompVis_Notes/ransac.pdf. Acesso em: 04 jan. 2014.
- DU, R.; LEE, H. J. Data compression system for lidar based on quad-tree structure. *Computing and Convergence Technology (ICCCT), 2012 7th International Conference on*, p. 1358–1363, 2012.
- DU, R.; LEE, H. J. Building extraction of lidar data based on quad-tree structure. *Journal of Convergence Information Technology*, v. 8, p. 529, 2013.
- EL-SHEIMY, N.; VALEO, C.; HABIB, A. *Digital terrain modeling: Acquisition, manipulation, and applications*. Artech House remote sensing library. London: Artech House, 2005.

- EFFORD, N. *Digital image processing: A practical introduction using java*. 1st. ed. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 2000.
- FELGUEIRAS, C. A.; CÂMARA, G. Introdução à geoinformática. 2001. Disponível em: <http://www.dpi.inpe.br/gilberto/livro/introd/index.html>. Acesso em: 17 nov. 2014.
- FERNANDEZ-DIAZ, J. C.; CARTER, W. E.; SHRESTHA, R. L.; GLENNIE, C. L. Now you see it. . . now you don't: Understanding airborne mapping lidar collection and data product generation for archaeological research in mesoamerica. *Remote Sensing*, v. 6, n. 10, p. 9951, 2014.
- FILIN, S. Surface clustering from airborne laser scanning data. *ISPRS Commission III Symposium "Photogrammetric Computer Vision"*, p. 119–124, 2002.
- FISCHLER, M. A.; BOLLES, R. C. Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography. *Commun. ACM*, v. 24, n. 6, p. 381–395, 1981.
- FORLANI, G.; NARDINOCCHI, C.; SCAIONI, M.; ZINGARETTI, P. Complete classification of raw lidar data and 3d reconstruction of buildings. *Pattern Analysis and Applications*, v. 8, n. 4, p. 357–374, 2006.
- GARCÍA-TEJERO, F. D. *Topografia abreviada*. 12. ed. Espanha: Mundi-Prensa, 1997.
- GLUCK, J.; DANNER, A. Fast gpgpu based quadtree construction. Technical report, Synergy Labs, Carnegie Mellon University, 2014.
- GONZALES, R. C.; WOODS, R. E. *Digital image processing*. third. ed. Upper Saddle River: Pearson Education, Inc., 2008.
- 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, 2011.
- IMHOF, E. *Cartographic relief presentation*. New York: Esri Press, 2007.
- JUTZI, B.; GROSS, H. Nearest neighbour classification on laser point clouds to gain object structures from buildings. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2009.
- KILIAN, J.; HAALA, N.; ENGLICH, M. Capture and evaluation of airborne laser scanner data. *International Archives of Photogrammetry and Remote Sensing*, p. 383–388, 1996.

- KOVAČ, B. An approach to visualization of large data sets from lidar. *Central European Seminar on Computer Graphics*, p. 8, 2009.
- LANDIM, P. M. B. *Análise estatística de dados geológicos multivariados*. São Paulo: Oficina de textos, 2011.
- LI, Z.; ZHU, C.; GOLD, C. *Digital terrain modeling: Principles and methodology*. New York: CRC Press, 2004.
- LI, J.; FAN, H.; MA, H.; GOTO, S. Determination of large-scale digital elevation model in wooded area with airborne lidar data by applying adaptive quadtree-based iterative filtering method. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, v. 38, p. 685–689, 2010.
- LINDENBERGER, J. Laser-profilmessungen zur topographischen geländeaufnahme. *Deutsche Geodätische Kommission*, v. C/400, p. 131, 1993.
- LIU, H.; HUANG, Z.; ZHAN, Q.; LIN, P. A database approach to very large lidar data management. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, v. 37(B1), p. 463–468, 2008.
- LOHMANN, P. Approaches to the filtering of laser scanner data. *International Archives of Photogrammetry and Remote Sensing*, v. 33, p. 540–547, 2000.
- LOHR, U. Digital elevation models by laser scanning. *The Photogrammetric Record*, v. 16, n. 91, p. 105–109, 1998.
- MENG, X.; CURRIT, N.; ZHAO, K. Ground filtering algorithms for airborne lidar data: A review of critical issues. *Remote Sensing*, v. 2, n. 3, p. 833, 2010.
- MINGOTI, S. *Análise de dados através de métodos de estatística multivariada: uma abordagem aplicada*. Belo Horizonte: Editora UFMG, 2005.
- MOUSSA, A.; EL-SHEIMY, N. Automatic classification and 3d modeling of lidar data. *Proceedings of the ISPRS Commission III symposium-PCV 2010*, 2010.
- NONATO, L. G. Quad-tree. tipos e estrutura de dados. 2000. Disponível em: <http://www.lcad.icmc.usp.br/~nonato/ED/Quadtree/quadtree.htm>. Acesso em: 21 nov. 2014.
- PACHECO, A. D. P.; CENTENO, J. A. S.; ASSUNÇÃO, M. G. T. D.; BOTELHO, M. F. Classificação de pontos lidar para a geração do mdt. *Boletim de Ciências Geodésicas*, v. 17, p. 417–438, 2011.

- PECKHAM, R.; JORDAN, G. *Digital terrain modelling: Development and applications in a policy support environment*. Lecture Notes in Geoinformation and Cartography. Berlin: Springer-Verlag, 2007.
- PEIXOTO, E. B. A.; CENTENO, J. A. S. Avaliação de filtros morfológicos para obtenção de modelo de drenagem a partir de dados laser. *Simpósio Brasileiro de Sensoriamento Remoto*, v. XIV, p. 5047–5054., 2009.
- POLODORIO, A. M.; TOMMASELLI, A. M. G.; IMAI, N. N.; GALO, M. L. B. T. Segmentação de corpos d'água em imagens multiespectrais e temporais usando watershed com marcadores automaticamente definidos. *Anais XII Simpósio Brasileiro de Sensoriamento Remoto*, p. 4249–4257, 2005.
- RAGURAM, R.; FRAHM, J.-M.; POLLEFEYS, M. A comparative analysis of ransac techniques leading to adaptive real-time random sample consensus. In: *Computer Vision–ECCV 2008*. Berlin: Springer-Verlag, 2008. p. 500–513.
- ROGGERO, M. Airborne laser scanning: Clustering in raw data. *International Archives of Photogrammetry Remote Sensing, Vol. XXXIV Part 3/W4*, p. 227–232, 2001.
- SAMET, H. *Applications of spatial data structures: Computer graphics, image processing, and gis*. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 1990.
- SERRA, J. *Image analysis and mathematical morphology*. Number v. 1 in Image Analysis and Mathematical Morphology. London: Academic Press, 1982.
- SHI, X.; ZAKHOR, A. Fast approximation for geometric classification of lidar returns. *Image Processing (ICIP), 2011 18th IEEE International Conference on*, p. 2925–2928, 2011.
- SITHOLE, G. Filtering of laser altimetry data using a slope adaptive filter. *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences*, v. 34, n. 3/W4, 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. Advanced Techniques for Analysis of Geo-spatial Data.
- SOHN, G.; DOWMAN, I. J. A model-based approach for reconstructing a terrain surface from airborne lidar data. *The Photogrammetric Record*, v. 23, n. 122, p. 170–193, 2008.
- TASHA-KURDI, F.; LANDES, T.; GRUSSENMEYER, P. Extended ransac algorithm for automatic detection of building roof planes from lidar data. *The Photogrammetric Journal of Finland*, v. 21, n. 1, p. 97–109, 2008.

- THEODORIDIS, S.; KOUTROUMBAS, K. Chapter 3 - linear classifiers. In: THEODORIDIS, S.; KOUTROUMBAS, K. (Eds.) *Pattern Recognition (Fourth Edition)*. Boston: Academic Press, fourth edition. ed., 2009. p. 91–150.
- TITTMANN, P.; SHAFII, S.; HARTSOUGH, B.; HAMANN, B. Tree detection and delineation from lidar point clouds using ransac. *Proceedings of Silvilaser 2011.*, 2011.
- VOSSELMAN, G. Slope based filtering of laser altimetry data. *International Archives of Photogrammetry and Remote Sensing*, v. 33, n. B3/2, p. 935–942, 2000.
- WACK, R.; WIMMER, A. Digital terrain models from airborne laser scanner data – agrid approach. *International Archives of Photogrammetry and Remote Sensing*, v. 34, p. 293–296, 2002.
- WEIDNER, U.; FÖRSTNER, W. Towards automatic building extraction from high-resolution digital elevation models. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 50, n. 4, p. 38–49, 1995.
- WEHR, A.; LOHR, U. Airborne laser scanning - an introduction and overview. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 54, p. 68–82, 1999.
- WIEDEMANN, C.; HEIPKE, C.; MAYER, H.; JAMET, O. Empirical evaluation of automatically extracted road axes. *Empirical Evaluation Techniques in Computer Vision*, p. 172–187, 1998.
- YAN, J.; JIANG, W.; SHAN, J. Quality analysis on ransac-based roof facets extraction from airborne lidar data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, v. 39, p. 367–372, 2012.

Apêndice A Descrição dos programas executáveis criados

A.1 Filtragem com abertura morfológica

O executável `filtraMorf.exe`, segue uma sintaxe similar ao aplicativo `las-ground.exe`, com exceção aos parâmetros, conforme seguinte exemplo:

```
filtraMorf.exe -i ArquivoEntrada.las -o ArquivoSaida.xyz -parametros
```

onde: os parâmetros são: “`step`”: espaçamento da grade regular (em metros); “`se_size`”: dimensão do elemento estruturante (em pixels); “`se_shape`”: formato do elemento estruturante, podendo ser “`rect`” para retângulo, “`cross`” para cruz e “`crossx`” para cruz com “X”.

A.2 Comparação de grades regulares

O executável `compara.exe` possui uma sintaxe similar ao aplicativo `lasdiff.exe`, isto é, como entrada tem-se os arquivos com as grades regulares (que devem ter a mesma dimensão e mesma origem), e como saída o executável apresenta as estatísticas e armazena a grade regular com as diferenças em um arquivo ASCII (*American Standard Code for Information Interchange*). Exemplo de uso:

```
compara.exe -i Arquivo1.asc -i Arquivo2.asc -o ArquivoDiferenca.asc
```

A.3 Classificação de nuvem de pontos

O executável `classifica.exe` apresenta uma sintaxe própria, sendo necessário dois arquivos de entrada (um com os dados e outro com os parâmetros) e um de saída. O arquivo com a nuvem de pontos pode estar em dois formatos: “.las” ou “.xyz”, conforme o seguinte exemplo.

```
classifica.exe -i ArquivoPontos -i ArquivoConfig -o ArquivoClassificado
```

O arquivo de saída possui uma formatação simples, sendo que cada linha representa um ponto: o primeiro valor informa o rótulo do ponto, e na sequência tem-se as três coordenadas (X, Y, Z). A rotulação dos pontos é feita a partir de um caracter, podendo ser “v” para vegetação, “t” para telhados e “c” para chão. Segue exemplo de uma linha, com a especificação do tipo da variável.

```
(char)rótulo (float)coord_x (float)coord_y (float)coord_z
```

O arquivo de configuração da classificação possui sintaxe baseada em estrutura XML, de modo a codificar os parâmetros. A formatação básica do arquivo requer a definição dos seguintes valores:

```
<?xml version="1.0" encoding="UTF-8"?>
<filter_parameters>
  <structure_element unit="pixel">
    <math_morph size="95" />
    <ransac_plane size="9" />
    <pca_plane size="5" />
  </structure_element>
  <princ_comp_analysys>
    <lambda_xy value="0.35" />
    <lambda_z value="0.2" />
  </princ_comp_analysys>
  <ransac unit="meter">
    <plane_threshold value="0.15" />
  </ransac>
  <ground_threshold value="3.0" unit="meter" />
</filter_parameters>
```

A.4 Cálculo dos elementos de avaliação quantitativa

Para o cálculo dos elementos de avaliação quantitativa da classificação, foi desenvolvido e utilizado o executável `quantifica.exe`. Como entrada tem-se o resultado da classificação obtida com o `classifica.exe` e um arquivo de referência (gerado manualmente). A saída deste aplicativo é um arquivo de texto contendo as estatísticas calculadas. Segue exemplo de uma linha de comando:

```
quantifica.exe -i ArquivoClasses -i ArquivoReferencia -o ArquivoEstatisticas
```

Apêndice B Leitura de dados no formato LAS

O formato de arquivos “.las” foi padronizado pela ASPRS (*American Society for Photogrammetry and Remote Sensing*) com o intuito de possibilitar o intercâmbio de informações de forma eficiente e independente de soluções comerciais.

Por ser um formato binário, os arquivos “.las” apresentam vantagens com relação aos arquivos de texto ASCII. A leitura é mais rápida, pois não requer a conversão de texto para ponto flutuante, além de apresentar dimensão reduzida.

Estão disponíveis no site da ASPRS (<http://www.asprs.org/Committee-General/LASer-LAS-File-Format-Exchange-Activities.html>) todas as especificações para os formatos (em suas versões, desde a 1.0 à 1.4).

Caso o interesse seja apenas pelas coordenadas (X, Y, Z) de um arquivo “.las”, a leitura dessas informações pode ser feita de modo simplificado, utilizando a linguagem C, por exemplo. As seguintes estruturas podem ser consideradas para representar um ponto e um arquivo, respectivamente:

```
typedef struct {
    double x;
    double y;
    double z;
} LAS_Point;

typedef struct {
    int numPoints;
    LAS_Point* arrPoints;

    double scaleFactor [3];
    double offsetFactor [3];
} LAS_File;
```

A função `LAS_ReadHeader` pode ser utilizada para a leitura dos dados do cabeçalho do arquivo, necessárias para a interpretação do restante das informações (carregamento e cálculo das coordenadas dos pontos). Esta função também se encarrega de alocar a memória dinamicamente para os pontos. Observa-se que apesar do cabeçalho conter diversas informações, a leitura das coordenadas requer apenas a quantidade de pontos e os fatores de escala e translação.

```

void LAS_ReadHeader(FILE* inputFile , LAS_File* lasFile)
{
    // Reads the number of points
    fseek(inputFile , 107, SEEK_SET);
    fread(& lasFile->numPoints , sizeof(int) , 1, inputFile);

    // Reads the scale factor
    fseek(inputFile , 131, SEEK_SET);
    fread(& lasFile->scaleFactor , sizeof(double) , 3, inputFile);

    // Reads the offset factor
    fseek(inputFile , 155, SEEK_SET);
    fread(& lasFile->offsetFactor , sizeof(double) , 3, inputFile);

    // Allocating the array
    lasFile->arrPoints = (LAS_Point*)
        malloc(lasFile->numPoints * sizeof(LAS_Point));
}

```

A leitura e cálculo das coordenadas, no entanto, requer uma iteração dentro do arquivo, buscando apenas os primeiros doze **bytes** de cada registro de um ponto. Os registros podem conter mais informações além das coordenadas, como valor de intensidade e rótulo, por exemplo. Nestes casos é necessário atentar para a quantidade de **bytes** entre registros consecutivos.

A função `LAS_ReadFile` se encarrega da leitura das coordenadas dos pontos do arquivo. É necessário que os ponteiros sejam válidos, e que o arquivo já tenha sido aberto. Nesta abordagem não é feita nenhuma verificação de integridade do arquivo, entretanto a função é capaz de obter as coordenadas independente da versão do formato.

```

void LAS_ReadFile(FILE* inputFile , LAS_File* lasFile)
{
    LAS_ReadHeader(inputFile , lasFile);

    short prl;
    int prs , bcr , oft , itr;

    // Reading the point record length
    fseek(inputFile , 105, SEEK_SET);
    fread(& prl , sizeof(short) , 1, inputFile);

    // Computing the step between point records
    prs = prl - 3 * sizeof(int);
}

```

```
// Seek the point data
fseek(inputFile, 96, SEEK_SET);
fread(&oft, sizeof(int), 1, inputFile);
fseek(inputFile, oft, SEEK_SET);

for (itr = 0; itr < lasFile->numPoints; itr++)
{
    // Coordinate X
    fread(&bcr, sizeof(int), 1, inputFile);
    lasFile->arrPoints[itr].x = bcr *
        lasFile->scaleFactor[0] + lasFile->offsetFactor[0];

    // Coordinate Y
    fread(&bcr, sizeof(int), 1, inputFile);
    lasFile->arrPoints[itr].y = bcr *
        lasFile->scaleFactor[1] + lasFile->offsetFactor[1];

    // Coordinate Z
    fread(&bcr, sizeof(int), 1, inputFile);
    lasFile->arrPoints[itr].z = bcr *
        lasFile->scaleFactor[2] + lasFile->offsetFactor[2];

    fseek(inputFile, prs, SEEK_CUR);
}
}
```

Apêndice C Resultados adicionais do segundo experimento

Tabela C.1 - Diferenças diretas e em módulo para a filtragem do terreno das três regiões. EE: Círculo, dimensão 27 m x 27 m.

Diferença [m]	Região 7		Região 8		Região 9	
	Direta	Módulo	Direta	Módulo	Direta	Módulo
Máxima	2,620	2,620	4,110	4,110	11,780	11,780
Mínima	-0,490	0,000	-3,510	0,000	-11,730	0,000
Média	0,267	0,270	0,070	0,235	-0,359	0,657
Desvio-Padrão	0,245	0,242	0,447	0,386	1,815	1,730

Tabela C.2 - Diferenças diretas e em módulo para a filtragem do terreno das três regiões. EE: Círculo, dimensão 37 m x 37 m.

Diferença [m]	Região 7		Região 8		Região 9	
	Direta	Módulo	Direta	Módulo	Direta	Módulo
Máxima	2,630	2,630	3,060	3,960	3,940	11,730
Mínima	-0,520	0,000	-3,960	0,000	-11,730	0,000
Média	0,259	0,264	-0,020	0,294	-0,781	0,957
Desvio-Padrão	0,242	0,237	0,663	0,594	2,371	2,306

Tabela C.3 - Diferenças diretas e em módulo para a filtragem do terreno das três regiões. EE: Círculo, dimensão 47 m x 47 m.

Diferença [m]	Região 7		Região 8		Região 9	
	Direta	Módulo	Direta	Módulo	Direta	Módulo
Máxima	2,630	2,630	3,060	3,960	3,950	11,730
Mínima	-0,830	0,000	-3,960	0,000	-11,730	0,000
Média	0,245	0,253	-0,046	0,295	-0,828	0,985
Desvio-Padrão	0,241	0,233	0,663	0,595	2,366	2,305

Tabela C.4 - Diferenças diretas e em módulo para a filtragem do terreno das três regiões. EE: Cruz com “X”, dimensão 27 m x 27 m.

Diferença [m]	Região 7		Região 8		Região 9	
	Direta	Módulo	Direta	Módulo	Direta	Módulo
Máxima	2,860	2,860	3,500	3,590	11,880	11,880
Mínima	-0,450	0,000	-3,590	0,000	-11,730	0,000
Média	0,343	0,346	0,162	0,304	-0,339	0,742
Desvio-Padrão	0,366	0,363	0,560	0,498	1,856	1,735

Tabela C.5 - Diferenças diretas e em módulo para a filtragem do terreno das três regiões. EE: Cruz com “X”, dimensão 37 m x 37 m.

Diferença [m]	Região 7		Região 8		Região 9	
	Direta	Módulo	Direta	Módulo	Direta	Módulo
Máxima	3,040	3,040	3,500	3,960	4,100	11,730
Mínima	-0,760	0,000	-3,960	0,000	-11,730	0,000
Média	0,345	0,354	0,052	0,357	-0,699	1,003
Desvio-Padrão	0,384	0,375	0,742	0,652	2,403	2,293

Tabela C.6 - Diferenças diretas e em módulo para a filtragem do terreno das três regiões. EE: Cruz com “X”, dimensão 47 m x 47 m.

Diferença [m]	Região 7		Região 8		Região 9	
	Direta	Módulo	Direta	Módulo	Direta	Módulo
Máxima	3,040	3,040	3,500	4,570	4,060	11,730
Mínima	-2,050	0,000	-4,570	0,000	-11,730	0,000
Média	0,316	0,350	0,074	0,379	-0,722	1,018
Desvio-Padrão	0,410	0,381	0,767	0,671	2,404	2,294

Tabela C.7 - Diferenças diretas e em módulo para a filtragem do terreno das três regiões. EE: Cruz, dimensão 27 m x 27 m.

Diferença [m]	Região 7		Região 8		Região 9	
	Direta	Módulo	Direta	Módulo	Direta	Módulo
Máxima	8,130	8,130	4,670	4,670	11,870	11,870
Mínima	-0,490	0,000	-3,510	0,000	-9,510	0,000
Média	0,458	0,460	0,292	0,379	0,219	0,561
Desvio-Padrão	0,822	0,821	0,668	0,623	1,298	1,191

Tabela C.8 - Diferenças diretas e em módulo para a filtragem do terreno das três regiões.
EE: Cruz, dimensão 37 m x 37 m.

Diferença [m]	Região 7		Região 8		Região 9	
	Direta	Módulo	Direta	Módulo	Direta	Módulo
Máxima	3,490	3,490	6,040	6,040	4,620	11,730
Mínima	-0,490	0,000	-3,910	0,000	-11,730	0,000
Média	0,314	0,317	0,167	0,417	-0,562	0,986
Desvio-Padrão	0,336	0,333	0,806	0,710	2,383	2,241

Tabela C.9 - Diferenças diretas e em módulo para a filtragem do terreno das três regiões.
EE: Cruz, dimensão 47 m x 47 m.

Diferença [m]	Região 7		Região 8		Região 9	
	Direta	Módulo	Direta	Módulo	Direta	Módulo
Máxima	3,660	3,660	3,480	3,910	3,940	11,730
Mínima	-0,490	0,000	-3,910	0,000	-11,730	0,000
Média	0,315	0,318	0,153	0,392	-0,669	1,010
Desvio-Padrão	0,346	0,343	0,769	0,679	2,411	2,290