

UNIVERSIDADE ESTADUAL PAULISTA

CAMPUS DE PRESIDENTE PRUDENTE

FACULDADE DE CIÊNCIAS E TECNOLOGIA

Programa de Pós-Graduação em Ciências Cartográficas

VANESSA JORDÃO MARCATO FERNANDES

**EXTRAÇÃO DE CONTORNOS DE TELHADOS DE EDIFÍCIOS A PARTIR DA
INTEGRAÇÃO DE IMAGEM AÉREA DE ALTA-RESOLUÇÃO E DADOS LASER,
UTILIZANDO CAMPOS ALEATÓRIOS DE MARKOV**



PRESIDENTE PRUDENTE

2016

UNIVERSIDADE ESTADUAL PAULISTA

CAMPUS DE PRESIDENTE PRUDENTE

FACULDADE DE CIÊNCIAS E TECNOLOGIA

Programa de Pós-Graduação em Ciências Cartográficas

VANESSA JORDÃO MARCATO FERNANDES

**EXTRAÇÃO DE CONTORNOS DE TELHADOS DE EDIFÍCIOS A PARTIR DA
INTEGRAÇÃO DE IMAGEM AÉREA DE ALTA-RESOLUÇÃO E DADOS LASER,
UTILIZANDO CAMPOS ALEATÓRIOS DE MARKOV**



Tese apresentada ao Programa de Pós-Graduação em Ciências Cartográficas da Faculdade de Ciências e Tecnologia – UNESP campus de Presidente Prudente.

Orientador: Prof. Dr. Aluir Porfírio Dal Poz

PRESIDENTE PRUDENTE

2016

FICHA CATALOGRÁFICA

| | |
|-------|--|
| F412e | <p>Fernandes, Vanessa Jordão Marcato.</p> <p>Extração de contornos de telhados de edifícios a partir da integração de imagem aérea de alta-resolução e dados laser, utilizando campos aleatórios de Markov / Vanessa Jordão Marcato Fernandes. - Presidente Prudente : [s.n], 2016</p> <p>133 f. : il.</p> <p>Orientador: Aluir Porfírio Dal Poz</p> <p>Tese (doutorado) - Universidade Estadual Paulista, Faculdade de Ciências e Tecnologia</p> <p>Inclui bibliografia</p> <p>1. Extração de telhados. 2. Imagens aéreas. 3. Dados de varredura laser. I. Fernandes, Vanessa Jordão Marcato. II. Dal Poz, Aluir Porfírio. III. Universidade Estadual Paulista. Faculdade de Ciências e Tecnologia. IV. Título.</p> |
|-------|--|

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: EXTRAÇÃO DE CONTORNOS DE TELHADOS DE EDIFÍCIOS A PARTIR DA INTEGRAÇÃO DE IMAGEM AÉREA DE ALTA-RESOLUÇÃO E DADOS LASER, UTILIZANDO CAMPOS ALEATÓRIOS DE MARKOV

AUTORA: VANESSA JORDÃO MARCATO FERNANDES

ORIENTADOR: ALUIR PORFIRIO DAL POZ

Aprovada como parte das exigências para obtenção do Título de Doutora em CIÊNCIAS CARTOGRÁFICAS, área: AQUISIÇÃO, ANÁLISE E REPRESENTAÇÃO DE INFORMAÇÕES ESPACIAIS pela Comissão Examinadora:


Prof. Dr. ALUIR PORFIRIO DAL POZ
Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente


Prof. Dr. MAURICIO GALO
Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente


Prof. Dr. JULIO KIYOSHI HASEGAWA
Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente


Prof. Dr. DANIEL RODRIGUES DOS SANTOS
Departamento de Geomática / Universidade Federal do Paraná


Prof. Dr. EDSON APARECIDO MITISHITA
Departamento de Geomática / Universidade Federal do Paraná

Presidente Prudente, 19 de dezembro de 2016

DEDICATÓRIA

A Deus.

Ao meu grande amor Leonardo, pelo amor,
paciência e bom humor.

Aos meus pais José Marcato e Eliane, pelo
amor e apoio incondicional.

Ao meu amado irmão, pela ajuda e incentivo.

AGRADECIMENTOS

A realização deste trabalho de pesquisa teve a colaboração direta e indireta de diversas pessoas e instituições a quem manifesto meus sinceros agradecimentos:

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) por financiar essa pesquisa durante todo o período, por meio da concessão de bolsa de estudo (processo nº 2012/22332-2).

Ao professor Dr. Aluir Porfírio Dal Poz, pela imprescindível orientação e pelos ensinamentos passados ao longo de todo esse período de convivência.

Aos membros da banca examinadora, Prof. Dr. Edson Aparecido Mitishita, Prof. Dr. Daniel Rodrigues dos Santos, Prof. Dr. Julio Kiyoshi Hasegawa e Prof. Dr. Maurício Galo, pelas valiosas sugestões e colaboração dadas na defesa desta tese de doutorado.

À Faculdade de Ciências e Tecnologia e ao Programa de Pós-Graduação em Ciências Cartográficas da UNESP – Universidade Estadual Paulista Júlio de Mesquita Filho, por toda a estrutura física disponibilizada durante a realização desta pesquisa.

Aos professores do Departamento de Cartografia da FCT/UNESP, em especial aos do Programa de Pós-Graduação em Ciências Cartográficas (PPGCC), pelo ensino e formação acadêmica.

Aos amigos do PPGCC, pelos bons momentos de convivência e trocas de experiência.

Às empresas Sensormap e Engemap, por fornecerem gentilmente os dados utilizados neste trabalho.

EPÍGRAFE

"O que vale na vida não é o ponto de partida e sim a caminhada. Caminhando e semeando, no fim terás o que colher"

(Cora Coralina)

RESUMO

Esse trabalho propõe o desenvolvimento de um método para a extração automática de contornos de telhados de edifícios com a combinação de dados de Varredura a LASER Aerotransportado (VLA) e dados fotogramétricos e campos aleatórios de Markov (MRF). Inicialmente, um Modelo Digital de Superfície normalizado (MDSn) é gerado através da diferença entre o Modelo Digital de Superfície (MDS) e o Modelo Digital de Terreno (MDT), obtidos a partir da nuvem de pontos LASER. Em seguida, o MDSn é segmentado para a obtenção dos polígonos que representam objetos altos da cena. Esses polígonos são projetados na imagem para restringir o espaço de busca para a segmentação da imagem em regiões. Esse processo possibilita a extração de polígonos na imagem que representem objetos altos. O processo de identificação de contornos de telhados, em meio aos objetos altos detectados na imagem, na etapa anterior, é realizado através da otimização de uma função de energia estabelecida com base em MRF que modela propriedades específicas de contornos de telhados de edifícios. No modelo MRF são utilizados tanto os polígonos extraídos da imagem quanto os extraídos dos dados VLA. A função de energia é otimizada pelo método Algoritmo Genético (AG). O método proposto nesse trabalho foi avaliado com base em dados reais - imagens aéreas de alta resolução e dados VLA. Os resultados obtidos na avaliação experimental mostraram que a metodologia funciona adequadamente na tarefa de extrair os contornos de telhados de edifícios. A função de energia proposta associada ao método de otimização AG diferenciou corretamente os contornos de telhados de edifícios dos demais objetos altos presentes nas cenas. Os contornos de telhados extraídos apresentam boa qualidade, o que é evidenciado por meio dos índices de completeza e correção obtidos pela avaliação numérica. Com base nos índices médios obtidos para cada experimento, têm-se as médias de completeza e correção para os experimentos iguais a 90,96% e 98,99%, respectivamente. Os valores máximos de completeza e correção são de 99,19% e 99,94%, respectivamente, e os valores mínimos de 78,08% e 97,46%, respectivamente. Os menores valores de completeza estão associados às áreas de oclusão por vegetação e presença de sombras.

Palavras-chaves: Fotogrametria, Extração de telhados, Dados VLA, Imagens aéreas e MRF.

ABSTRACT

This paper proposes a method for the automatic extraction of building roof contours through a combination of Airborne Laser Scanner (ALS) and photogrammetric data, and Markov Random Field (MRF). Initially, a normalized digital surface model (nDSM) is generated on the basis of the difference between the digital surface model and the digital terrain model, obtained from the LiDAR point cloud. Then the nDSM is segmented to obtain the polygons representing aboveground objects. These polygons are projected onto image to restrict the search space for image segmentation into regions. This process enables the extraction of polygons in the image representing aboveground objects. Building roof contours are identified from among the aboveground objects in the image by optimizing a Markov-random-field-based energy function that embodies roof contour specific properties. In the MRF model are used both polygons extracted from image and from ALS data. The energy function is optimized by the Genetic Algorithm (GA) method. The method proposed in this work was evaluated based on real data - high-resolution aerial images and ALS data. The results obtained in the experimental evaluation showed that the methodology works adequately in the task of extracting the contours of building roofs. The proposed energy function associated with the GA optimization method correctly differentiated the building roof contours from the other high objects present in the scenes. The extracted roof contours show good quality, which is evidenced by the indexes of completeness and correctness obtained by numerical evaluation. Based on the mean indexes obtained for each experiment, the average completeness and correctness for the experiments were equal to 90.96% and 98.99%, respectively. The maximum completeness and correctness values are 99.19% and 99.94%, respectively, and the minimum values are 78.08% and 97.46%, respectively. The lowest values of completeness are associated to the vegetation occlusion areas and presence of shadows.

Keywords: Photogrammetry, Roofs extraction, ALS Data, Aerial image and MRF.

LISTA DE TABELAS

| | |
|---|-----|
| Tabela 2.1 - Complementaridade dos dados VLA e dos dados fotogramétricos. | 42 |
| Tabela 2.2 - Cliques para os nós R1 e R5 da Figura 2.14. | 50 |
| Tabela 4.1 - Parâmetros de qualidade estimados na análise numérica dos contornos de telhado obtidos pelo método proposto para o experimento 1. | 86 |
| Tabela 4.2 - Parâmetros de qualidade estimados na análise quantitativa dos contornos de telhado obtidos pelo método proposto para o experimento 2. | 92 |
| Tabela 4.3 - Parâmetros de qualidade estimados na análise quantitativa dos contornos de telhado obtidos pelo método proposto para o experimento 3. | 99 |
| Tabela 4.4 - Parâmetros de qualidade estimados na análise quantitativa dos contornos de telhado obtidos pelo método proposto para o experimento 4. | 105 |
| Tabela 4.5 - Parâmetros de qualidade estimados na análise numérica dos contornos de telhado obtidos pelo método proposto para o experimento 5. | 110 |
| Tabela 4.6 - Parâmetros de qualidade estimados na análise quantitativa dos contornos de telhado obtidos pelo método proposto para o experimento 6. | 115 |
| Tabela 4.7 - Parâmetros de qualidade estimados na análise quantitativa dos contornos de telhado obtidos pelo método proposto para o experimento 7. | 120 |

LISTA DE FIGURAS

| | |
|---|----|
| Figura 2.1 – Esquema do cubo de cores RGB. | 21 |
| Figura 2.2 – Espaço de cores HSI. | 23 |
| Figura 2.3 – Histogramas de intensidade divididos. | 27 |
| Figura 2.4 – Ilustração da comparação do método <i>watershed</i> com um relevo topográfico...29 | |
| Figura 2.5 – Divisão da imagem em quadrantes. | 31 |
| Figura 2.6 - Diferença entre MDS e MDT. | 32 |
| Figura 2.7 – Obtenção do MDSn. | 32 |
| Figura 2.8 – Princípio da interpolação por vizinho mais próximo..... | 34 |
| Figura 2.9 - Semivariograma..... | 35 |
| Figura 2.11 – Exemplo de perfilagem irregular obtida por varredura a LASER..... | 39 |
| Figura 2.6 - Condição de colinearidade. | 44 |
| Figura 2.13 – Grafo G(R, E). | 48 |
| Figura 2.14 – (a) Imagem segmentada; (b) RAG..... | 48 |
| Figura 2.15 - Estrutura Básica de um AG..... | 55 |
| Figura 2.16 – Algoritmo de divisão recursiva..... | 62 |
| Figura 3.1 – Fluxograma do método proposto. | 64 |
| Figura 3.2 – Exemplo do procedimento de filtragem. | 65 |
| Figura 3.3 – Exemplo de MDS e MDT..... | 66 |
| Figura 3.4 – Exemplo de um MDSn. | 67 |
| Figura 3.5 – Exemplo de polígonos representando objetos altos..... | 67 |
| Figura 3.6 - Espaço de cor YUV..... | 68 |
| Figura 3.7 - Histograma bidimensional e as linhas <i>watersheds</i> | 69 |
| Figura 3.8 – Exemplo de segmentação da imagem..... | 70 |
| Figura 3.9 – Janela envolvente..... | 70 |
| Figura 3.10 – Exemplo de um contorno de telhado de edifício obtido pelo método proposto. | 71 |
| Figura 3.12 – População inicial..... | 77 |
| Figura 3.13 – Cruzamento..... | 78 |
| Figura 3.14 – Mutação. | 79 |
| Figura 4.1 – Imagem aérea da região do experimento 1..... | 82 |

| | |
|--|-----|
| Figura 4.2 – MDSn obtido para o experimento 1..... | 83 |
| Figura 4.3 - Polígonos extraídos dos dados VLA e projetados na imagem no experimento 1. | 83 |
| Figura 4.4 – Experimento 1..... | 84 |
| Figura 4.5 – Contornos de referência utilizados na análise quantitativa dos resultados obtidos no experimento 1..... | 86 |
| Figura 4.6 – Imagem aérea da região do experimento 2..... | 87 |
| Figura 4.7 - MDSn obtido para o experimento 2. | 87 |
| Figura 4.8 - Polígonos extraídos dos dados VLA e projetados na imagem no experimento 2. | 88 |
| Figura 4.9 - Polígonos extraídos da Imagem para o experimento 2..... | 89 |
| Figura 4.10 – Segmentação em regiões obtida na imagem para o polígono 2..... | 90 |
| Figura 4.11 - Resultado do processo de otimização da função de energia para o experimento 2..... | 91 |
| Figura 4.12 – Contornos de referência utilizados na análise quantitativa dos resultados obtidos no experimento 2..... | 92 |
| Figura 4.13 – Imagem aérea da região do experimento 3..... | 93 |
| Figura 4.14 - MDSn obtido para o experimento 3. | 94 |
| Figura 4.15 – Polígonos extraídos dos dados VLA e projetados na imagem no experimento 3..... | 95 |
| Figura 4.16 - Polígonos extraídos da Imagem para o experimento 3..... | 95 |
| Figura 4.17 – Segmentação em regiões dos recortes. | 96 |
| Figura 4.18 - Resultado do processo de otimização da função de energia para o experimento 3..... | 98 |
| Figura 4.19 – Contornos de referência utilizados na análise quantitativa dos resultados obtidos no experimento 3..... | 99 |
| Figura 4.20 – Imagem aérea da região do experimento 4..... | 100 |
| Figura 4.21 - MDSn obtido para o experimento 4. | 101 |
| Figura 4.22 – Polígonos extraídos dos dados VLA e projetados na imagem no experimento 4..... | 102 |
| Figura 4.23 – Experimento 4..... | 103 |
| Figura 4.24 – Contornos de referência utilizados na análise quantitativa dos resultados obtidos no experimento 4..... | 104 |
| Figura 4.25 – Imagem aérea da região do experimento 5..... | 106 |

| | |
|--|-----|
| Figura 4.26 - MDSn obtido para o experimento 5. | 106 |
| Figura 4.27 – Polígonos extraídos dos dados VLA e projetados na imagem no experimento 5..... | 107 |
| Figura 4.28 - Experimento 5. | 108 |
| Figura 4.29 – Contornos de referência utilizados na análise quantitativa dos resultados obtidos no experimento 5. | 110 |
| Figura 4.30 – Imagem aérea da região do experimento 6. | 111 |
| Figura 4.31 - MDSn obtido para o experimento 6. | 112 |
| Figura 4.32– Polígonos extraídos dos dados VLA e projetados na imagem no experimento 6. | 112 |
| Figura 4.33 – Experimento 6..... | 113 |
| Figura 4.34 – Contornos de referência utilizados na análise quantitativa dos resultados obtidos no experimento 6. | 114 |
| Figura 4.35 – Imagem aérea da região do experimento 7. | 116 |
| Figura 4.36 - MDSn obtido para o experimento 7. | 116 |
| Figura 4.37 – Polígonos extraídos dos dados VLA e projetados na imagem no experimento 7..... | 117 |
| Figura 4.38 – Experimento 7..... | 118 |
| Figura 4.39 – Contornos de referência utilizados na análise quantitativa dos resultados obtidos no experimento 7. | 119 |

SUMÁRIO

| | |
|---|----|
| 1 INTRODUÇÃO | 14 |
| 1.1 Considerações Gerais | 14 |
| 1.2 Objetivos..... | 18 |
| 1.2.1 Geral..... | 18 |
| 1.2.2 Específicos | 18 |
| 1.3 Justificativa..... | 18 |
| 1.5 Estrutura do trabalho | 19 |
| 2. REVISÃO BIBLIOGRÁFICA..... | 20 |
| 2.1 Modelos de Cores | 20 |
| 2.1.1 Modelo RGB..... | 21 |
| 2.1.2 Modelos CMY e CMYK..... | 22 |
| 2.1.3 Modelo HSI..... | 23 |
| 2.1.4 Modelo YUV | 25 |
| 2.2 Segmentação | 26 |
| 2.2.1 Limiarização | 27 |
| 2.2.2 Crescimento de Regiões..... | 29 |
| 2.2.3 Divisão e Fusão..... | 30 |
| 2.3 Modelo Digital de Elevação (MDE)..... | 31 |
| 2.3.1 Métodos de Interpolação..... | 33 |
| 2.4 Varredura a LASER | 37 |
| 2.4.2 Qualidade dos dados VLA | 38 |
| 2.4.3 Amostragem dos pontos LASER..... | 39 |
| 2.4.4 Filtragem de Dados VLA..... | 40 |
| 2.4.5 Varredura a LASER versus aerofotogrametria para extração de edifícios | 42 |
| 2.5 Equações de Colinearidade e Transformações no Espaço-Imagem | 43 |
| 2.6 Campos Aleatórios de Markov (Markov Random Field - MRF) | 46 |
| 2.6.1 MRF para análise de imagens por regiões | 47 |
| 2.6.2 MRF em estrutura de grafo | 47 |
| 2.6.3 Rotulação de imagem usando MRF..... | 50 |
| 2.7 Solução MAP..... | 52 |

| | |
|--|-----|
| 2.8 Métodos de Otimização | 53 |
| 2.8.1 Algoritmos Genéticos | 54 |
| 2.8.1.1 Cálculo da Aptidão..... | 56 |
| 2.8.1.3 Técnicas de Reprodução | 57 |
| 2.8.1.4 Operadores Genéticos | 58 |
| 2.8.1.5 Critérios de Parada | 60 |
| 2.9 Vetorização e Poligonização | 60 |
| 3. MATERIAL E MÉTODO..... | 63 |
| 3.1 Introdução..... | 63 |
| 3.2 Material | 63 |
| 3.2.1 Dados | 63 |
| 3.2.2 Recursos de Hardware e Software | 63 |
| 3.3 Método..... | 64 |
| 3.3.1 Extração de Polígonos representando as regiões altas a partir do MDSn..... | 65 |
| 3.3.2 Extração de Polígonos representando as regiões altas na Imagem..... | 68 |
| 3.3.3 Modelagem MRF..... | 72 |
| 3.3.4 Otimização da Função de Energia | 76 |
| 4. RESULTADOS | 80 |
| 4.1 Introdução..... | 80 |
| 4.2 Parâmetros e limiares utilizados..... | 80 |
| 4.3 Formas de análise dos resultados | 81 |
| 4.4 Resultados e análise..... | 82 |
| 4.4.1 Experimento 1 | 82 |
| 4.4.2 Experimento 2..... | 87 |
| 4.4.3 Experimento 3..... | 93 |
| 4.4.4 Experimento 4..... | 100 |
| 4.4.5 Experimento 5..... | 105 |
| 4.4.6 Experimento 6..... | 111 |
| 4.4.7 Experimento 7..... | 115 |
| 5. CONCLUSÕES E RECOMENDAÇÕES FUTURAS | 121 |
| 5.1 Conclusões..... | 121 |
| 5.2 Recomendações para trabalhos futuros | 123 |
| REFERÊNCIAS | 124 |

1 INTRODUÇÃO

1.1 Considerações Gerais

Informações contidas em um Sistema de Informações Geográficas (SIG) podem auxiliar em propostas de planejamento, administração e monitoramentos socioeconômicos de cidades. Para o desenvolvimento e a manutenção de um SIG, é de grande importância adquirir e atualizar os dados espaciais. O desenvolvimento de métodos para a coleta desses dados tem sido um tópico de interesse para a Fotogrametria e Sensoriamento Remoto, uma vez que esforços são feitos para tornar o processo mais rápido com procedimentos automáticos ou semiautomáticos e ainda, nesse contexto, há uma crescente disponibilidade de dados de sensores diversos, ópticos e não ópticos, implicando num enorme volume de dados a serem submetidos aos processos de extração de informações espaciais.

As pesquisas na área de extração automática de feições em ambiente urbano a partir de imagens ou de outros tipos de dados (por exemplo, dados de varredura a LASER - *Light Amplification by Stimulated Emission of Radiance*) têm crescido nos últimos anos. Em particular, as pesquisas na área de extração de telhados de edifícios, segundo Mayer (1999), iniciaram-se na primeira parte da década de 1980, tendo por base dados de imagem de alta resolução, visto que o objetivo era a reconstrução detalhada de edificações. Até meados da década de 1990 as imagens aéreas eram as fontes usuais de dados utilizadas para a extração. Fua e Hanson (1987) sugeriram uma metodologia para localizar e delinear edificações complexas em imagens aéreas. Em Shufelt (1987) é proposto o sistema PIVOT (*Perspective Interpretation of Vanishing points for Objects in Three dimension*), no qual o objetivo básico é extrair automaticamente edificações a partir de uma única imagem aérea. Muller e Zaum (2005) propuseram detectar edifícios em imagens aéreas com uso da segmentação da imagem por crescimento de regiões e posterior separação de regiões entre edifícios e vegetação com base em atributos geométricos e fotométricos associados às regiões previamente segmentadas. E Sirmaçek e Ünsalan (2011) apresentaram uma abordagem probabilística para detectar edifícios em imagens aéreas e de satélite.

O uso de dados de Varredura a LASER Aerotransportado (VLA) em problemas de extração de feições se tornou comum nos últimos anos. O desenvolvimento de metodologias

que utilizam esse tipo de dados para mapeamento é bastante atrativo às aplicações que envolvem a reconstrução e extração de objetos. Em Vosselman (1999) a proposta básica é extrair planos de telhados e combiná-los para extrair por intersecção as cumeeiras. Já os contornos são detectados e delineados por meio de algoritmos de detecção de descontinuidade. Rottensteiner et al. (2005) e Botelho e Centeno (2007) adotam, de um modo geral, os mesmos princípios. Já Lafarge et al. (2008) desenvolveram uma metodologia para a extração de edifícios a partir de Modelos Digitais de Elevação (MDE), em que as partes dos edifícios são extraídas como objetos retangulares. Estes objetos são posteriormente agregados para gerar modelos 3D completos de edificações.

A extração de telhados de edifícios é um problema difícil no âmbito do reconhecimento de objetos, o que está relacionado com a complexidade e a variabilidade da cena e, dessa forma, para minimizar esse problema se torna interessante o desenvolvimento de metodologias que utilizam várias fontes de dados (SOHN, 2004). O problema de extração de edifícios com o uso de dados VLA conjuntamente com dados de imagem vem sendo investigado nos últimos anos. Essa combinação de dados é atrativa para esse problema, uma vez que esses dois dados possuem informações complementares. Imagens de alta-resolução são ricas em informação espectral e de textura, mas são facilmente afetadas por muitos fatores como contraste, iluminação e oclusão. O sistema VLA pode rapidamente adquirir dados de altura densos e precisos de grandes áreas. As mudanças de altura facilitam a localização de edifícios mais do que informações espectrais e de textura. No entanto, a acurácia horizontal de edifícios extraídos desse tipo de dados é pobre devido à amostragem dos pulsos LASER (LI et. al., 2013).

Várias metodologias dessa classe podem ser encontradas na literatura. Como por exemplo, em Cheng et al. (2008) os edifícios segmentados nos dados VLA são usados para isolar as regiões na imagem aérea que os contêm. Na sequência, as duas direções principais de cada edifício são determinadas nos dados VLA e refinadas nas regiões pré-selecionadas da imagem. As direções principais dos edifícios permitem realizar a detecção direcional de segmentos de retas. Os segmentos de reta distantes dos contornos dos edifícios, previamente segmentados nos dados VLA e registrados nas regiões da imagem, são eliminados. As retas remanescentes são agrupadas para gerar os contornos fechados dos edifícios. Kabolizade et al. (2010) propuseram extrair contornos de telhados em imagens de alta-resolução. Para tanto, geraram um MDSn/LASER (Modelo Digital de Superfície normalizado a partir dos dados VLA) para detectar um contorno de telhado aproximado. Esse contorno aproximado,

em seguida, é usado para extrair pontos iniciais e esses por sua vez são fornecidos para um modelo Snake encontrar um contorno de telhado refinado na imagem. Em Chen et al. (2012) é proposto um método para detecção de edifícios com uso de dados VLA e imagem QuickBird. Os dados VLA são utilizados para gerar um MDSn e, assim serem obtidos os candidatos a representar edifícios, em seguida, a vegetação é filtrada com base em informações da imagem. Awrangjeb et al. (2013) apresentam um método para reconstrução automática de telhados 3D através da integração de dados VLA com imagem multiespectral. As informações provenientes de ambos os dados são utilizadas para a classificação de retas detectadas na imagem entre terreno, árvore, contorno e cumeeira de telhado. Os pontos dos dados VLA considerados acima do terreno, próximos a retas longas de contornos de telhados, são utilizados para gerar planos de telhados iniciais e para selecionar as demais retas que compõem cada telhado de edifício. Em Li et al. (2013) por meio de um processo de filtragem os pontos LASER são separados em pontos ou não de terreno, na sequência é aplicado um algoritmo de crescimento de regiões e são mantidas, como telhados, regiões que são grandes o suficiente com base em um limiar de área. Na imagem é aplicado o detector de Canny em regiões limitadas pelos resultados fornecidos pelos dados VLA. Por fim, regiões extraídas dos dados VLA e as retas extraídas da imagem são integradas por meio da morfologia matemática para formar o contorno final do telhado. Zhou e Zhou (2014) realizaram a fusão de dados VLA e imagem aérea com base em grafos de aspecto e utilizaram atributos de telhados de edifícios como geometria, estrutura e forma para extrair os telhados de edifícios. E em Zarea e Mohammadzadeh (2016) um MDSn (gerado a partir de uma nuvem de pontos LASER) e uma imagem aérea ortoretificada são utilizados em uma classificação automática utilizando Support Vector Machines (SVMs) para separar os telhados de edifícios e árvores e, adicionalmente, as regiões resultante passam por um pós-processamento pelo K-means para separar edifícios de diferentes alturas.

As metodologias existentes para a extração de telhados exploram, a exemplo de algumas metodologias brevemente apresentadas acima, diversos processos para alcançar o objetivo desejado. Uma teoria que vem ganhando espaço no campo da extração de feições são os campos aleatórios de Markov (MRF – *Markov Random Field*). Como exemplos, tem-se Krishnamachari e Chellappa (1996) que desenvolveram uma metodologia de extração de contornos de telhados que envolve a extração de feições retas em uma imagem aérea e o uso do modelo MRF para agrupar essas feições retas para delinear os edifícios. Em Katartzis e Sahli (2008) é proposto um método automático para detecção de telhados em imagens

aéreas. A abordagem é baseada em um modelo de interpretação de imagem estocástico, modelo de MRF, que combina informações de contexto 2D e 3D da imagem. As hipóteses de telhado de edifícios são extraídas usando um agrupamento hierárquico e princípios de organização perceptual. Galvanin e Dal Poz (2012) utilizaram dados VLA, para gerar um MDE, em conjunto com o MRF para a extração de contornos de telhados. Primeiramente, a fim de detectar objetos altos (edifícios altos, árvores etc.), o MDE é segmentado via divisão recursiva e fusão por inferência bayesiana. A extração dos contornos de telhados é focada nos objetos altos detectados, cujo problema é formulado e resolvido com base no MRF. Dal Poz et al. (2009b) propuseram uma metodologia para o refinamento geométrico de contornos de telhados extraídos de dados VLA, usando imagens aéreas de alta resolução e MRF. Primeiramente, os contornos 3D representando contornos de telhados são transformados para o espaço imagem. Na sequência, as retas extraídas da imagem e as projetadas são utilizadas para estabelecer uma descrição MRF com base em relações entre ambos os conjuntos de retas. A função de energia associada com a descrição MRF é minimizada através do algoritmo de força bruta, resultando num agrupamento de retas para cada contorno de telhado. Fernandes e Dal Poz (2016) apresentam uma versão melhorada do método desenvolvido em Dal Poz et al. (2009b), em que há, basicamente, o aprimoramento da função de energia e é utilizado o algoritmo genético como método de otimização. A grande vantagem de utilizar o modelo MRF está na possibilidade de caracterizar a informação contextual, já que a tarefa de segmentação de objetos em áreas urbanas, diante da complexidade da cena, requer o desenvolvimento de métodos específicos para a integração de informação de vizinhança e o conhecimento a priori de características dos objetos de interesse.

Nesse contexto, o presente trabalho propõe o desenvolvimento de um método para a extração automática de contornos de telhados de edifícios com a integração de dados VLA e fotogramétricos, via MRF. Os polígonos extraídos dos dados VLA que representam objetos altos da cena, obtidos a partir da segmentação do MDSn, são projetados na imagem para fornecer parâmetros para a realização da segmentação da imagem em regiões. Esse processo possibilita a extração de polígonos da imagem que representem objetos altos. O processo de identificação de contornos de telhados, em meio aos objetos altos detectados na imagem, na etapa anterior, é realizado através da otimização de uma função de energia estabelecida com base em MRF que modela propriedades específicas de contornos de

telhados de edifícios. Nesse processo são utilizados tanto os polígonos extraídos da imagem quanto os extraídos dos dados VLA.

1.2 Objetivos

1.2.1 Geral

Esse trabalho tem por objetivo principal desenvolver um método para extração automática dos contornos de telhados de edifícios a partir dados VLA e imagem aérea de alta-resolução usando MRF.

1.2.2 Específicos

- 1- Utilizar métodos existentes para a separação de objetos altos em um MDSn;
- 2- Desenvolver uma estratégia de segmentação de imagem combinando métodos existentes de segmentação e de compensação de iluminação de telhados;
- 3- Desenvolver com base na teoria de MRF um modelo matemático que possibilite modelar contornos de telhados, com uso de atributos de forma e espaciais, a partir de polígonos obtidos de dados VLA e de imagem;
- 4- Implementar uma técnica existente de otimização para separação de contornos de telhados de edifícios em meio aos objetos altos; e
- 5- Avaliar experimentalmente a metodologia proposta usando dados reais.

1.3 Justificativa

A relevância científica e tecnológica desse trabalho é evidenciada pela importância dada ao tema pela *International Society for Photogrammetry and Remote Sensing (ISPRS)*,
Fernandes, V. J.M.

no Grupo de Trabalho WG III/1 (*Thematic Information Extraction*) da Comissão III (*Remote Sensing*) que tem como um de seus termos de referência promover estudos científicos de novas tecnologias e metodologias de extração de informação temática com ênfase em abordagens multi-sensores. Nesse sentido, Chen et al. (2016) traz o estado da arte e diretrizes de pesquisa fixadas para o quadriênio (2016 – 2020) no tema, no qual aponta a utilização de fusão de dados, em especial, dados VLA e imagens, e o uso de abordagens probabilísticas, como MRF, para a extração de feições, tais como edifícios, o que evidencia que o presente trabalho está ancorado nessas diretrizes.

A extração automática de feições cartográficas, principalmente em áreas urbanas, é de grande relevância tecnológica, uma vez que ainda hoje, a extração de feições é realizada com interferência de um operador, o que demanda muito tempo e implica em elevados custos no processo de aquisição de dados.

O método proposto neste trabalho enquadra-se no contexto de desenvolvimento de novas metodologias para a aquisição eficiente de informações espaciais com uso de dados gerados por diversos sensores. O grande desafio dessa proposta está ligado principalmente ao objetivo específico 3, no qual se propõe o desenvolvimento de um modelo MRF estabelecido com base em atributos de formas e espaciais, a partir de polígonos obtidos de dados VLA e de imagem. Dessa forma, esse método procura aproveitar o grande potencial que o modelo MRF possui para a modelagem das relações espaciais. O objetivo específico 2 também é relevante, face às diferenças de iluminação em faces adjacentes de telhado causadas por diferenças de orientação. Esse problema leva a um outro: segmentação fragmentada de telhados.

1.5 Estrutura do trabalho

Esse relatório está dividido em 6 capítulos principais. O capítulo 2 trata da revisão bibliográfica. No capítulo 3 é apresentada a método proposto. O capítulo 4 versa sobre os resultados experimentais realizados. O capítulo 5 apresenta as conclusões e recomendações para trabalhos futuros. No capítulo 6 são listadas as referências utilizadas.

2. REVISÃO BIBLIOGRÁFICA

Este capítulo apresenta conceitos e ferramentas úteis para o desenvolvimento da pesquisa proposta. A seção 2.1 trata sobre alguns modelos de cores existentes. A seção 2.2 apresenta técnicas para segmentação de uma imagem. A seção 2.3 versa sobre modelos digitais de elevação e métodos de interpolação. A seção 2.4 apresenta temas relacionados à varredura a LASER. A seção 2.5 trata das equações de colinearidade e transformações no espaço imagem. A seção 2.6 versa sobre a teoria de Campos Aleatórios de Markov (MRF – Markov Random Field). Na seção 2.7, é introduzido o conceito de a solução MAP – Maximum a Posteriori. A seção 2.8 apresentado o método de otimização Algoritmo Genético. E a seção 2.9 finaliza esse capítulo com uma breve descrição do processo de vetorização e poligonização.

2.1 Modelos de Cores

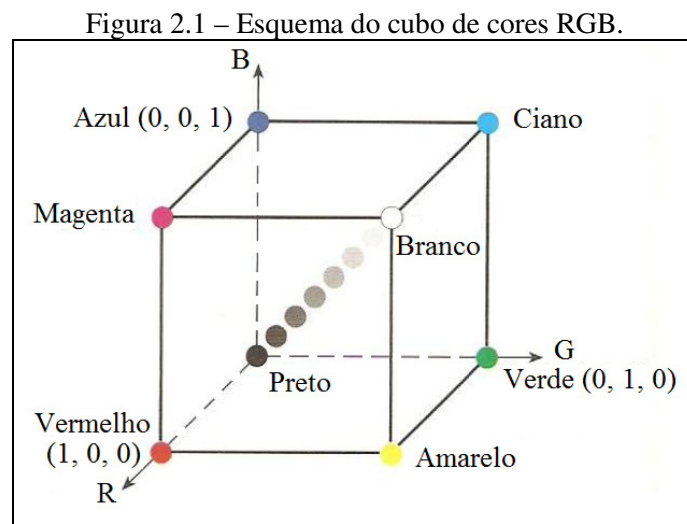
O uso da cor no processamento de imagens é bastante vantajoso, uma vez que a cor, em muitos casos, pode facilitar a identificação e extração de objetos em uma cena (GONZALEZ e WOODS, 2010).

A modelagem da cor é necessária e tem por objetivo facilitar a especificação das cores em alguma forma padronizada. Assim, um modelo de cores corresponde a um sistema de coordenadas, em um subespaço em que cada cor representa um ponto (GONZALEZ e WOODS, 2010).

Atualmente, existem muitos modelos de cores desenvolvidos, devido ao uso da cor em diferentes aplicações. Nessa seção serão apresentados alguns dos modelos utilizados no processamento de imagens, tais como: o modelo RGB (*red, green, blue* – vermelho, verde, azul), o modelo CMY (*cyan, magenta, yellow* – ciano, magenta, amarelo), o modelo HSI (*hue, saturation, intensity* – matiz, saturação, intensidade) e o modelo YUV.

2.1.1 Modelo RGB

O modelo RGB é formado por um sistema de coordenadas cartesianas. O subespaço de cores utilizado é o cubo, no qual os valores RGB primários (vermelho, verde e azul) estão em três vértices, as cores secundárias ciano, magenta e amarelo estão em outros três vértices, o preto está na origem, e branco está no vértice mais distante da origem. A escala de cinza estende-se ao longo do segmento de reta que une o preto até o branco. Por conveniência todos os valores são normalizados, e assim, os valores de R, G e B estão no intervalo $[0, 1]$ (Figura 2.1) (GONZALEZ e WOODS, 2010).



Fonte: adaptado de Gonzalez e Woods (2010).

Uma imagem no modelo de cores RGB, dessa forma, é composta por três componentes de imagem, uma para cada cor primária. Quando essas três componentes são combinadas produzem uma imagem de cores compostas (GONZALEZ e WOODS, 2010).

Esse modelo de cores RGB é ideal para implementações em hardware, por exemplo, geração de imagens coloridas através de uma câmera, exibição de imagens em um monitor, dentre outros (GONZALEZ e WOODS, 2010).

2.1.2 Modelos CMY e CMYK

O modelo de cores CMY é baseado nas cores secundárias: ciano, magenta e amarelo. Esse modelo é inspirado em fenômenos que se verificam quando a luz incide em superfícies, por exemplo, quando uma superfície coberta com pigmento magenta é iluminada com luz branca, nenhuma luz verde é refletida da superfície, ou seja, o magenta subtrai a luz verde da luz branca refletida, que é composta por quantidades iguais de luz vermelha, verde e azul. De forma análoga, o ciano e o amarelo resultam da subtração do vermelho e azul, respectivamente, da luz branca (GONZALEZ e WOODS, 2010).

O espaço de cores CMY é construído da mesma forma que é construído o espaço RGB. As coordenadas do espaço CMY passam a ser as cores secundárias, da mesma maneira que no RGB, as intensidades de cada componente estão normalizadas no intervalo $[0, 1]$ e o subespaço utilizado é o cubo.

A conversão de RGB para CMY é realizada através de uma operação simples (Equação 2.1) (GONZALEZ e WOODS, 2010).

$$\begin{bmatrix} C \\ M \\ Y \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix} - \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.1)$$

A Equação 2.1 mostra que a luz refletida de uma superfície ciano puro não contém vermelho, assim como, o magenta puro não reflete o verde, e o amarelo puro não reflete o azul (GONZALEZ e WOODS, 2010).


O modelo CMY é utilizado na maioria dos dispositivos de impressão. Teoricamente, quantidades iguais dos pigmentos ciano, magenta e amarelo deveriam produzir o preto. No entanto, a combinação dessas cores para impressão produz um preto de aparência turva. Dessa maneira, o verdadeiro preto é adicionado como uma quarta cor, o que gera o modelo de cores CMYK.

2.1.3 Modelo HSI

O modelo HSI é definido em termos de matiz, saturação e brilho. O matiz está relacionado com a cor pura (azul, amarelo ou verde puros), a saturação é a medida da diluição de uma cor pura por luz branca e o brilho incorpora a noção acromática de intensidade. Esse modelo de cores diferente dos modelos de cores RGB e CMY, se aproxima mais da percepção humana. Isso porque os seres humanos descrevem um objeto em termos de matiz, saturação e brilho, não em termos de três cores primárias que quando combinadas formam uma imagem colorida (GONZALEZ e WOODS, 2010).

A representação do espaço de cor HSI é composta por dois cones hexagonais unidos pela base (Figura 2.2). Esse espaço de cores é representado por um eixo de intensidade na posição vertical e os pontos de cor estão situados em planos perpendiculares a esse eixo. O matiz do ponto é o ângulo formado a partir do eixo vermelho (eixo normalmente utilizado como ponto de referência). O eixo vermelho corresponde ao ângulo de 0° , portanto ao valor de matiz igual a 0, esse valor aumenta no sentido anti-horário a partir desse ponto. A saturação é o comprimento do vetor que parte da origem até o ponto, a origem considerada é o eixo vertical. Esses elementos estão representados na Figura 2.2.

Figura 2.2 – Espaço de cores HSI.



Fonte: adaptado de <http://www.ufrgs.br/engcart/PDASR/formcor.html>.

A seguir, são apresentadas as equações para conversão do formato de cores RGB para o HSI (GONZALEZ e WOODS, 2010). O componente matiz (H) de cada pixel RGB é obtido a partir da Equação 2.2.

$$H = \begin{cases} \theta & \text{se } B \leq G \\ 360 - \theta & \text{se } B > G \end{cases} \quad (2.2)$$

$$\text{Com } \theta = \arccos \left\{ \frac{\frac{1}{2}[(R-G)+(R-B)]}{\left[\frac{1}{4}[(R-G)^2+(R-B)(G-B)] \right]^{\frac{1}{2}}} \right\}$$

A saturação é dada por:

$$S = 1 - \frac{3}{(R+G+B)} [\min(R, G, B)] \quad (2.3)$$

Por fim, o componente intensidade pode ser obtido a partir da Equação 2.4.

$$I = \frac{1}{3} (R + G + B) \quad (2.4)$$

Considera-se que os valores RGB estão normalizados para o intervalo [0, 1], e o ângulo medido a partir do eixo vermelho. Os valores de matiz (H) resultantes da Equação 2.2 podem ser normalizados no intervalo [0, 1] dividindo-os por 360°.

Na conversão de cores de HSI para RGB devem ser considerados os valores de H. São utilizados três intervalos de interesse, relacionados aos intervalos de 120° que separam as cores primárias (Figura 2.2). Assim, dados os valores de HSI no intervalo [0, 1], inicialmente multiplica-se o valor de H por 360° e por fim, considera-se os seguintes setores para realizar essa conversão.

- Setor RG ($0^\circ \leq H < 120^\circ$) as equações utilizadas para o cálculo dos componentes RGB são:

$$B = I (1 - S) \quad (2.5)$$

$$R = I \left[1 + \frac{S \cos H}{\cos(60^\circ - H)} \right] \quad (2.6)$$

$$G = 3I - (R + B) \quad (2.7)$$

- Setor GB ($120^\circ \leq H < 240^\circ$) para valores de H nesse intervalo é necessário subtrair, inicialmente, de H 120° , ou seja, $H = H - 120^\circ$. Nesse caso, as equações utilizadas são:

$$R = I (1 - S) \quad (2.8)$$

$$G = I \left[1 + \frac{S \cos H}{\cos(60^\circ - H)} \right] \quad (2.9)$$

$$B = 3I - (R + G) \quad (2.10)$$

- Setor BR ($240^\circ \leq H < 360^\circ$) nesse intervalo é necessário subtrair dos valores de H 240° ($H = H - 240^\circ$). E assim as componentes RGB são:

$$G = I (1 - S) \quad (2.11)$$

$$B = I \left[1 + \frac{S \cos H}{\cos(60^\circ - H)} \right] \quad (2.12)$$

$$R = 3I - (G + B) \quad (2.13)$$

2.1.4 Modelo YUV

O modelo de cores YUV foi desenvolvido, inicialmente, para os sistemas de televisão em cores PAL (*Phase Alternating Line*) e SECAM (*Séquence Electronique Couleur avec Mémoire*), na Alemanha e França em 1961. A componente Y corresponde a luminância e as demais componentes (U e V) são as componentes cromáticas. Dessa forma, esse modelo de cores permitia, na época, que os televisores preto e branco continuassem funcionando, uma vez que a componente Y não possuía informações de cores e somente seu uso, permitia que imagens em tons de cinza pudessem ser transmitidas (KOSCHAN e ABIDI, 2008).

Os valores em RGB no intervalo [0,1] podem ser transformados em YUV a partir da Equação 2.14 (KOSCHAN e ABIDI, 2008).

$$\begin{bmatrix} Y \\ U \\ V \end{bmatrix} = \begin{bmatrix} 0,299 & 0,587 & 0,114 \\ -0,147 & -0,289 & 0,437 \\ 0,615 & -0,515 & -0,100 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.14)$$

A Equação 2.15 apresenta a conversão de valores em YUV para RGB (KOSCHAN e ABIDI, 2008).

$$\begin{bmatrix} R \\ G \\ B \end{bmatrix} = \begin{bmatrix} 0,749 & -0,509 & 1,139 \\ 1,084 & -0,225 & -0,587 \\ 0,971 & 1,972 & -0,00001 \end{bmatrix} \begin{bmatrix} Y \\ U \\ V \end{bmatrix} \quad (2.15)$$

2.2 Segmentação

A segmentação é o processo pelo qual se subdivide uma imagem em regiões (GONZALEZ e WOODS, 2010).

Assim, considerando R uma região espacial representada por uma imagem. A segmentação particiona R em n sub-regiões, R_1, R_2, \dots, R_n , de acordo com as seguintes propriedades (GONZALEZ e WOODS, 2010):

- 1) $\bigcup_{i=1}^n R_i = R$, ou seja, a segmentação deve ser completa;
- 2) R_i é uma região conexa, $i = 1, 2, \dots, n$;
- 3) $R_i \cap R_j = \emptyset$, para todo i e j , $i \neq j$, isto é as regiões devem ser disjuntas;
- 4) $P(R_i) = VERDADEIRA$, para $i = 1, 2, \dots, n$, se todos os pixels da região R_i possuírem a mesma propriedade P ; e
- 5) $P(R_i \cup R_j) = FALSA$, para $i \neq j$ se as regiões R_i e R_j não possuírem a mesma propriedade P .

Dessa forma, o problema fundamental da segmentação é a divisão de uma imagem em regiões que atendam as condições apresentadas. Normalmente, os algoritmos de segmentação são baseados nas propriedades de descontinuidade ou similaridade dos valores de intensidade. Nessa primeira propriedade, a imagem é particionada a partir de mudanças bruscas nos valores de níveis de cinza. Nessa categoria, as feições de interesse são as linhas,

as bordas e os pontos isolados. Na segunda propriedade os pixels podem ser rotulados a uma mesma região se eles possuem características similares. As principais abordagens dessa categoria baseiam-se em limiarização, crescimento de regiões e divisão e fusão de regiões (GONZALEZ e WOODS, 2010).


2.2.1 Limiarização

A limiarização tem uma posição de destaque na segmentação de imagens, isso devido a sua simplicidade, que envolve propriedades intuitivas e facilidade de implementação (GONZALEZ e WOODS, 2010).

O processo de limiarização baseia-se na diferença dos níveis de cinza que compõe diferentes objetos de uma imagem. Assim, de acordo com as características dos objetos de interesse, um limiar é estabelecido para separá-los do fundo. A imagem passa a ter um grupo de pontos do objeto e outro grupo de pontos do fundo. Por exemplo, uma imagem $f(x, y)$ é formada por objetos claros sobre um fundo escuro, um limiar T é estabelecido com base em um histograma de intensidade (Figura 2.3 (a)), a imagem segmentada $g(x, y)$ é dada por (GONZALEZ e WOODS, 2010):

$$g(x, y) = \begin{cases} 1 & \text{se } f(x, y) > T \\ 0 & \text{se } f(x, y) \leq T \end{cases} \quad (2.16)$$

Figura 2.3 – Histogramas de intensidade divididos.
(a) por um limiar e (b) por dois limiares.



Fonte: adaptado de Gonzalez e Woods (2010).

Outro exemplo é apresentado na Figura 2.3 (b), na qual o histograma mostra a presença de três modos dominantes, que podem corresponder, por exemplo, a duas classes de objetos claros sobre um fundo escuro. Nesse caso, são selecionados dois limiares. Assim, o ponto é classificado como fundo se $f(x, y) \leq T_1$, para uma classe de objeto se $T_1 < f(x, y) \leq T_2$ e para classe de outro objeto se $f(x, y) > T_2$. A imagem segmentada $g(x, y)$ é dada por (GONZALEZ e WOODS, 2010):

$$g(x, y) = \begin{cases} a & \text{se } f(x, y) > T_2 \\ b & \text{se } T_1 < f(x, y) \leq T_2 \\ c & \text{se } f(x, y) \leq T_1 \end{cases} \quad (2.17)$$

em que, a , b e c são três valores de intensidade correspondentes às classes consideradas.

Essa técnica pode ser expandida para a segmentação de imagens coloridas. Da forma mais simples, as componentes coloridas de um modelo de cores podem ser combinadas em uma função unidimensional (F). Por exemplo, o RGB pode ser padronizado a partir da Equação 2.18 (BONSKPEN e COY, 1991).

$$F(R, G, B) = \frac{(0,25R+4G-B)}{5} \quad (2.18)$$

Melhores resultados são alcançados quando histogramas uni-, bi- ou tridimensionais são calculados diretamente para as componentes do modelo de cores. A escolha do modelo de cores está diretamente relacionada com a aplicação desejada (KOSCHAN e ABIDI, 2008).

Quando utilizados histogramas unidimensionais, para cada componente de cor é calculado um histograma. Uma abordagem para determinação dos limiares a partir desses histogramas é apresentada em Koschan e Abidi (2008). Inicialmente, são encontrados os máximos em cada histograma e, na sequência, é criada uma lista de prioridades de máximos ($max_1, max_2, \dots, max_n$), com base na frequência ou em um peso determinado. É um processo iterativo, em que seguindo a lista de máximos a imagem é dividida com base em valores de limiares estabelecidos pela regra $T_k < max_i \leq T_j$, os pixels que caem dentro desse intervalo criam uma região e os pixels que caem fora desse intervalo criam outra.

Abordagens têm sido desenvolvidas para a segmentação de imagens coloridas a partir de histogramas bi- e tridimensionais. Por exemplo, Shafarenko et. al. (1998)

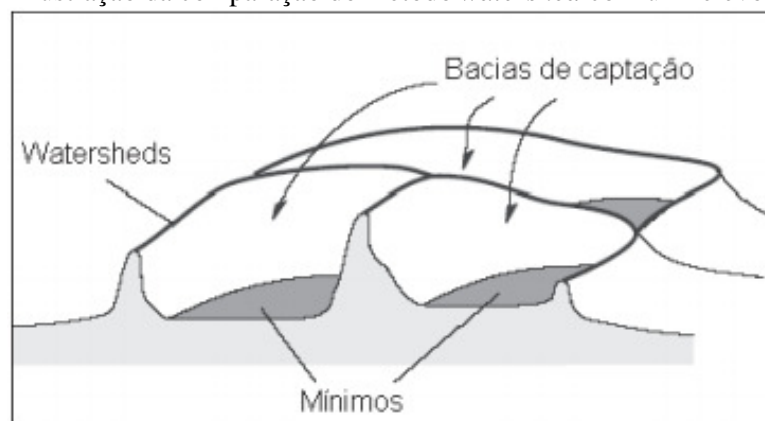
desenvolveram um método para segmentar imagens coloridas utilizando tanto um histograma bidimensional quanto um tridimensional. Para localizar de forma automática os vales no histograma é utilizado o algoritmo *watershed* (MEYER e BEUCHER, 1993).

2.2.2 Crescimento de Regiões

A segmentação por crescimento de regiões, segundo Gonzalez e Woods (2010), é um processo iterativo que parte de um pixel ou uma região semente e agrega pixels adjacentes que possuem características similares e que satisfaçam algum critério de similaridade pré-definido, formando regiões homogêneas. O processo é finalizado quando nenhum pixel adjacente satisfaz o critério de inclusão em cada região.

O método de segmentação por *watershed* é um dos principais métodos de segmentação por crescimento de regiões (GONZALEZ E WOORDS, 2010). Esse método baseia-se no princípio de inundação de relevos topográficos. Nesse princípio considera-se que uma imagem em tons de cinza pode ser vista como uma superfície topográfica, em que as coordenadas de cada pixel representam as coordenadas planimétricas e os tons de cinza a altura do relevo, tons mais escuros são os vales e os mais claros as montanhas. A inundação ocorre a partir dos mínimos da imagem-superfície, como se o relevo estivesse perfurado nos pontos de altitude mínima e fosse imerso em um lago. Conforme as bacias são inundadas, águas de diferentes bacias se encontram formando linhas divisórias, as chamadas barragens ou linhas de *watershed* (Figura 2.4). Assim, quando a água atinge o pico mais alto do relevo (correspondente ao maior valor de intensidade da imagem) o processo termina (ROERDINK e MEIJSTER, 2001).

Figura 2.4 – Ilustração da comparação do método *watershed* com um relevo topográfico.



Fonte: <http://students.wikia.com/wiki/File:Watershed-figura11.gif>.

Normalmente, essa técnica é aplicada no gradiente morfológico da imagem, pelo fato desse operador realçar as descontinuidades da imagem. Nesse processo deve-se atentar ao fato desse operador ser muito sensível a ruídos e necessitar da aplicação de filtros para eliminar máximos e mínimos locais, e dessa forma, evitar a super-segmentação. Adicionalmente, para evitar a super-segmentação pode-se, também, utilizar a técnica de marcadores proposta por Meyer e Beucher (MEYER e BEUCHER, 1990), que consiste em determinar marcadores, que são pontos pelos quais é iniciado o alagamento.


Existem vários métodos desenvolvidos para a construção das linhas de *watershed*. Em Gonzalez e Woods (2010) é apresentada uma abordagem morfológica, em que o processo de inundação é realizado a partir do processo de dilatação (GONZALEZ e WOODS, 2010). Soille e Vicent (1991) desenvolveram um algoritmo recursivo que percorre a imagem do menor ao maior valor de intensidade, utilizando para a composição das linhas de *watershed* conceitos relacionados à distância geodésica (mínimo caminho entre dois pontos dentre todos os caminhos possíveis). E Meyer (1994) apresentou uma abordagem que utiliza a distância topográfica (projeção da distância geodésica no plano) para o cálculo das bacias e linhas divisórias.

2.2.3 Divisão e Fusão

A segmentação de uma imagem também pode ser realizada através de operações combinadas de divisão e fusão. Nessa abordagem, pode-se subdividir a imagem em um conjunto de regiões arbitrárias e disjuntas, e dessa forma, realizar a divisão e/ou fusão das regiões em busca de satisfazer condições pré-definidas (GONZALEZ e WOODS, 2010).

A partir de uma imagem inteira R e uma propriedade P , uma maneira de segmentar esta imagem é subdividi-la sucessivamente em quadrantes cada vez menores de modo que, para cada região R_i , a propriedade P seja verdadeira (Figura 2.5 (a)).

Figura 2.5 – Divisão da imagem em quadrantes.
(a) Imagem particionada e; (b) estrutura *quadtree* correspondente.



Fonte: Gonzalez e Woods (2010).

O processo inicia-se com uma imagem inteira sendo como uma única região R , se a propriedade $P(R) = \text{FALSO}$, ou seja, se os pixels dessa região não são similares conforme uma propriedade estabelecida previamente divide-se essa região em quatro sub-regiões iguais. Para cada nova região, se $P(R) = \text{FALSO}$, divide-se novamente em quatro sub-regiões iguais, e assim sucessivamente até que não haja mais regiões a ser divididas (GONZALEZ e WOODS, 2010).

Essa estratégia de divisão recursiva da imagem pode ser representada por uma *quadtree* que é um tipo especial de árvore em que cada nó possui exatamente quatro descendentes (Figura 2.5 (b)).

Somente dividir a imagem pode acarretar em regiões adjacentes com propriedades semelhantes, uma opção para melhorar o resultado final é realizar a fusão. Esse procedimento é realizado somente nas regiões adjacentes que satisfazem a propriedade P . Assim, duas regiões são unidas se $P(R_j \cup R_k) = \text{VERDADE}$ (GONZALEZ e WOODS, 2010).


2.3 Modelo Digital de Elevação (MDE)

O Modelo Digital de Elevação é a forma mais utilizada para representar uma superfície de maneira digital com base em um conjunto de pontos com coordenadas tridimensionais. Um MDE consiste em uma representação discreta de uma superfície

topográfica, na qual as elevações do terreno são representadas computacionalmente por um conjunto de pontos (WOLF e DEWWITT, 2000).

Um MDE pode se subdividir em Modelo Digital do Terreno (MDT) ou Modelo Digital de Superfície (MDS). O MDT consiste em um MDE no qual as informações de pontos de elevação se restringem a superfície topográfica, compreendendo apenas o terreno e corpos d'água. O MDS refere-se a um MDE que apresenta informações de elevação de pontos na superfície terrestre e de objetos que estão sobre ela (por exemplo, árvores, edificações, entre outros) (EL-SHEIMY, 1999). A Figura 2.6 ilustra a diferença entre MDS e MDT.


Figura 2.6 - Diferença entre MDS e MDT.



Fonte: Centeno e Mitishita (2007).

Já MDSn (Modelo Digital de Superfície normalizado) é uma representação no plano dos objetos acima da superfície topográfica, o qual pode ser determinado subtraindo o MDT do MDS, como ilustra a Figura 2.7.

Figura 2.7 – Obtenção do MDSn.



Fonte: Elberink e Mass (2000).

A obtenção de um MDE pode ser realizada por meio de técnicas fotogramétricas, como também, através de levantamento GPS (Global Positioning System) em campo. Essas técnicas consistem da aquisição de uma malha de pontos com coordenadas de terreno que permitam a modelagem almejada (EL-SHEIMY, 2005).

Uma alternativa mais usual é a aquisição de dados por meio de sistemas VLA. Para a obtenção de modelos de superfícies existem vários métodos. O *Triangulated Irregular Network* (TIN) e a malha regular são os métodos mais usados para representar superfícies em meio digital.

Quando se trata de malha regular uma das considerações a serem feitas é com relação à determinação do espaçamento entre seus elementos. Esse valor deve ser determinado de forma que possa representar fielmente regiões de comportamento irregular e, ao mesmo tempo, reduzir as redundâncias em regiões quase planas.

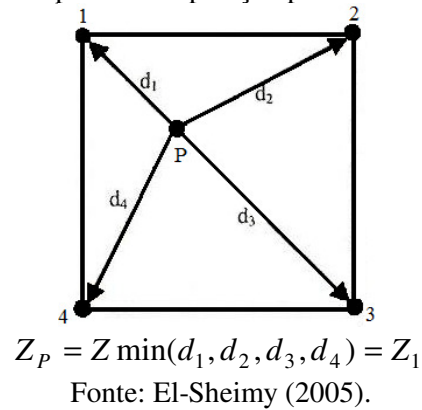
Uma vez definida as coordenadas dos pontos da grade, pode-se aplicar um método de interpolação para se obter a cota Z nesses pontos.

2.3.1 Métodos de Interpolação

A escolha da função de interpolação é de fundamental importância para se obter uma boa exatidão do modelo. Os processos de interpolação empregados são, geralmente, os locais, quando se considera uma vizinhança limitada, ou globais, quando a vizinhança é considerada ilimitada.

O método de interpolação por vizinho mais próximo atribui ao ponto interpolado o valor de elevação que está associado ao ponto de referência mais próximo. A Figura 2.8 ilustra o princípio desse método para pontos de referência regularmente distribuídos (EL-SHEIMY, 2005).

Figura 2.8 – Princípio da interpolação por vizinho mais próximo.



Esse interpolador é usado quando se deseja manter os valores de elevação das amostras sem gerar valores intermediários. A grande vantagem desse método é sua eficiência computacional. No entanto, ele apresenta a desvantagem de produzir superfícies descontínuas (EL-SHEIMY, 2005).

Outro método de interpolação é a bilinear. O polinômio bilinear (Equação 2.19) pode ser definido por quatro pontos amostrados.

$$Z(X, Y) = a_0 + a_1X + a_2Y + a_3XY \quad (2.19)$$

Dessa forma, utilizando os quatro vértices de referência é possível definir quatro equações para a determinação dos coeficientes e, assim, usá-los para estimar o valor da elevação do ponto a ser interpolado.

A interpolação por média ponderada, como o próprio nome diz, utiliza a média ponderada das elevações dos pontos de referência vizinhos ao ponto a ser interpolado para estimar o seu valor de elevação. O peso é inversamente proporcional à distância entre o ponto a ser interpolado e o ponto de referência em questão. O princípio básico desse método é que pontos próximos possuem valores de elevação similares (EL-SHEIMY, 2005). A Equação 2.20 descreve matematicamente o processo.

$$Z(X, Y) = \frac{\sum_{i=1}^n \left[\frac{Z_i}{d_i^p} \right]}{\sum_{i=1}^n \left[\frac{1}{d_i^p} \right]} \quad (2.20)$$

Nessa equação, $Z(X, Y)$ é o valor de elevação estimado para o ponto localizado em (X, Y) , Z_i é a elevação do i -ésimo ponto de referência localizado em (X_i, Y_i) , d_i é a

distância entre o ponto de referência e o ponto a ser interpolado e p é a potência atribuída a distância.


Outro método de interpolação é o método geostatístico chamado krigagem. A geoestatística tem por base a teoria das variáveis regionalizadas. O comportamento dessas variáveis é baseado em alguns pressupostos, como o de estacionariedade, que considera que o fenômeno é descrito como homogêneo na região em que se pretende fazer estimativas; o de ergodicidade que enuncia que a esperança referente à média de todas as possíveis realizações da variável é igual a média de uma única realização dentro de um certo domínio; e finalmente o pressuposto da hipótese intrínseca que diz que as diferenças entre valores apresentam fraco incremento, ou seja, são localmente estacionárias (LANDIM, et al., 2002).

O método de interpolação por krigagem é fundamentado na teoria das variáveis regionalizadas e, dessa forma, leva em consideração tanto a distância entre as amostras como o seu agrupamento. Nessa técnica estima-se valores médios e uma medida de acuracidade dessa estimativa. Os pesos a serem associados às amostras são calculados com base na distância entre a amostra e o ponto estimado, na continuidade espacial e no arranjo geométrico do conjunto (BETTINI, 2007). A determinação desses pesos está diretamente relacionada à modelagem da continuidade espacial obtida a partir do semivariograma.

O semivariograma pode ser obtido experimentalmente, com uso do esquema de amostragem em duas dimensões apresentado na Figura 2.9, em que $Z(x_1)$ e $Z(x_1 + h)$ correspondem ao valor em uma posição cujos componentes são (x_1, y_1) e (x_2, y_2) , respectivamente; h é um vetor que aponta de (x_1, y_1) para (x_2, y_2) , com módulo igual à distância entre esses pontos (CAMARGO et al., 2004).

Figura 2.9 - Semivariograma.

(a) Gráfico de distribuição espacial, e (b) componentes do semivariograma.



Fonte: Camargo et al. (2004).

Assim, para determinar experimentalmente o semivariograma é considerado para cada valor de h , todos os pares de pontos $Z(x_i)$ e $Z(x_i + h)$, separados pela distância $\|h\|$ e a função semivariograma ($\gamma(h)$) é calculada a partir da Equação 2.21 (CAMARGO et al., 2004).

$$\gamma(h) = \frac{1}{2n(h)} \sum_{i=1}^{n(h)} [Z(x_i) - Z(x_i + h)]^2 \quad (2.21)$$

com $n(h)$ definido pelo número de pares de observações.

A função $\gamma(h)$ descreve o desvio esperado nos valores dos pontos $Z(x_i)$ em função da distância entre pares de pontos. A Figura 2.9 (b) apresenta o semivariograma experimental, em função de $\gamma(h)$ e h , e relaciona-o a um comportamento idealizado composto pelos seguintes parâmetros (CAMARGO et al., 2004):

- Alcance (a): representa a distância máxima em que as amostras se apresentam correlacionadas espacialmente;
- Patamar: valor de $\gamma(h)$ correspondente ao seu alcance (a); e
- Efeito pepita (C_0): representa a descontinuidade do semivariograma para distâncias menores que a menor distância entre as amostras.

Dentre várias técnicas de krigagem, a ordinária consiste em uma forma de estimação linear para uma variável regionalizada que atende à hipótese intrínseca, ou seja, não requer o conhecimento prévio da média e assume-se a hipótese de estacionaridade local (YAMAMOTO e LANDIM, 2013). A Equação (2.22) fornece o estimador da krigagem ordinária.


$$Z_{KO}^*(x_0) = \sum_{i=1}^n \lambda_i Z(x_i) \quad (2.22)$$

em que $Z(x_i)$ são os dados experimentais; λ_i , ($i = 1, 2, \dots, n$) são os pesos atribuídos a cada valor amostral e n , o número total de dados.

2.4 Varredura a LASER

Os sistemas de varredura a LASER trabalham na região do infravermelho com comprimento de ondas de, aproximadamente, 1064 nm até 1540 nm. Os principais componentes desses sistemas, segundo Mikhail et al. (2001), são (Figura 2.8): o emissor do feixe LASER, mecanismo de varredura e ópticas de projeção, ópticas de recepção, e os sensores de navegação da plataforma (GPS (*Global Positioning System*) e INS (*Inertial Measurement Unit*)).

Figura 2.10 - Componentes de um sistema de varredura a LASER.



Fonte: Adaptado de Mikhail et al. (2001).

O emissor de feixe LASER emite um pulso de luz, o qual é direcionado à superfície pelos espelhos de varredura. Uma parcela deste pulso, ao atingir a superfície, é refletida na direção do sensor e essa parte é direcionada ao detector por meio da óptica de recepção. Cabe ressaltar, que o sensor mede a intensidade do sinal de retorno e o tempo decorrido entre a emissão e a captação do retorno, o que permite calcular a distância do sensor ao objeto, uma vez que o pulso LASER se propaga à velocidade da luz. Finalmente, para se obter as coordenadas 3D no espaço objeto, torna-se necessário ter um sistema de georreferenciamento direto (GPS e INS), o qual proporciona a posição e a orientação de cada pulso nos instantes de emissão e de chegada (MIKHAIL et al. 2001).

Nesse trabalho, serão apresentados apenas os fatores que afetam a qualidade dos dados VLA, amostragem dos pontos LASER e algumas técnicas de filtragem dos pontos LASER, maiores detalhes podem ser vistos em Dalmolin e Santos (2004) e Baltsavias (1999).

2.4.2 Qualidade dos dados VLA

Durante os últimos anos a qualidade dos dados VLA vem sendo estudada (KRAUS e PFEIFFER, 1998; BALTSAVIAS, 1999; GORDON et al., 2001; AHOKAS et al., 2003). Esses trabalhos mostram que esse tipo de dados é afetado por um grande número de fatores, tais como a superfície do material, altura de voo, integração GPS/IMU, ângulo de observação, tipo de sensor utilizado, entre outros.

A altura de voo é um dos fatores que influencia na qualidade dos dados. Sua variação implica em uma maior ou menor densidade de pontos na superfície do terreno, o que influencia diretamente na descrição do relevo. Em Ahokas et al. (2003) é analisada a densidade dos dados VLA em situações envolvendo diferentes tipos de superfície (floresta, cascalho, asfalto e capim), diferentes sensores e diferentes alturas de voo. Nesse trabalho, pode-se verificar que, como esperado, quanto maior a altura de voo, menor é a densidade dos pontos.

Outro fator que influencia na qualidade dos dados VLA é a divergência do pulso. Esse fator está relacionado com a complexa interação entre a transmissão e a reflexão do pulso no objeto (BRANDALIZE, 2002). O sinal retornado é influenciado pela dispersão da energia do pulso na área formada pela interceptação do pulso no alvo. Assim, o erro da divergência será proporcionalmente maior para alvos não uniformes com diferenças de reflexão e inclinação, acarretando em incertezas na posição do alvo.

A acurácia posicional do pulso depende principalmente da qualidade do pós-processamento do DGPS, do GPS, do número e configuração de satélites visíveis durante o voo, da distância entre as estações de referência e aerotransportadas, da qualidade da integração e calibração do GPS, IMU e sistema VLA e da acurácia da direção do pulso (acurácia da varredura). Geralmente, com DGPS e pós-processamento pode-se alcançar uma acurácia de 5-15cm (BALTSAVIAS, 1999).

Dessa forma, a qualidade dos dados VLA depende de parâmetros variáveis como: altura de voo, ângulo de varredura, topografia do terreno, geometria do objeto, refletividade do alvo e uma parte constante, como por exemplo: acurácia da detecção do pulso, acurácia do GPS, entre outros.


2.4.3 Amostragem dos pontos LASER

O levantamento de um certo número de pontos com coordenadas espaciais (X, Y, Z), através de alguma técnica de amostragem, é um procedimento utilizado na aquisição de informações espaciais para fins de modelagem matemática de superfícies. O processo de amostragem deve ser conduzido de forma que, os pontos escolhidos representem o comportamento estrutural da superfície real. Dessa forma, esse processo não pode ser realizado casualmente, pois demanda cuidados com relação à escolha dos pontos (EL-SHEIMY, 2005).

Uma das técnicas mais utilizadas na aquisição de informações espaciais para fins de modelagem matemática de superfícies é a perfilagem. Essa técnica consiste na obtenção de pontos representativos da área de estudo.

Os dados VLA advêm de uma perfilagem irregular na qual não é conhecido o exato espaçamento de pontos no perfil ou entre perfis (Figura 2.11).

Figura 2.11 – Exemplo de perfilagem irregular obtida por varredura a LASER.



2.4.4 Filtragem de Dados VLA

Conforme dito, um sistema VLA produz um conjunto de pontos 3D irregularmente espaçados. Esse conjunto de pontos é denominado nuvem de pontos. As técnicas de filtragem de dados VLA têm por finalidade detectar e eliminar os pontos da nuvem LASER que não pertencem ao terreno. Como consequência, pontos associados com vegetação e outros objetos elevados devem ser eliminados nesse processo.

Os processos de filtragem já desenvolvidos, segundo Sithole e Vosselman (2004), podem ser conceituados de acordo com vários critérios, dentre os quais estão:

1) Estrutura dos dados utilizada: os algoritmos de filtragem utilizam uma nuvem de pontos original (AXELSSON, 1999; PFEIFER et al. 1998; SITHOLE, 2001) ou uma malha regular de pontos (reamostrada) (BROVELLI, 2002; ELMQVIST, 2001). Esse último busca tomar proveito de algoritmos já desenvolvidos para o processamento digital de imagens;

2) Critérios de definição de vizinhança: os algoritmos sempre operam em uma vizinhança local para a classificação de um ou mais pontos por vez. Essa classificação envolve três técnicas distintas (SITHOLE E VOSELMAN, 2004):

- Classificação ponto contra ponto: somente um ponto é classificado de cada vez. Os algoritmos comparam dois pontos de cada vez, uma função discriminante é utilizada com base na posição de dois pontos e, assim, se a saída da função discriminante estiver acima de um limiar, então um dos pontos é assumido como pertencente ao objeto (SITHOLE, 2001; ROGGERO, 2001);
- Classificação ponto contra pontos: Nesses algoritmos tem-se um ponto de interesse e seus vizinhos são usados para resolver uma função discriminante. Esse ponto é classificado como pertencente a um objeto tendo por base a função discriminante. Nesse método, também, somente um ponto é classificado por vez (AXELSSON, 1999; SOHN e DOWMAN, 2002); e
- Classificação pontos contra pontos: Os algoritmos que utilizam esse tipo de classificação usam vários pontos para resolver uma função discriminante, que é então utilizada para classificar vários pontos como pertencentes ao objeto (PFEIFER et al. 1998; ELMQVIST, 2001).

3) Medida de descontinuidade: para a separação do terreno de objetos elevados, os algoritmos de filtragem se baseiam em uma medida de descontinuidade. Comumente, são utilizadas, por exemplo, diferença de altura, declividade, menor distância a faces de um TIN, e menor distância a superfícies parametrizadas;

4) Princípios de filtragem: Os filtros tem por base algum modelo da estrutura do terreno em uma vizinhança local. Por exemplo, pode-se estabelecer que pontos de terreno devem ajustar-se a uma dada superfície paramétrica. Existem quatro princípios de filtragem distintos (SITHOLE E VOSSSELMAN, 2004):

- Baseado na declividade: Nesses algoritmos (SITHOLE, 2001), a declividade entre dois pontos é medida. Se o desnível supera certo limiar, o ponto mais alto é assumido como pertencente a um objeto elevado;
- Baseado no bloco mínimo: A função discriminante é um plano horizontal delimitando uma região em 3D, na qual os pontos do terreno devem ser encontrados (WACK e WIMMER, 2002);
- Baseado na superfície parametrizada: semelhante ao anterior, com a diferença de que o plano é substituído por uma superfície parametrizada (ELMQVIST, 2001) e AXELSSON, 1999);e
- Baseado na segmentação: esse método (por exemplo, Brovelli (2002)) consideram que pontos que se agrupam e estão acima de uma vizinhança, pertencem a um objeto. Para tanto, os agrupamentos devem delinear objetos e não faces de objetos.

5) Mecanismo de controle: o iterativo ou o não iterativo. A filtragem realizada pelos algoritmos não iterativos (SITHOLE, 2001) é feita em uma única passagem, ao contrário, dos algoritmos iterativos (ELMQVIST, 2001; AXELSSON, 1999) que classificam pontos com o uso de múltiplas passagens;

6) Natureza da filtragem: trata da remoção ou da recolocação dos pontos filtrados no conjunto de dados. Os algoritmos que removem o ponto, normalmente trabalham com uma malha irregular (SITHOLE, 2001; AXELSSON, 1999). Já a recolocação dos pontos é realizada em algoritmos que utilizam uma malha regular. Nesse caso, o ponto recebe um novo valor de altura, atribuído por um processo de interpolação; e

7) Uso do primeiro pulso e dados de reflectância: a possibilidade de um sensor armazenar múltiplos pulsos pode favorecer o processo de filtragem em ambientes com vegetação alta, uma vez que o primeiro pulso retorna informações do topo da vegetação e os demais adentram a vegetação e possibilitam a obtenção de informações da superfície. Além disso, informações de intensidade do pulso LASER podem contribuir na classificação de pontos, já que superfícies diferentes podem absorver e refletir o pulso de diferentes maneiras.

2.4.5 Varredura a LASER versus aerofotogrametria para extração de edifícios

No contexto de extração de telhados de edifícios, o uso de dados VLA, na forma de MDE ou de uma estrutura TIN, ou de dados fotogramétricos apresenta vantagens e desvantagens. Os principais elementos de comparação para avaliação dos pontos fracos e fortes desses dois tipos de dados no âmbito da extração de edifícios podem ser observados na Tabela 2 (DAL POZ et al., 2009a).

Tabela 2.1 - Complementaridade dos dados VLA e dos dados fotogramétricos.

| Elementos de comparação | Varredura a LASER | Aerofotogrametria |
|--------------------------------|-----------------------------|-----------------------------|
| Linhas de descontinuidade | Baixa densidade posicional | Alta densidade posicional |
| Regiões Homogêneas | Densa informação posicional | Pouca informação posicional |
| Precisão Posicional | Melhor em altimetria | Melhor em planimetria |
| Informação Semântica | Baixa | Alta |

Fonte: Dal Poz (2009b).

As linhas de descontinuidade normalmente estão presentes ao longo dos contornos de telhados. Os dados VLA possuem baixa densidade posicional para essas entidades, enquanto que os dados fotogramétricos apresentam-se superiores nesse caso, e, dessa forma, devem ser utilizados na obtenção de contornos de telhados com alta qualidade. Já, quando se trata da obtenção de planos de telhados e sua orientação, a situação se inverte. Os dados VLA apresentam melhores resultados, uma vez que as alturas são mais precisas nesse dado e nas imagens os planos de telhados são homogêneos, o que dificulta a obtenção de informação posicional densa ao longo deles com o uso de técnicas fotogramétricas. Consequentemente, os dados VLA permitem a extração acurada de cumeeiras de telhados através da intersecção de planos. Por fim, a qualidade de informações semânticas nesses dois tipos de dados é bem diferente. Apesar de vários sistemas VLA permitirem o registro de informações de intensidade de retorno do pulso LASER, seu uso é limitado para a extração de edifícios. Por outro lado, as imagens fornecem informações semânticas com alto nível de detalhamento (DAL POZ et al., 2009a).


Kaartinen et al. (2005) realizaram um estudo no qual avaliaram diferentes metodologias de extração de telhados de edifícios, tendo por referência edifícios selecionados em mapas cadastrais. As metodologias avaliadas envolvem, o uso de dados VLA, ou dados fotogramétricos ou a combinação de ambos, e possuem diferentes níveis de refinamento e automação. Os experimentos realizados corresponderam às expectativas teóricas. Os dados VLA são superiores na determinação de elevações, planos de telhado e cumeeiras de telhado. Já os dados fotogramétricos são superiores na determinação de contornos de telhados.

Desse modo, pode-se concluir que a combinação de dados VLA e dados fotogramétricos é bastante vantajosa para melhorar a determinação de contornos de telhados de edifícios e pequenos detalhes.

2.5 Equações de Colinearidade e Transformações no Espaço-Imagem

O modelo mais utilizado para relacionar o espaço-objeto com o espaço-imagem é o modelo de colinearidade. Este modelo consiste basicamente em duas equações (Equação 2.23), as quais consideram que um ponto no espaço-objeto, o seu correspondente no espaço-imagem e o centro perspectivo (CP) são colineares no instante da tomada da imagem (Figura 2.12).

Figura 2.6 - Condição de colinearidade.



Fonte: Adaptado de MIKHAIL et al. (2001).

As Equações de Colinearidade para uma imagem de quadro (*frame*) são dadas por (MIKHAIL et al., 2001):

$$\begin{aligned} x &= -f \cdot \frac{m_{11} \cdot (X - X_{CP}) + m_{12} \cdot (Y - Y_{CP}) + m_{13} \cdot (Z - Z_{CP})}{m_{31} \cdot (X - X_{CP}) + m_{32} \cdot (Y - Y_{CP}) + m_{33} \cdot (Z - Z_{CP})} \\ y &= -f \cdot \frac{m_{21} \cdot (X - X_{CP}) + m_{22} \cdot (Y - Y_{CP}) + m_{23} \cdot (Z - Z_{CP})}{m_{31} \cdot (X - X_{CP}) + m_{32} \cdot (Y - Y_{CP}) + m_{33} \cdot (Z - Z_{CP})} \end{aligned} \quad (2.23)$$

Na Equação 2.23 têm-se os seguintes elementos:

- x, y são as coordenadas de um ponto no sistema fotogramétrico;
- (X, Y, Z) são as coordenadas do mesmo ponto no referencial cartesiano do espaço objeto;
- (X_{CP}, Y_{CP}, Z_{CP}) são as coordenadas do Centro Perspectivo (CP) no referencial cartesiano do espaço-objeto;
- f é a distância focal da câmara;
- Os elementos m_{ij} , para i e j variando de 1 a 3, pertencem a matriz de rotação, dada pela Equação 2.24, calculada em função dos ângulos ω , φ e κ em torno dos

eixos X, Y e Z, respectivamente. Por convenção, essa matriz é definida do sistema de referência do espaço objeto para o sistema de referência do espaço imagem (KRAUS e WALDHAUSL, 1992).

$$M = \begin{bmatrix} \cos\varphi \cos\kappa & -\cos\varphi \sin\kappa & \sin\varphi \\ \cos\omega \sin\kappa + \sin\omega \sin\varphi \cos\kappa & \cos\omega \cos\kappa - \sin\omega \sin\varphi \sin\kappa & -\sin\omega \cos\varphi \\ \sin\omega \sin\kappa - \cos\omega \sin\varphi \cos\kappa & \sin\omega \cos\kappa + \cos\omega \sin\varphi \sin\kappa & \cos\omega \cos\varphi \end{bmatrix} \quad (2.24)$$

Para a transformação do ponto $p(x, y)$ para o referencial da imagem (L, C), é necessário primeiro introduzir as distorções relacionadas com o sistema de lentes¹. Isso é necessário porque a imagem digital original, onde geralmente as operações de análise de imagem são realizadas, é afetada por aquelas distorções. As distorções das lentes são resultantes de duas causas básicas (MIKHAIL et al., 2001):

- Dificuldade em fabricar superfícies de lentes como um parabolóide de revolução: o efeito é o deslocamento radial simétrico em relação ao pp de pontos imagem, dando origem a um erro sistemático conhecido como distorção radial simétrica; e
- Dificuldade em alinhar os eixos ópticos das lentes que compõem a objetiva: essa distorção é conhecida como descentrada e produz tanto deslocamentos radiais assimétricos quanto tangenciais de pontos imagem.

O modelo matemático de Conrady-Brown permite corrigir ambas as distorções é dado por (CONRADY, 1919 e BROWN, 1964),

$$\begin{aligned} x &= x_c - (k_1 \cdot r^2 + k_2 \cdot r^4 + k_3 \cdot r^6) \cdot x_c - p_1 \cdot (r^2 + 2 \cdot x_c^2) + 2 \cdot p_2 \cdot x_c \cdot y_c \\ y &= y_c - (k_1 \cdot r^2 + k_2 \cdot r^4 + k_3 \cdot r^6) \cdot y_c - p_2 \cdot (r^2 + 2 \cdot y_c^2) + 2 \cdot p_1 \cdot x_c \cdot y_c \end{aligned} \quad (2.25)$$

em que: k_1, k_2, k_3, p_1, p_2 são parâmetros conhecidos de calibração; (x_c, y_c) são coordenadas de um ponto $p(x_d, y_d)$ afetadas pelas distorções das lentes e transformada para o referencial central da imagem ($x_c = x_d - x_o$ e $y_c = y_d - y_o$); $r = \sqrt{x_c^2 + y_c^2}$; e (x, y) são coordenadas de $p(x, y)$ livres das distorções, sendo estas coordenadas obtidas pelas equações de colinearidade (Equação 2.23)

¹ A refração fotogramétrica não será considerada devido à pequena magnitude do erro resultante.

A Equação 2.25 tem o problema de permitir o cálculo das coordenadas não afetadas pelos erros sistemáticos (x, y) em função das coordenadas afetadas pelos erros sistemáticos (x_d, y_d) . Como esta equação não admite a inversa analítica é necessário utilizar alguma solução numérica para encontrar os valores de (x_d, y_d) que satisfaçam a Equação 2.25. Esta equação pode ser eficientemente resolvida pelo método numérico de Newton-Raphson de encontrar raízes de funções (SULI e MAYERS, 2003).

Finalmente, o último passo consiste em transformar o ponto $p(x_c, y_c)$ para seu correspondente ponto $p(L, C)$ no sistema de imagem. Esse sistema é associado a uma imagem digital que pode ser definida como uma matriz bidimensional em um sistema de coordenadas linha e coluna, representados por L e C , que possui um atributo que indica os níveis de cinza (TOMMASELLI, 2004).

Para realizar a ultima etapa desse procedimento, basta observar que: o eixo coordenado C é paralelo e de mesmo sentido que o eixo x_c do referencial central; o eixo coordenado L é paralelo e refletido em relação ao eixo y_c do referencial central; a origem do referencial digital da imagem (LC) é o centro do pixel localizado no canto superior esquerdo da imagem; e existem diferenças de escala entre ambos os sistemas, visto que as coordenadas (x_c, y_c) têm a mesma unidade da distância focal (f), geralmente dada em milímetro, e as coordenadas (L, C) são dadas em pixels. Pode-se então escrever,

$$\begin{aligned} C &= \frac{x_c}{DC} + \frac{DW - 1}{2} \\ L &= -\frac{y_c}{DL} + \frac{DH - 1}{2} \end{aligned} \quad (2.26)$$

em que: DW e DH são as dimensões horizontal e vertical (em pixels) da imagem; e DC e DL são as dimensões horizontal e vertical (em milímetros) de um pixel. Como normalmente $DC = DL$, existirá apenas um fator de escala entre os referenciais envolvidos.

2.6 Campos Aleatórios de Markov (Markov Random Field - MRF)

O Campo Aleatório de Markov ou, simplesmente MRF é um modelo que tem chamado bastante a atenção de pesquisadores nos últimos anos. Os modelos MRF têm sido

empregados em processamentos de baixo nível, como segmentação e restauração de imagem (GEMAN e GEMAN, 1984; SZIRÁNYI et al., 2000), como também, em análise de imagens de alto nível (KIM e YANG, 1995; MODESTIN e ZHANG, 1992; KOPPARAPU e DESAI, 2001; ANDERSEN et al., 2002).

A aplicação do MRF em análise de imagem é estabelecida como um problema de estimação do máximo a posteriori (*Maximum a Posteriori* – MAP). Dessa forma, esse processo consiste em resolver um problema de minimização de energia.

O MRF pode ser definido sobre grafos e aplicado para o problema de análise de imagem (KINDERMAN e SNELL, 1980). A seguir é apresentada uma abordagem de análise de imagem via MRF, tendo por base a primitiva região.

2.6.1 MRF para análise de imagens por regiões


Os problemas de análise de imagem através da formulação de um MRF podem ser resolvidos a partir de uma imagem segmentada e da construção de um grafo de regiões adjacentes (*Region Adjacency Graphy* – RAG). Cada região da imagem corresponde a um nó do RAG e dois nós tem ligação entre eles se as duas regiões em questão compartilharem de uma mesma fronteira. Em seguida, assume-se que a interpretação do nó segue um modelo MRF, considerando o conhecimento específico dos objetos de interesse e os atributos obtidos da imagem observada. Dessa forma, o problema de análise de imagem é resolvido como um problema de estimativa MAP. Essa abordagem tem como uma das grandes vantagens a possibilidade de modelar as relações entre os objetos de interesse e os demais presentes na cena.

2.6.2 MRF em estrutura de grafo

Um grafo é uma estrutura $G (R, E)$ em que R é um conjunto finito não-vazio de objetos denominados nós e E é um conjunto finito de pares de nós não ordenados chamados arestas. Os grafos são chamados assim, pois podem ser representados graficamente e essa

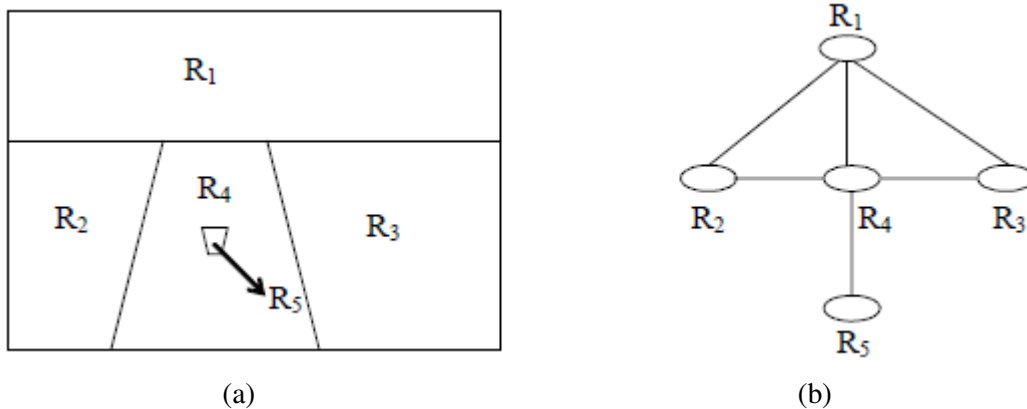
representação ajuda no entendimento de suas propriedades. Os vértices são indicados por pontos e as arestas por linhas que unem pares de pontos. No grafo simples, dois nós são adjacentes ou vizinhos se existir uma aresta em G (Figura 2.13).

Figura 2.13 – Grafo $G(R, E)$.



A formulação de um MRF em estrutura de grafos dá-se inicialmente, com uma imagem segmentada com n regiões $\{R_1, R_2, \dots, R_n\}$ e o RAG correspondente. A seguir, pode ser observado um exemplo de imagem segmentada e o correspondente RAG (Figura 2.14).

Figura 2.14 – (a) Imagem segmentada; (b) RAG.



(a)

(b)

Fonte: Koppurapu e Desai (2001).

Na Figura 2.14, o RAG mostra que a região R_1 é adjacente às regiões R_2 , R_3 e R_4 , assim como, a R_4 é adjacente a R_1 , R_2 , R_3 e R_5 .

Seja $G = \{R, E\}$ um RAG, em que $R = \{R_1, R_2, \dots, R_n\}$ denota o conjunto de nós R_i , $i = 1, 2, \dots, n$ e E caracteriza o conjunto de arestas. Se as regiões correspondentes aos nós R_i e R_j compartilharem, pelo menos em parte, de uma mesma fronteira, haverá uma aresta entre esses nós.

A representação do sistema de vizinhança em G será dada por:

$$\eta = \{\eta(R_1), \eta(R_2), \dots, \eta(R_n)\} \quad (2.27)$$

em que, $\eta(R_i)$, $i = 1, 2, \dots, n$, é o conjunto de todos os nós em R vizinhos de R_i .

Seja $X = \{X_1, X_2, \dots, X_n\}$ uma família de variáveis aleatórias definida sobre R, em que cada X_i corresponde a R_i . Além disso, considera-se que X_i toma valores em um espaço amostral finito. Assim, X é um MRF sobre G com relação ao sistema de vizinhança η se e somente se: $P[X = x] > 0$ para todas as realizações de X; e $P[X_i = x_i | X_j = x_j \forall j \neq i] = P[X_i = x_i | X_j = x_j \forall j | R_j \in \eta(R_i)]$.

O modelo MRF possui a vantagem de ter como função distribuição de probabilidade a distribuição de Gibbs conforme estabelece o teorema de *Hammersley-Clifford* (KOPPARAPU e DESAI, 2001).

Nesse contexto, um clique c é um subconjunto de nós de G tal que cada par de diferentes nós em c são vizinhos. O conjunto de todos os cliques de G com relação ao sistema de vizinhança η é representado como $C(G, \eta)$.

Considerando que X tem um número finito de configurações em relação ao espaço amostral S, e que $P[X = x] > 0$, dessa forma X é um MRF, com respeito ao sistema de vizinhança η , somente se X tem distribuição de probabilidade de Gibbs, conforme estabelece o teorema de *Hammersley-Clifford* (KOPPARAPU e DESAI, 2001) (Equação 2.28).

$$P[X = x] = \frac{1}{Z} \exp^{-U(x)} \quad (2.28)$$

em que, x é uma realização de X e Z é a constante de normalização, conforme pode ser visto na Equação 2.29 e $U(x)$ é a função de energia de Gibbs (Equação 2.30).

$$Z = \sum_{\text{toda conf. } x} e^{-U(x)} \quad (2.29)$$

$$U(x) = \sum_{c \in C(G, \eta)} V_c(x^c) \quad (2.30)$$

em que, $V_c(x^c)$ é a função potencial da clique e x^c o valor das variáveis associadas com os nós pertencentes ao clique $c \in C(G, \eta)$.

Para que fique mais claro o conceito de clique, será considerado o RAG da Figura 2.14. A seguir, será apresentada a Tabela 3, na qual são mostradas as cliques para dois nós desse RAG.

Tabela 2.2 - Cliques para os nós R1 e R5 da Figura 2.14.

| Nós | Cliques de primeira ordem | Cliques de segunda ordem | Cliques de terceira ordem |
|-----|---------------------------|--|--|
| 1 | $\{R_1\}$ | $\{R_1, R_2\}$ $\{R_1, R_4\}$ $\{R_1, R_3\}$ | $\{R_1, R_2, R_4\}$ $\{R_1, R_3, R_4\}$ |
| 5 | $\{R_5\}$ | $\{R_5, R_4\}$ | ---- |

Fonte: Koppurapu e Desai (2001).

Verifica-se que $\{R_1, R_2, R_3, R_4\}$ não pode ser um clique, pois R_2 e R_3 não são vizinhos.

A função potencial V_{c_i} envolve apenas nós de c_i , desse modo, cada função desse tipo expressa a forma e o grau de iteração (primeira ordem, segunda ordem, entre outros) que cada nó R_i tem com seus vizinhos.

A abordagem baseada no modelo MRF para análise de imagem proporciona vantagens em relação à representação do conhecimento, aprendizado e otimização, devido à estrutura na qual as propriedades locais e globais são relacionadas, através de cliques.

2.6.3 Rotulação de imagem usando MRF

A rotulação de regiões através de uma imagem segmentada é dada a partir da atribuição de um nó R_i para cada região, desse modo, o conjunto de arestas E é tal que o nó R_i está ligado a R_j apenas se as regiões correspondentes forem vizinhas. Assim, a imagem segmentada da Figura 2.14(a) toma a forma do grafo de adjacência (Figura 2.14(b)).

Um rótulo possível do conjunto $I = \{I_1, I_2, \dots, I_M\}$ é atribuído a cada nó R_i . Desse modo, o espaço amostral para cada X_i , variável aleatória para o nó R_i , será $I = \{I_1, I_2, \dots, I_M\}$. Assim, cada X_i receberia um valor do conjunto $\{I_1, I_2, \dots, I_M\}$, referentes aos M rótulos possíveis.

O conhecimento específico a priori k está relacionado com os objetos constituintes e que se pretende identificar da cena. A caracterização de k constituiu em estimar valores característicos para os atributos considerados importantes para o processo de rotulação. Os atributos como níveis de cinza ou características geométricas (perímetro, área, entre outros) podem ser definidos em um clique de primeira ordem, contraste ou comprimento da fronteira entre dois objetos em cliques de segunda ordem. Os atributos mais completos podem ser definidos para cliques de ordem superior.

Os atributos úteis para a análise de imagem podem ser classificados em atributos primários e secundários. Os primários constituem atributos obtidos da cena a partir de medidas diretas e os secundários obtidos através dos atributos primários e, portanto, não são obtidos diretamente da cena. Como exemplo de atributos primários tem-se área, perímetro, variância e o nível médio de cinza, já os atributos secundários podem ser o contraste, a compacidade e o comprimento da fronteira entre dois objetos. Os atributos de natureza contextual (relação entre o objeto de interesse e os demais objetos) destacam-se dentre os atributos, pois possibilitam aos modelos MRF uma modelagem ampla do problema em questão. Essa característica é uma das grandes vantagens dessa abordagem.

Os atributos obtidos através da imagem de entrada podem ser dados por (KOPPARAPU e DESAI, 2001):

$$F = \{F^c \mid \forall c \in C(G, \eta)\} \quad (2.31)$$

em que, $F^c = \{F_1^c, \dots, F_q^c\}$ é o conjunto de q atributos medidos sobre o clique c . O conhecimento a priori k caracteriza esses q atributos.

A distribuição de probabilidade do vetor aleatório X definido sobre o RAG G , dado o conhecimento a priori k e o conjunto de atributos F , é assumido como um MRF (Equação 2.32) (KOPPARAPU e DESAI, 2001).

$$P[X = x \mid F = f, k] = \frac{1}{Z} \exp^{-U(x|f,k)} \quad (2.32)$$

em que:

$$U(x|f,k) = \sum V_c(x^c | f^c, k) \quad (2.33)$$

sendo, f a realização dos atributos definidos em F .

Desse modo, o problema de análise de imagem é resolvido como um problema de estimativa MAP (Equação 2.34).

$$x_* = \arg \max_x P[X = x | F = f, k] \quad (2.34)$$

De forma equivalente:

$$x_* = \arg \min_x U(x|f,k) \quad (2.35)$$

A questão central é com definir a função energia $U(x|f,k)$ para um dado problema. A solução ótima x é obtida através de estimativa MAP.

2.7 Solução MAP

O problema de análise de imagem em questão, conforme já citado, é formulado como um problema de estimativa MAP. Normalmente, quando se tem um problema baseado em um modelo MRF, a solução envolve uma estimativa MAP, ou seja, a solução do problema de minimização da função de energia (Equação 2.36) (KOPPARAPU e DESAI, 2001).

$$x_* = \arg \min_x \left[\sum_{\forall c=\text{um nó clique}} V_c^1(x^c | f^c, k) + \sum_{\forall c=\text{múltiplos nós clique}} V_c^m(x^c | f^c, k) \right] \quad (2.36)$$

Na Equação 2.36, a expressão dentro dos colchetes, normalmente, possui vários mínimos locais. Dessa forma, torna-se necessário aplicar um algoritmo de minimização que forneça um mínimo global. O uso de métodos simples de otimização, como Força Bruta, que consiste de uma busca combinatorial exaustiva do melhor candidato entre todos os possíveis, resulta em uma complexidade exponencial da ordem de L^N , em que L é o número de rótulos e N o número de nós do grafo de adjacência.

2.8 Métodos de Otimização

Os métodos de otimização visam encontrar o máximo ou o mínimo de uma função com uma ou mais variáveis em um determinado domínio. A escolha de um ou outro método deve estar relacionada com o problema a ser maximizado ou minimizado. A classificação de um método de otimização é dada de acordo com sua formulação. Assim, segundo Goldberg (1989) pode-se classificar os métodos de otimização da seguinte maneira:

- Baseados em cálculo diferencial;
- Enumerativos; e
- Aleatórios.

Os métodos baseados em cálculo diferencial podem ainda ser divididos em: métodos diretos e indiretos. Os métodos diretos buscam pelo valor ótimo da função movendo-se na direção do gradiente local (GOLDBERG, 1989). Como exemplos, tem-se: Método do Gradiente Generalizado, Método das Direções Viáveis e Método de Programação Linear Sequencial. Já o método indireto busca o valor ótimo através do conjunto de equações não lineares resultantes da fixação em zero do gradiente da função (GOLDBERG, 1989). Dentre os métodos indiretos tem-se: Método da Função de Penalidade Exterior, o Método da Função de Penalidade Interior e o Método dos Multiplicadores de Lagrange Aumentado.

Nos métodos enumerativos a busca pelo valor ótimo inicia-se por vários pontos do espaço de busca. A cada iteração calculam-se os valores da função para cada ponto e

comparam-se esses valores com as restrições e os valores anteriores, a fim de verificar a melhora ou não no processo. A grande desvantagem desse método é que quando se envolve um espaço de busca grande, o custo computacional se torna altíssimo (GOLDBERG, 1989).

Já os métodos de busca aleatórios tem atraído a atenção entre os pesquisadores. Nas últimas décadas surgiram diversas técnicas relacionadas aos algoritmos evolucionários. Esses algoritmos são métodos de busca estocásticos que imitam a evolução biológica natural, dentre eles pode-se destacar o método dos Algoritmos Genéticos (AGs).

Os AGs trabalham com um conjunto de soluções submetido ao princípio da sobrevivência dos indivíduos mais aptos para, dessa forma, encontrar uma solução cada vez melhor. Esses algoritmos aplicam aos indivíduos da população operadores naturais tais como a seleção dos melhores, o cruzamento entre eles e a mutação (GOLDBERG, 1989).

Esses algoritmos são aplicados em muitos problemas, uma vez que não impõem limitações normalmente apresentadas pelos métodos diretos e indiretos. Na maioria das vezes, apresentam uma solução na vizinhança do ótimo global.

Os AGs trabalham sobre um conjunto de pontos do espaço de busca em vez de um único ponto; podem trabalhar sobre uma codificação das variáveis de projeto, em vez de trabalhar com as próprias variáveis; não exigem a continuidade e a diferenciabilidade da função-objetivo ou das restrições; e usam regras probabilísticas de transição (GOLDBERG, 1989). Além disso, são relativamente fáceis de serem implementados e adaptam-se com outras técnicas heurísticas.

Com tais características, segundo Goldberg (1989), os AGs demonstram ser muito mais robustos que os métodos tradicionais. E assim, a utilização desses algoritmos em problemas de engenharia vem crescendo a cada dia.

2.8.1 Algoritmos Genéticos

Os Algoritmos Genéticos foram inventados por John Holland na década de 1960. Em contraposição com as estratégias da evolução e a programação evolucionária, o objetivo inicial de Holland não foi de desenvolver algoritmos para solucionar problemas específicos, mas de estudar o fenômeno da adaptação e como isso ocorre na natureza e, também, de

desenvolver maneiras em que a adaptação natural poderia ser importada em sistemas computacionais (MITCHELL, 1999).

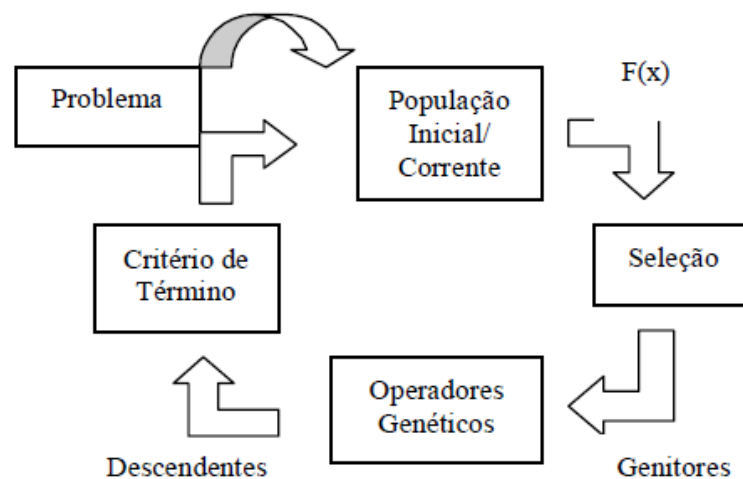
O livro de Holland “Adaptation in Natural and Artificial Systems” apresenta o algoritmo genético como uma abstração da evolução biológica e dá base teórica para adaptações por trás do AG.

O AG é um método para transformar uma população de cromossomos, cadeia de bits, que representa uma solução possível para o problema em uma nova população com o uso de um tipo de seleção natural através de inspirações genéticas com operadores de cruzamento, mutação e inversão. Cada cromossomo consiste de genes, representação de cada parâmetro de acordo com o alfabeto utilizado (binário, inteiro ou real), e cada gene é uma instância de um “alelo” (exemplo: 0 e 1) (MITCHELL, 1999).

O AG é aplicado, normalmente, na solução de problemas de otimização complexos. Como por exemplo, problemas com diversos parâmetros ou características que precisam ser combinadas em busca da melhor solução, problemas com muitas restrições ou condições que não podem ser representadas matematicamente, e problemas com grandes espaços de busca.

A estrutura básica do AG é mostrada na Figura 2.15:

Figura 2.15 - Estrutura Básica de um AG.



Fonte: Pacheco (1999).

A estrutura de um AG é composta pela inicialização de uma população. Essa população de n indivíduos é gerada aleatoriamente. Cada um dos indivíduos da população representa uma possível solução para o problema, ou seja, um ponto no espaço de soluções.

A cada iteração do algoritmo genético corresponde à aplicação de um conjunto de operações básicas: cálculo de aptidão com uso da função objetivo $F(x)$, seleção e reprodução (aplicação dos operadores genéticos) (GOLDBERG, 1989).

2.8.1.1 Cálculo da Aptidão

A aptidão do indivíduo, normalmente, é determinada através do cálculo da função objetivo. Essa função é construída a partir dos parâmetros envolvidos no problema e fornece uma medida da proximidade da solução em relação a um conjunto de parâmetros (MITCHELL, 1999).

2.8.1.2 Seleção

A seleção é utilizada para escolher os indivíduos da geração atual que serão submetidos às operações genéticas, como cruzamento e mutação (descritas a seguir), para gerar uma nova população, ou seja, a geração seguinte.

Os principais métodos de seleção são: roleta, torneio, amostragem determinística, amostragem estocástica dos resíduos e amostragem estocástica universal (SOARES, 1997).

No método roleta, cada indivíduo tem a probabilidade de ser selecionado proporcional à sua aptidão. Dessa maneira, se f_i é a aptidão do indivíduo i na população corrente, a probabilidade p_i do indivíduo i ser selecionado é proporcional a (Equação 2.37):

$$p_i = \frac{f_i}{\sum_{j=1}^N f_j} \quad (2.37)$$

em que N é o número de indivíduos na população.

Outro método é o de torneio. O torneio retorna o melhor indivíduo entre dois obtidos no método da roleta. Com isso, esse método busca evitar que um indivíduo com baixo desempenho seja escolhido, mas claro que não elimina a possibilidade. A convergência prematura, nesse método, pode ocorrer, já que é baseado no método da roleta (GOLDBERG, 1989).

A amostragem determinística possui dois estágios. O primeiro consiste em criar uma população temporária, que é preenchida com o número inteiro obtido pelo cálculo da expectativa de cópias de cada membro i da população (f_i / f_{med} - razão entre aptidão do indivíduo i pela aptidão média). Devido às partes fracionárias dessa expectativa, haverá vagas ociosas nessa população. No segundo estágio, essas vagas são preenchidas de acordo com os indivíduos que possuem a parte fracionária do valor de desempenho mais alta (GOLDBERG, 1989).

Da mesma maneira que o método anterior, a amostragem estocástica dos resíduos forma uma população temporária com o número inteiro da expectativa de cópias. As vagas restantes são preenchidas, de acordo com algum evento verificado com a probabilidade da parte fracionária. Um indivíduo, por exemplo, possui a expectativa de 2,3 cópias para a próxima geração, ou seja, possui 2 vagas garantidas e mais 30% de chance de preencher mais uma vaga. Para o preenchimento das vagas ociosas deve ser escolhido algum critério para escolha dos indivíduos candidatos (GOLDBERG, 1989).

O último método de seleção é a amostragem estocástica universal, que consiste da escolha aleatória entre os indivíduos da população. Nesse método, cada indivíduo tem a chance de $1/N$ (número de indivíduos na população) de ser escolhido (SOARES, 1997).

2.8.1.3 Técnicas de Reprodução

As técnicas de reprodução determinam o critério de substituição dos indivíduos de uma população para a próxima geração. Existem basicamente quatro métodos, que são: troca de toda a população, troca de toda a população por elitismo, troca parcial da população e troca parcial da população sem duplicados (PACHECO, 1999).

1 – Troca de toda a população: a cada geração N (número de indivíduos)/2 são escolhidos para acasalamento, criando N novos indivíduos.

2 – Troca de toda a população por elitismo: todos os indivíduos são substituídos e o indivíduo mais apto é copiado na população seguinte.

3 – Troca parcial da população: cria-se M indivíduos ($M < N$), que substituem os piores indivíduos da população corrente.

4 – Troca parcial da população sem duplicados: semelhante ao anterior, sem permitir a presença de indivíduos duplicados.

2.8.1.4 Operadores Genéticos

Os operadores genéticos classificam-se em:

- Cruzamento;
- Mutação; e
- Inversão.

O cruzamento é realizado logo após a aplicação de um método de seleção. Esse operador, em sua forma mais simples, é aplicado em duplas selecionadas aleatoriamente a partir dos indivíduos selecionados. Em seguida, cada par de indivíduos é cruzado a partir de um ponto de corte. Esse ponto de corte k é selecionado aleatoriamente e varia entre $[1, L - 1]$ (L é o número de genes do indivíduo). Assim, dois novos indivíduos são criados trocando todos os caracteres entre as posições $k + 1$ e L (GOLDBERG, 1989). Para fins ilustrativos pode-se observar um exemplo apresentado em Goldberg (1989):

$$A_1 = 0 \ 1 \ 1 \ 0 \ | \ 1$$

$$A_2 = 1 \ 1 \ 0 \ 0 \ | \ 0$$

Nesse exemplo têm-se dois cromossomos e uma posição entre 1 e 4 e selecionada aleatoriamente, por exemplo, $k = 4$ (indicado pelo símbolo separador $|$). Os descendentes são:

$$A'_1 = 0\ 1\ 1\ 0\ 0$$

$$A'_2 = 1\ 1\ 0\ 0\ 1$$

O operador de cruzamento possui algumas variações, algumas delas são: cruzamento com n pontos de corte e cruzamento uniforme.

O cruzamento com n pontos é similar ao por um ponto, onde os locais de corte são escolhidos aleatoriamente. Por exemplo, supõe-se $n = 4$ e que os pontos de corte são o 4, 6, 9 e 12. Tem-se (SOARES, 1997).

$$A_1 = 1\ 0\ 1\ 0\ |0\ 0\ |0\ 0\ 1\ |0\ 0\ 1\ |1\ 1\ 1\ 0$$

$$A_2 = 1\ 1\ 0\ 1\ |1\ 1\ 1\ 0\ 1\ |1\ 1\ 0\ 0\ 1\ |0\ 0\ 0\ 0$$

Resulta em:

$$A'_1 = \mathbf{1\ 0\ 1\ 0\ |1\ 1\ |0\ 0\ 1\ |0\ 0\ 1\ |1\ 1\ 0}$$

$$A'_2 = 1\ 1\ 0\ 1\ |\mathbf{0\ 0\ |0\ 1\ 1\ |0\ 0\ 1\ |0\ 0\ 0}$$

No cruzamento uniforme que é capaz de recombinar quaisquer posições entre os dois genitores. Para cada bit verifica-se a ocorrência de um evento com probabilidade de 50%. Se sim, esse bit é um ponto de corte, caso contrário, repete-se o procedimento para o bit posterior (SOARES, 1997).

O operador de mutação é utilizado para garantir uma maior varredura do espaço de busca e evitar que o algoritmo genético convirja muito cedo para mínimos locais (MITCHELL, 1999). A mutação é efetuada alterando-se o valor de um gene de um indivíduo sorteado aleatoriamente com uma determinada probabilidade, denominada probabilidade de mutação, ou seja, vários indivíduos da nova população podem ter um de seus genes alterado aleatoriamente.

A inversão é um operador genético, considerado secundário, que efetua a troca de posições entre genes escolhidos de forma aleatória. Ele foi criado para evitar que bons padrões se quebrem ao realizar o cruzamento. Dessa maneira, antes do cruzamento, a inversão é aplicada em um indivíduo, com uma determinada probabilidade, invertendo a

ordem dos elementos entre dois pontos de corte escolhidos aleatoriamente (SOARES, 1997). Por exemplo (SOARES, 1997):

$$A_1 = 1 \ 0 \ \mathbf{1} \ \mathbf{1} \ 0 \ 1$$

$$A'_1 = 1 \ 0 \ \mathbf{0} \ \mathbf{1} \ \mathbf{1} \ 1$$

O operador de inversão traz um custo computacional alto e é dificilmente empregado (SOARES, 1997).

Ao fim dessas operações cria-se uma nova população, chamada de geração que, espera-se, representa uma melhor aproximação da solução do problema de otimização que a população anterior.

2.8.1.5 Critérios de Parada

Como critérios de parada do algoritmo em geral são usados a aptidão do melhor indivíduo em conjunto com a limitação do número de gerações. Outros critérios podem envolver, por exemplo, um erro abaixo de um valor especificado pelo projetista para um determinado parâmetro do problema (PACHECO, 1999).

2.9 Vetorização e Poligonização

O processo de vetorização consiste em varrer todos os pixels de uma imagem binária e formar uma lista ordenada de pixels. Esse processo é realizado a partir de uma lista não ordenada de pixels proveniente de algum processo de detecção e afinamento de bordas e linhas (JAIN et al., 1995).


A ideia básica consiste em varrer toda imagem e, quando encontrar uma borda ou linha, varrê-la de ponta a ponta, armazenando sequencialmente as coordenadas dos respectivos pixels, com simultânea eliminação da imagem binária de linha ou borda (mudando a codificação dos pixels de 1 para 0) dos pixels que já foram integrados nas listas

de linha ou borda. Neste processo de varredura, em cada pixel de linha ou borda é possível a continuidade da linha ou borda ao longo de oito direções possíveis. Entretanto, várias destas direções podem ser eliminadas a priori através do conhecimento da direção local do vetor gradiente da imagem. Este algoritmo está detalhadamente descrito em Dal Poz (2002).

Após a obtenção das cadeias de pixels, é possível determinar as sequências de pixels que podem ser modeladas por feições retas. Uma maneira de se obter esse resultado é através de algoritmos de poligonização, cujos resultados são polígonos para contornos fechados e linhas poligonais para contornos abertos.

Existem vários algoritmos de poligonização, dentre os quais pode-se citar o algoritmo de divisão recursiva (JAIN et al., 1995). Tendo por base uma cadeia de pixels de borda ou linha, o algoritmo insere recursivamente novos vértices, até que a linha poligonal, definida pelos pontos extremos e os vértices gerados aproxime, com uma precisão desejada, à curva inicial. Como mostra a Figura 2.16(a), inicialmente a curva inicial é modelada grosseiramente pelo segmento de reta definido pelos pontos A e B. Na sequência (Figura 2.16(b)), o segmento \overline{AB} é subdividido através da inclusão de um novo ponto C, que é o ponto da curva inicial mais distante do segmento de reta \overline{AB} . A linha poligonal definida pelos pontos A, B e C é uma modelagem melhor para a curva inicial. O mesmo é feito com o segmento de reta \overline{CB} , dando origem ao ponto D e a linha poligonal definida pelos pontos A, C, D e B (Figura 2.16(c)). Esta linha poligonal é uma melhoria significativa da modelagem anterior (Figura 2.16(b)). O procedimento prossegue até que nenhum ponto da curva inicial esteja a uma distância da linha poligonal superior a um limiar pré-definido.

Figura 2.16 – Algoritmo de divisão recursiva.



Fonte: Adaptado de JAIN et al. (1995).

3. MATERIAL E MÉTODO

3.1 Introdução

Esse capítulo apresenta os materiais necessários para a realização da pesquisa e o método proposto. Na seção 3.2 são apresentados os dados e os recursos computacionais utilizados no desenvolvimento desse trabalho. A seção 3.3 apresenta o método de extração de telhados de edifícios proposto.

3.2 Material

3.2.1 Dados

Os dados utilizados na execução desse trabalho foram: 1- Imagens aéreas digitais (com parâmetros de orientação interior e exterior), de dimensões 6708 x 8956 pixels e resolução espacial de aproximadamente 6 cm, tomadas na cidade de Presidente Prudente/ SP no ano de 2011; e 3 – Nuvem de pontos LASER com densidade de aproximadamente 8 pontos/ m² do ano de 2013. Ambos os dados adquiridos pela empresa Engemap e fornecidos pelo Departamento de Cartografia da Faculdade de Ciências e Tecnologia (FCT) da Universidade Estadual Paulista (UNESP) – Campus de Presidente Prudente/ SP.

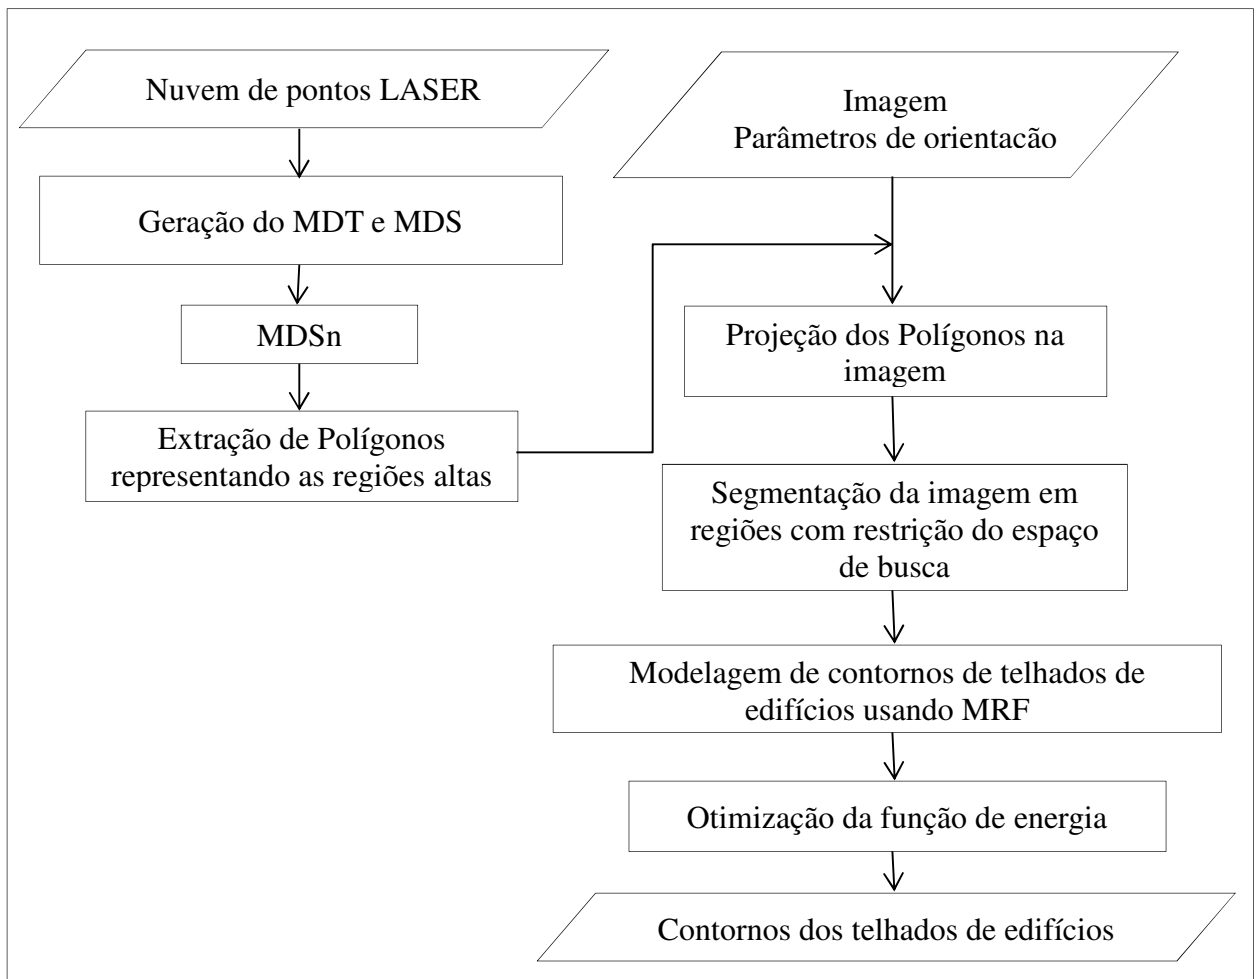
3.2.2 Recursos de Hardware e Software

Os principais recursos de hardware e software utilizados foram: biblioteca de funções/classes em C/C++ desenvolvidas anteriormente pelo grupo de pesquisa; biblioteca de funções/classes em C/C++ disponíveis no HALCON 12.0 da MVTec; software Inpho 6.0 para processamento; software Surfer 8.0; compilador Visual Studio C++ 2013; software Lastools para visualização; microcomputadores disponíveis no Laboratório de Fotogrametria e Sensoriamento Remoto da FCT/UNESP.

3.3 Método

O fluxograma a seguir (Figura 3.1), apresenta o método proposto para extração automática de contornos de telhados de edifícios.

Figura 3.1 – Fluxograma do método proposto.




As principais etapas do método (Figura 3.1) são a extração de polígonos representando regiões altas a partir de um MDSn obtido com uso de dados VLA, segmentação da imagem para extração de polígonos representando as regiões altas, o estabelecimento da função de energia ($U(x)$) com base em um modelo MRF e a otimização da função de energia através algoritmo de otimização AG.

As subseções seguintes apresentam detalhes sobre cada etapa do método proposto.

3.3.1 Extração de Polígonos representando as regiões altas a partir do MDSn

Os dados provenientes da varredura a LASER são pontos irregularmente espaçados (Figura 3.2 (a)), representados pelas coordenadas (E, N, h) . Neste caso, (E, N) correspondem às coordenadas planimétricas e h é a altitude ortométrica de um ponto. O primeiro passo do método proposto consiste em realizar a filtragem dos pontos LASER para detectar e eliminar pontos não pertencentes ao terreno. Esse procedimento é realizado no software Inpho 6.0, conforme exemplo apresentado na Figura 3.2 (b).

Figura 3.2 – Exemplo do procedimento de filtragem.
(a) Malha irregular original; e (b) malha irregular filtrada.

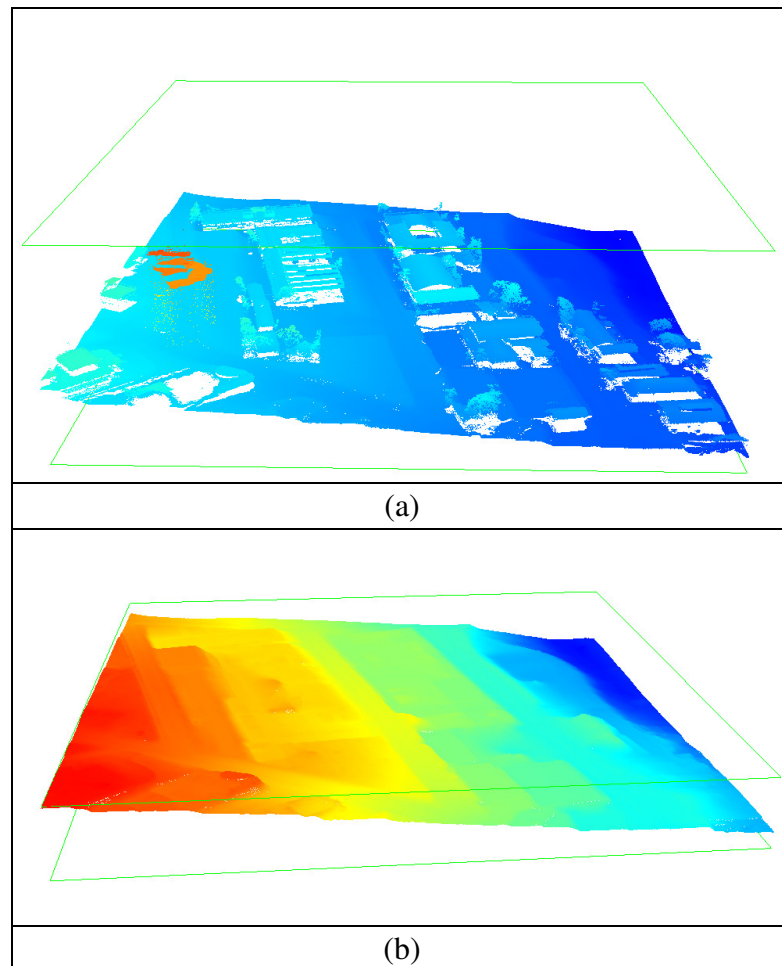


Esse procedimento é realizado para obter uma malha irregular filtrada para a geração do MDT. Conforme dito, os pontos fornecidos pela varredura a LASER consistem de uma amostragem irregular, ou seja, não é conhecido o exato espaçamento entre os pontos da grade gerada. Para a geração de uma grade regular é necessária a aplicação de um método de interpolação (Subseção 2.3.1) para a atribuição de valores de h as novas posições criadas pela malha. E, assim, o MDS e o MDT em grade regular são obtidos (Capítulo 2, Seção 2.3). Para gerar o MDS o interpolador utilizado é o vizinho mais próximo. Esse interpolador tem um comportamento desejável, no caso envolvendo telhados de edifícios, uma vez que não cria valores intermediários e proporciona uma maior nitidez nas bordas do telhado (GALVANIN, 2007). Para gerar o MDT foi utilizado o interpolador krigagem, nesse caso, assume-se um comportamento suave no interior das quadras e esse método de interpolação

Extração de contornos de telhados de edifícios a partir da integração de imagem aérea de alta-resolução e dados LASER, utilizando campos aleatórios de Markov


preserva melhor essas características por manter a continuidade do terreno (BOTELHO, 2007). Para o processo de interpolação foi utilizado o software Surfer 8.0. A Figura 3.3 mostra um exemplo de MDS e MDT de uma mesma área.

Figura 3.3 – Exemplo de MDS e MDT.
(a) Visão 3D do MDS; e (b) visão 3D do MDT.



Com o intuito de evitar os efeitos da topografia, calcula-se o MDSn (Modelo Digital de Superfície normalizado), que corresponde à diferença entre o MDS e o MDT (Figura 3.4).

Figura 3.4 – Exemplo de um MDSn.



Para a obtenção dos polígonos representando as regiões altas, inicialmente, o MDSn é transformado em uma imagem de elevação. Essa imagem passa por um processo de segmentação. Para tanto, foi utilizado um operador de limiarização presente no software Halcon 12.0, o qual determina limiares automáticos a partir da detecção de mínimos no histograma da imagem (Capítulo 2, Seção 2.2). Na sequência, as regiões altas passam a ser representadas por polígonos. Para tanto, é aplicado um algoritmo de vetorização de contornos seguido da poligonação (Capítulo 2, Seção 2.9), com algoritmos disponíveis no Halcon 12.0. Também é aplicado um limiar para eliminação de pequenas áreas. Um exemplo de resultado obtido com esse procedimento pode ser observado na Figura 3.5.

Figura 3.5 – Exemplo de polígonos representando objetos altos.

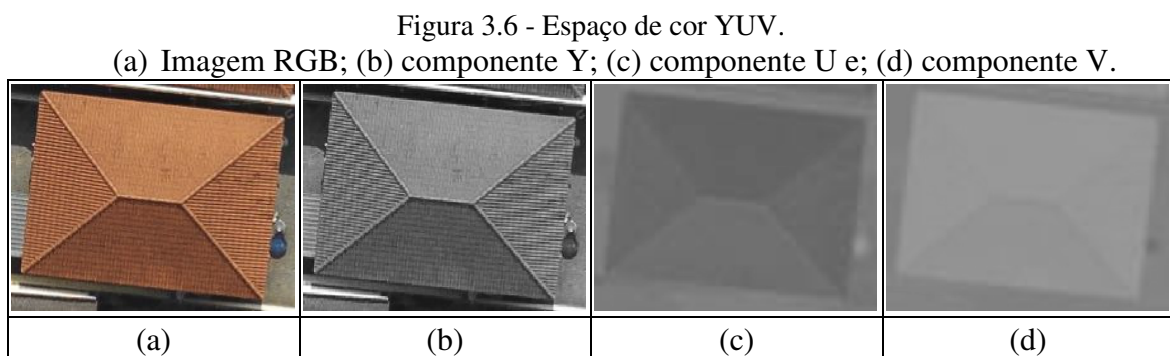


3.3.2 Extração de Polígonos representando as regiões altas na Imagem

Em seguida, projeta-se (Seção 2.5) na imagem os polígonos representando objetos altos, obtidos na etapa anterior, com o objetivo de fornecer parâmetros para realizar a segmentação da imagem em regiões. A projeção desses polígonos é usada para isolar as regiões na imagem que os contêm através de recortes nessa imagem. Esse recorte deve ser gerado com certa tolerância (t_e), a fim de garantir o enquadramento do correspondente objeto na imagem. Dessa maneira, a segmentação é aplicada somente nesses recortes. Nesse trabalho foram utilizados operadores disponíveis no software Halcon 12.0 da MVTec.

O processo de detectar superfícies inclinadas, como o caso do telhado de edifício, em imagens é bastante desafiador devido às diferentes reflexões da luz no momento da tomada da imagem, que causam uma alta descontinuidade em intensidade/cor em uma única estrutura (COTE e SAEEDI, 2013). Dessa forma, com vista a solucionar possíveis problemas relacionados à segmentação de um mesmo telhado de edifício em várias regiões, optou-se por trabalhar com o espaço de cor YUV, mais próximo da percepção humana e que torna possível remover a influência da componente intensidade.

Em um primeiro momento, foi realizada a transformação das componentes RGB para o espaço de cor YUV (Seção 2.1.4). A componente Y determina a luminância e as componentes U e V são as componentes cromáticas. A seguir, na Figura 3.6, pode-se observar uma imagem RGB e suas componentes YUV.




Na sequência, as componentes U e V são usadas para gerar um histograma bidimensional. Os tons de cinza da componente U são interpretados como valores atribuídos ao eixo linha e os tons de cinza da componente V como valores do eixo coluna. O valor de

cinza de um ponto $P (g_1, g_2)$ da imagem de saída indica a frequência de combinação (g_1, g_2) . A seguir, o histograma passa por um processo de suavização pela média.

O próximo passo consiste em determinar quais e quantas são as regiões significativas nesse histograma. Para tanto, foi utilizado o operador *watershed* (Seção 2.2.2) com uso de limiar. Inicialmente, esse operador segmenta regiões pelo método *watershed* e em seguida funde regiões que são separadas umas das outras por uma *watershed* menor que um limiar estipulado. Dessa forma, esse limiar funciona como um critério de fusão entre as regiões segmentadas. Supondo B_1 e B_2 sendo os menores valores de cinza entre duas regiões vizinhas e W o menor valor de cinza da *watershed* que separa essas duas regiões, duas regiões são fundidas se $\max\{W-B_1, W-B_2\} < W_{limiar}$.

A seguir, na Figura 3.7 pode ser observado um exemplo de imagem representando um histograma bidimensional produzido a partir das componentes U e V apresentadas na Figura 3.6 (c) e (d). Também estão representadas as regiões significativas encontradas pelo método *watershed* com uso de limiar.

Figura 3.7 - Histograma bidimensional e as linhas *watersheds*.




As linhas *watersheds* encontradas delimitam regiões significativas no histograma, por exemplo, na Figura 3.8 foram encontradas duas regiões significativas (uma região delimitada pela linha verde e a outra pela vermelha). Esse resultado é então utilizado para segmentar a imagem a partir de um operador de classificação por pixel de duas dimensões. As dimensões consideradas são as componentes U e V da imagem.

Dessa forma, para cada ponto da imagem são considerados dois valores de cinza (um da componente U e outro da V) e então é feita a comparação com as *watersheds* encontradas a partir do histograma. Assim, seja P um ponto com coordenadas $P (L, C)$, $g(l)$ o valor de cinza na posição (L, C) da componente U e $g(c)$ o valor de cinza na posição (L, C) da componente V, busca-se no histograma com base nas *watersheds* encontradas em qual

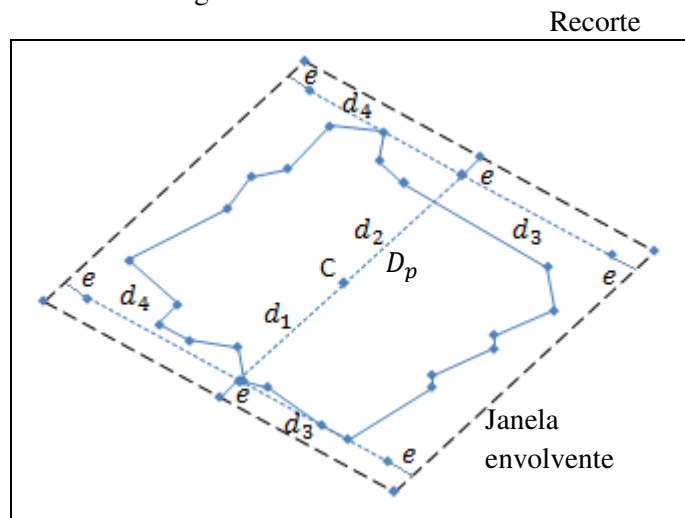
das regiões o ponto deve ser agregado. Segmentada a imagem, é aplicado um operador de preenchimento de buracos. Esse operador elimina pequenas regiões através da comparação do pixel com sua vizinhança. A seguir é apresentado um exemplo do resultado do procedimento de segmentação da imagem (Figura 3.8).

Figura 3.8 – Exemplo de segmentação da imagem.
(a) Imagem RGB; e (b) imagem segmentada.



Para selecionar qual das regiões segmentadas corresponde ao objeto alto presente na cena é realizada uma nova restrição do espaço de busca utilizando o polígono projetado extraído dos dados VLA (Figura 3.9). Essa restrição do espaço de busca corresponde a manter somente polígonos extraídos na imagem que estejam dentro de uma janela envolvente calculada a partir da direção principal (D_p) do polígono extraído dos dados VLA que foi projetado na imagem. Conforme ilustra a Figura 3.9, o retângulo maior em preto corresponde ao recorte da imagem e a janela envolvente corresponde ao retângulo tracejado em preto.

Figura 3.9 – Janela envolvente.



Para o cálculo dessa janela envolvente, primeiro é obtida a direção principal do polígono em questão. Para calcular o ângulo principal de um objeto, uma possibilidade é dividir o círculo trigonométrico em 24 setores de 15° e cada setor ser representado por seu ângulo central. A direção do eixo principal de um objeto é calculada na forma que segue (GALVANIN, 2007): 1 – calcular a direção e comprimento de cada segmento de reta do polígono que representa o objeto; 2 – inicializar cada setor com valor nulo; 3 – para uma dada direção de um dado segmento de reta, verificar qual setor que a contém, adicionando a este setor o valor inteiro do comprimento do respectivo segmento de reta; 4 – repetir o passo 3 para todos os segmentos de reta do polígono; 5 – identificar a direção do eixo principal como sendo a primeira direção maior.

Calculada a direção principal (D_p) do polígono, o próximo passo consiste em obter a reta que passa pelo centro do polígono (C) e tem direção angular igual à direção principal. Em seguida, calcular as distâncias entre essa reta e os pontos que definem o polígono (linhas contínuas em azul na Figura 3.9) e selecionar as maiores distâncias à direita (d_3) e a esquerda (d_4) da reta (Figura 3.9). O mesmo procedimento é realizado com a reta que passa pelo centro e tem direção angular igual à direção principal mais 90° ($D_p + 90^\circ$) para obter as distâncias d_1 e d_2 (Figura 3.9). Essas distâncias são então utilizadas para estabelecer as dimensões da janela envolvente. Nessa etapa do procedimento deve ser considerada uma tolerância (e) para cada uma das distâncias obtidas.

Os polígonos extraídos no recorte da imagem que estão contidos na janela envolvente são mantidos e passam por uma análise de tamanho de área. O polígono de maior área é conservado (Figura 3.10).

Figura 3.10 – Exemplo de um contorno de telhado de edifício obtido pelo método proposto.



Vale ressaltar que os pré-processamentos realizados, principalmente nos dados VLA, não garantem o isolamento de apenas contornos de edifício. Cada polígono resultante da segmentação da imagem envolve um objeto alto. Assim, o grande desafio deste trabalho é

o desenvolvimento de uma função de energia que responda otimamente (com um mínimo) a configurações de polígonos representando, idealmente, somente contornos de edifícios.

Para o reconhecimento de contornos de telhados de edifícios em meio a esses objetos altos devem ser consideradas algumas propriedades relacionadas a esse objeto para assim, definir a função de energia baseada na modelagem MRF.

3.3.3 Modelagem MRF

Os polígonos extraídos da imagem e os extraídos dos dados VLA pelo método proposto são usados para construir um modelo MRF expressando formas específicas de contornos de telhados de edifícios. A função de energia é definida de forma que cada região (polígono extraído da imagem e extraído dos dados VLA) é associada com uma variável aleatória (x_i), que assume valores binários de acordo com a regra especificada na Expressão 3.1.

$$x_i = \begin{cases} 1 & \text{se a } i - \text{ésima região for um contorno de telhado} \\ 0 & \text{caso contrário} \end{cases} \quad (3.1)$$

Essa regra dá origem a um vetor aleatório n-dimensional, em que n é o número de regiões. Esse vetor aleatório é a incógnita a ser determinada no processo de otimização.

A construção da função de energia $U(I|F, k)$, com base em MRF, depende fundamentalmente do conhecimento a priori sobre as propriedades do objeto telhado. O conhecimento a priori (k) sobre o objeto de interesse é de fundamental importância na análise da imagem, uma vez que permite supor o que se espera do objeto antes de aplicar o algoritmo de análise. A caracterização de k consiste em estabelecer valores nominais para os atributos que são importantes no processo de decisão na análise. Já os valores nominais para o conjunto (F) de atributos podem ser medidos no polígono envolvente que contém cada objeto individual e entre polígonos, caracterizando a relação contextual entre os objetos.

Para um melhor entendimento da função de energia, inicialmente, serão apresentados algumas propriedades de contorno de telhados que serão usadas para a formulação da função de energia.

Os telhados possuem algumas propriedades de interesse, como, as geométricas, as quais estão relacionadas com a retangularidade, direção, entre outras, e as relações contextuais nas quais o objeto telhado se relaciona com outros objetos presentes na cena (por exemplo, ângulos entre eixos de objetos).

Inicialmente, é necessário definir o sistema de vizinhança η_{R_i} , ou seja, as regiões R_j vizinhas de R_i ($i \neq j$), conforme proposto em Galvanin (2007),

$$\eta_{R_i,r} = \{R_j \mid \text{dist}(R_j, R_i) \leq r\} \quad (3.2)$$

em que a função dist é a distância euclidiana entre os centros de massa de dois objetos analisados (R_j, R_i) e r é a distância máxima permitida entre R_i e R_j .

A retangularidade é um dos atributos a ser utilizado. Para o cálculo desse atributo considera-se o ângulo formado pela direção principal e secundária de um objeto. Na seção 3.3.2 já foi apresentado o procedimento utilizado para o cálculo da direção principal. Para obter a secundária basta identificar a segunda direção mais frequente do objeto.

A retangularidade é expressa na Equação 3.3.

$$r = |\text{sen } \theta| \quad (3.3)$$

em que θ é o ângulo entre as direções principal e secundária.

A ideia fundamental desse atributo é beneficiar objetos com formas geométricas regulares, em que prevalecem os ângulos retos nos vértices do contorno. Assim, o ângulo formado entre a direção principal e secundária de um objeto, no processo de extração de contornos de telhados, em sua forma ideal, é 90° ou 270° , ou seja, $r = 1$. Assim, o valor ideal do conhecimento a priori k para o problema em questão é igual a 1 (um).

O atributo relacionamento espacial baseia-se no ângulo entre as direções principais de dois objetos (R_j, R_i) vizinhos (Equação 3.4).

$$Re(R_i, R_j) = |\cos(2\theta_{ij})| \quad (3.4)$$

em que θ_{ij} é o ângulo entre as direções principais de dois objetos.

Esse atributo atua na verificação do paralelismo ou da perpendicularidade de objetos, ou seja, se o ângulo entre dois objetos é igual a 0° (eixos principais paralelos) ou igual a 90° (eixos principais perpendiculares), $Re(R_i, R_j) = 1$. O valor ideal do conhecimento k é igual a 1 (um).

A função de energia $U(x)$ é formulada baseada em três termos de energia, dois deles construídos com base nos atributos apresentados e um que relaciona os polígonos extraídos da imagem e dos dados VLA.

O primeiro termo $U_1(x)$ é baseado no atributo retangularidade. Para o problema em questão, o atributo retangularidade é considerado tanto para o polígono extraído da imagem quanto para o correspondente polígono projetado na imagem que foi extraído dos dados VLA. Dessa forma, a verificação dessa propriedade é realizada com base em ambos os ângulos obtidos entre as direções principais e secundárias desses polígonos. Ainda com relação a esse atributo, deve-se considerar um peso maior para os polígonos extraídos da imagem, já que a varredura a LASER apresenta baixa densidade de informações posicionais ao longo de linhas de quebra e, dessa forma, o polígono extraído da imagem apresenta uma maior estabilidade geométrica quando comparado ao polígono extraído dos dados VLA. A retangularidade deve, dessa maneira, favorecer objetos que apresentem uma boa resposta para ambos os polígonos, ou que apresentem uma boa resposta para o polígono extraído da imagem. O termo de retangularidade é expresso matematicamente pela Equação 3.5.

$$U_1(x_i) = \sum_{i=1}^n |x_i - (r_i^I + r_i^L)| \quad (3.5)$$

em que $r_i^I = p_I |\sin \theta_i^I|$ e $r_i^L = p_L |\sin \theta_i^L|$, definidos a partir do atributo retangularidade; θ_i^I e θ_i^L são os ângulos formados entre as direções principais e secundárias do polígono extraído da imagem e do polígono projetado na imagem extraído dos dados VLA, respectivamente; e p_I e p_L são pesos atribuídos aos polígonos imagem e LASER, respectivamente, em que $p_I + p_L = 1$.

O termo de energia de relacionamento espacial (Equação 3.6) deve favorecer o agrupamento de telhados, isso porque os eixos principais dos telhados são, num padrão urbano axadrezado, paralelos ou perpendiculares.

$$U_2(x_i) = - \sum_{i=1}^n \sum_{j \in \eta_i} x_i \cdot x_j \cdot (re_{ij}^I + re_{ij}^L) \quad (3.6)$$

em que $re_{ij}^I = p_I |\cos(2\theta_{ij}^I)|$ e $re_{ij}^L = p_L |\cos(2\theta_{ij}^L)|$ definidos pelo atributo relacionamento espacial; θ_{ij}^I e θ_{ij}^L são ângulos entre as direções principais de dois polígonos, polígonos extraídos da imagem e extraídos dos dados VLA, respectivamente; e p_I e p_L são pesos atribuídos aos polígonos imagem e LASER, respectivamente, $p_I + p_L = 1$. No problema apresentado nesse trabalho, é verificado simultaneamente, o paralelismo ou a perpendicularidade entre objetos, tanto para os polígonos extraídos da imagem quanto para os polígonos extraídos dos dados VLA. Nesse caso, também deve ser atribuído um peso maior para os polígonos extraídos da imagem. O sinal negativo é atribuído a esse termo justamente para seguir a regra de favorecimento dos polígonos extraídos da imagem.

O termo de energia orientação relativa (Equação 3.7) é calculado com base no ângulo obtido entre as direções principais do polígono extraído da imagem e do polígono projetado na imagem que foi extraído dos dados VLA. Assim, esse atributo beneficia objetos envolvidos por polígonos com direções angulares similares.

$$U_3(x_i) = \sum_{i=1}^n x_i |\sen \theta_i| \quad (3.7)$$

em que $\theta_i = |\theta_L - \theta_{im}|$; θ_L é a direção principal do polígono projetado na imagem que foi extraído dos dados VLA; e θ_{im} é a direção principal do polígono extraído da imagem. Nesse caso, o ângulo entre as direções principais, em sua forma ideal, é igual a 0° ou 180° . Essa expectativa dificilmente ocorreria para objetos irregulares (por exemplo, um segmento de vegetação). Quanto mais retilíneo o objeto, maior a chance dos eixos serem paralelos.

Por fim, a equação de energia é formulada como,

$$U(x) = \alpha_1 U_1(x) + \alpha_2 U_2(x) + \alpha_3 U_3(x) \quad (3.8)$$

em que, α_1 , α_2 e α_3 são constantes positivas e a soma delas é igual a 1. Essas constantes são pesos que dão a importância relativa para cada termo da função de energia.

3.3.4 Otimização da Função de Energia

Em Marcato e Dal Poz (2014) foi utilizado para a otimização da função de energia o Algoritmo Genético (AG). No problema em questão, o objetivo era encontrar a melhor configuração de retas extraídas da imagem que representassem os lados de contorno e cumeeiras de um telhado de edifício. Esse método de otimização se mostrou bastante eficiente e proporcionou resultados satisfatórios.

Nesse trabalho, da mesma forma que em Marcato e Dal Poz (2014), o vetor incógnito a ser determinado no processo de otimização é aleatório e binário. Assim, o problema já encontra-se concebido de forma a facilitar o uso do algoritmo AG para otimizar a função de energia, dessa forma, basta somente particularizar para o caso presente.

Assim, o primeiro passo para aplicar esse método de otimização consiste em inicializar a população. Cada indivíduo (cromossomo) dessa população inicial consiste de n genes, ou seja, n regiões extraídas na cena, que são candidatas a representarem contornos de edifícios. A população inicial de m indivíduos é gerada de forma aleatória (Figura 3.12).

Figura 3.12 – População inicial.

| Regiões Candidatas | 1 | 2 | 3 | 4 | 5 | 6 | 7 | ... | n |
|--------------------|---|---|---|---|---|---|---|-----|-----|
| Cromossomos | | | | | | | | | |
| 1 | 1 | 0 | 1 | 0 | 1 | 1 | 0 | ... | 1 |
| 2 | 0 | 1 | 1 | 0 | 0 | 1 | 1 | | 0 |
| 3 | 0 | 1 | 0 | 1 | 0 | 1 | 0 | | 1 |
| 4 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | | 1 |
| 5 | 1 | 1 | 0 | 0 | 1 | 1 | 0 | | 1 |
| 6 | 0 | 0 | 0 | 1 | 1 | 1 | 1 | | 0 |
| 7 | 1 | 1 | 0 | 0 | 0 | 0 | 0 | | 1 |
| . | . | | | | | | | | |
| . | . | | | | | | | | |
| . | . | | | | | | | | |
| m | 1 | 1 | 0 | 0 | 1 | 1 | 0 | | 0 |

Por exemplo, na Figura 3.12, tem-se vetores binários (1, 2,..., m) (cromossomos), em que cada célula (gene) representa uma região candidata. Se determinada região candidata a representar um contorno de telhado for selecionada, a variável aleatória associada com essa região (gene) recebe o valor 1 e se não recebe o valor 0. Assim, cada cromossomo dessa população inicial possui uma configuração de regiões representativas de contornos de telhados a ser testada, ou seja, cada um desses indivíduos é uma possível solução para o problema.


Gerada a população inicial, em seguida, é calculada a aptidão de cada cromossomo da população com o uso da função de energia (Equação 3.8). Candidatos mais aptos, nesse caso, correspondem à proximidade do mínimo da função.

Com base na aptidão do candidato é realizada a seleção dos mais aptos. Nesse trabalho utiliza-se a seleção por amostragem determinística. Na escolha desse método de seleção considera-se que há a possibilidade de um indivíduo pouco apto possuir alguma característica que não deve ser perdida e pode ser aproveitada nas etapas seguintes. Nessa suposição pode-se considerar que talvez os indivíduos mais aptos não possuam tal característica e que conservar somente esses indivíduos pode acarretar em uma convergência local.

A técnica de reprodução utilizada é a troca de toda população por elitismo, ou seja, todos os indivíduos são substituídos e o indivíduo mais apto é copiado na população seguinte. Dessa forma, o indivíduo mais apto da geração atual já está garantido na próxima geração. Resta selecionar $m - 1$ indivíduos para formar uma lista de selecionados para as próximas etapas (cruzamento e mutação).

Com os indivíduos selecionados é iniciado o processo de cruzamento. Essa operação consiste em formar duplas de cromossomos de forma aleatória e com uma determinada probabilidade efetuar a troca de genes entre esses dois, a partir de um ponto de corte (Figura 3.13).

Figura 3.13 – Cruzamento.



| Regiões Candidatas | 1 | 2 | 3 | 4 | 5 | 6 | 7 | ... | n |
|-------------------------|---|---|---|---|---|---|---|-----|-----|
| Indivíduos selecionados | | | | | | | | | |
| 1 | 1 | 0 | 1 | 0 | 1 | 1 | 0 | ... | 1 |
| 2 | 0 | 1 | 1 | 0 | 0 | 1 | 1 | | 0 |
| | | | | | | | | | |
| 1' | 1 | 0 | 1 | 0 | 0 | 1 | 1 | | 0 |
| 2' | 0 | 1 | 1 | 0 | 1 | 1 | 0 | | 1 |

São formados a partir de dois indivíduos outros dois novos (Figura 3.13). Um dos dois novos indivíduos possui os genes do primeiro indivíduo do ponto de corte (seta) para trás e os genes do segundo indivíduo do ponto de corte para frente. Depois, o novo indivíduo possui os genes do primeiro indivíduo do ponto de corte para frente e os genes do segundo indivíduo do ponto de corte para trás.

O cruzamento, como já foi dito, tem uma probabilidade de acontecer. Desse modo é possível não ocorrer o cruzamento entre uma determinada dupla e, assim, os indivíduos dessa dupla permanecerem os mesmos.

Aplicado o cruzamento, há a possibilidade de ocorrer a mutação em um determinado indivíduo, ou seja, a troca da característica (Figura 3.14). A mutação é realizada com uma determinada probabilidade de mutação, normalmente bastante baixa.

Figura 3.14 – Mutaç o.



| Regi es Candidatas | 1 | 2 | 3 | 4 | 5 | 6 | 7 | ... | <i>n</i> |
|-----------------------|---|---|---|---|---|---|---|-----|----------|
| Indiv duo selecionado | | | | | | | | | |
| 1 | 1 | 0 | 1 | 0 | 1 | 1 | 0 | ... | 1 |
| | | | | | | | | | |
| 1' | 1 | 0 | 1 | 1 | 1 | 1 | 0 | | 1 |

  realizado, em seguida, o c lculo da aptid o de cada cromossomo dessa nova popula o e   realizado todo o procedimento novamente.

Esse processo repete-se at  que se atinja um crit rio de parada pr -estabelecido. Nesse trabalho utiliza-se um valor limite de itera es para t rmino do processo. O resultado ser  a escolha do indiv duo que ao final possuir a maior aptid o, ou seja, a configura o de regi es selecionadas   estabelecida pelo cromossomo mais apto encontrado durante o processo de otimiza o por AG.

4. RESULTADOS

4.1 Introdução

Esse capítulo apresenta a avaliação experimental do método de extração de contornos de telhado de edifícios desenvolvido neste trabalho. A Seção 4.2 traz a especificação dos parâmetros e limiares utilizados na realização dos experimentos. A Seção 4.3 apresenta as formas de avaliação dos resultados. Na Seção 4.4 são apresentados os resultados experimentais.

4.2 Parâmetros e limiares utilizados

Essa subseção apresenta os valores estabelecidos para os parâmetros e limiares utilizados nesse trabalho.

- Espaçamento da malha regular do MDS e MDT - 25 cm. Esse valor mostrou-se adequado para representar as cenas utilizadas;
- Área mínima: 20 m²;
- Tolerância para gerar o recorte na imagem $t_e = 80$ pixels;
- Tolerância para gerar a janela envolvente $e = 30$ pixels;
- Dimensão da máscara de suavização pela média do histograma da imagem: 9x9;
- Limiar utilizado no processo de segmentação por *watershed*, $W_{limiar} = 50$;
- Pesos $p_I = 0,7$ e $p_L = 0,3$, conforme já mencionado na Seção 3.3.3, deve ser atribuído peso maior ao polígono extraído na imagem devido a sua maior regularidade;
- Pesos $\alpha_1 = 0,4$ e $\alpha_2 = \alpha_3 = 0,3$. São pesos próximos, para evitar o favorecimento de um ou outro termo da função de energia. Foi atribuído peso um pouco maior para o termo de retangularidade por ser um atributo bastante característico de contornos de telhados de edifícios;
- Probabilidade de cruzamento, $p_c = 0,7$, e mutação, $p_m = 0,01$;
- Tamanho da população gerada pelo método AG, $m = 15$ e número de iterações = 40.

Os valores de limiares e parâmetros utilizados foram definidos, em sua maioria, a partir de tentativa e erro. Vale lembrar que esses parâmetros e limiares foram mantidos iguais para todos os experimentos.

4.3 Formas de análise dos resultados

Para avaliar o método proposto, vários experimentos foram realizados utilizando dados reais. Os resultados obtidos foram analisados visualmente e numericamente.

A análise visual refere-se basicamente à inspeção visual dos contornos de telhado extraídos sobrepostos na imagem aérea, o que permite avaliar o desempenho do método de extração de forma qualitativa ao indicar se a extração de um contorno de telhado foi bem sucedida ou não.

A análise quantitativa é baseada em parâmetros de qualidade, como: as porcentagens de contornos de telhados não extraídos (falsos negativos) e extraídos incorretamente (falsos positivos) e os parâmetros de completeza e correção. Os parâmetros de qualidade de completeza e correção são estimados a partir da comparação dos contornos de telhado extraídos com contornos de referência, considerados de melhor qualidade e obtidos através da identificação visual e medição manual das coordenadas de seus vértices na imagem aérea. O parâmetro de completeza corresponde à porcentagem da área de referência que foi extraída pelo método, e o parâmetro de correção está relacionado a quanto da área extraída está correta. A seguir são apresentadas as equações utilizadas para o cálculo da completeza e correção (Equações 4.1 e 4.2, respectivamente) (FAZAN e DAL POZ, 2013).

$$completeza = \frac{A_{E \cap R}}{A_R} 100\% \quad (4.1)$$

$$correção = \frac{A_{E \cap R}}{A_E} 100\% \quad (4.2)$$

em que: $A_{E \cap R}$ é a área do polígono resultante da intersecção entre os polígonos que descrevem os contornos do telhado extraído e de referência; A_R é a área do polígono correspondente ao contorno do telhado de referência; e A_E é a área do polígono correspondente ao contorno do telhado extraído pelo método proposto.

4.4 Resultados e análise

A seguir serão descritos e discutidos os resultados obtidos pela aplicação do método proposto. Para demonstrar o potencial desse método são apresentados sete experimentos com diferentes complexidades, que compreendem duas principais situações:

- Extração de contornos de telhados de edifícios isolados na imagem aérea que apresentam pouca ou nenhuma interação com telhados de outros edifícios, mas apresentam interação com árvores em maior ou menor quantidade. Essa situação é apresentada nos dois primeiros experimentos; e
- Extração de contornos de telhados de edifícios presentes em quadras urbanas de uso predominantemente residencial, com edificações de até dois pavimentos, onde existe maior interação dos telhados com objetos vizinhos, como telhados de outros edifícios e árvores. Situação apresentada nos demais experimentos.

4.4.1 Experimento 1

Essa seção descreve o primeiro experimento realizado para avaliar o método desenvolvido. Esse experimento tem por objetivo verificar o desempenho do método de extração de contornos de telhado de edifícios que estão isolados na imagem aérea.

Para a realização deste experimento foi selecionada uma área na imagem que compreende alguns edifícios da Faculdade de Ciências e Tecnologia FCT/UNESP de Presidente Prudente (Figura 4.1).


Figura 4.1 – Imagem aérea da região do experimento 1.



Conforme pode ser observado na Figura 4.1, a área considerada no Experimento 1 é formada por três telhados de edifícios. Cada um dos telhados que compõe a cena apresenta geometria retangular e simples.

Na Figura 4.2 pode ser observado o MDSn obtido para a região do Experimento 1.

Figura 4.2 – MDSn obtido para o experimento 1.



Nota-se (Figura 4.2) que os três edifícios presentes na cena foram destacados adequadamente, acentuando a diferença em altura entre o terreno e topo da edificação. Pode-se verificar que há uma quantidade considerável de vegetação alta.

Na Figura 4.3 é apresentada a projeção na imagem aérea do resultado obtido a partir da segmentação do MDSn/LASER. Foram extraídos oito polígonos dos dados VLA, que compreendem os três edifícios que compõem a cena (Polígonos 1, 2 e 3) e mais cinco polígonos que envolvem vegetação alta (Polígonos 4, 5, 6, 7 e 8). Vale lembrar que nesse resultado pode-se observar, que conforme previsto no método, nessa etapa já foi realizada um filtragem prévia com base em uma área mínima pré-definida.


Figura 4.3 - Polígonos extraídos dos dados VLA e projetados na imagem no experimento 1.



Pode-se notar que os polígonos 1, 2 e 3 apontam corretamente a localização dos telhados de edifícios, mas não definem bem seus contornos.

Na Figura 4.4 (a) pode ser observado o resultado obtido com a segmentação da imagem e na Figura 4.4 (b) o resultado obtido com o processo de otimização da função de energia. Na imagem (Figura 4.4 (a)), com a aplicação do método proposto para segmentação da imagem com restrição do espaço de busca (Seção 3.3.2 do Capítulo 3) foram obtidos oito polígonos correspondentes aos oito polígonos extraídos dos dados VLA (Figura 4.4). Conforme já dito, três desses polígonos são representativos de telhados de edifícios. Nota-se (Figura 4.4 (a)) que os contornos dos telhados de edifícios foram melhorados significativamente e se apresentam mais regulares e acurados em comparação com os extraídos do MDSn/LASER.

Figura 4.4 – Experimento 1. (a) Polígonos extraídos da Imagem; e (b) resultado do processo de otimização da função de energia.



Na Figura 4.5 (b) é apresentado o resultado do processo de otimização da função de energia pelo método AG, no qual foram conservados três polígonos. Pela análise visual verifica-se que os três polígonos conservados são representativos dos três telhados de edifícios presentes na cena. Verifica-se que os polígonos conservados foram favorecidos pelas características contidas na função de energia proposta (Equação 3.8). Os polígonos que envolvem cada um dos telhados de edifícios, tanto os extraídos dos dados VLA quanto os extraídos na imagem, apresentam forma aproximadamente retilínea (Termo 1 – Equação 3.5), seguem o padrão de agrupamento de telhados (paralelos ou perpendiculares entre eles) (Termo 2 – Equação 3.6) e apresentam orientação relativa similar (Termo 3 – Equação 3.7). A característica de retangularidade é mais acentuada nos polígonos extraídos na imagem, conforme pode ser visto nas Figuras 4.3 e 4.4(a). Nota-se que os polígonos desconsiderados não apresentam tais características, o que é esperado, uma vez que envolvem vegetação alta. Dessa forma, não possui falsos positivos ou falsos negativos, o que evidencia o bom funcionamento do processo de otimização da função de energia por AG.

A inspeção visual dos resultados mostra que a extração dos contornos de telhado foi bem sucedida, uma vez que se observa boa correspondência entre os contornos extraídos e os reais presentes na imagem aérea. No entanto, é possível verificar a ocorrência de pequenas irregularidades (destacadas na Figura 4.4 (b) por círculos amarelos) no contorno C1 causadas por alguns galhos de árvores que ocultam alguns trechos das bordas do telhado e também uma pequena falha em um dos cantos do contorno C2 causada por sombra.

A Figura 4.5 apresenta os contornos de telhado (sobrepostos na imagem aérea) utilizados como referência para a análise quantitativa dos resultados obtidos nesse experimento.

Figura 4.5 – Contornos de referência utilizados na análise quantitativa dos resultados obtidos no experimento 1.



Os parâmetros de qualidade estimados nessa análise são apresentados pela Tabela 4.1. Estes valores se referem à completude e correção.

Tabela 4.1 - Parâmetros de qualidade estimados na análise numérica dos contornos de telhado obtidos pelo método proposto para o experimento 1.

| Contornos | Completeza (%) | Correção (%) |
|------------------|-----------------------|---------------------|
| C1 | 99,31 | 99,87 |
| C2 | 98,28 | 99,96 |
| C3 | 100 | 100 |
| Mínima | 98,28 | 99,87 |
| Máxima | 100 | 100 |
| Média | 99,19 | 99,94 |

A análise numérica apresentada na Tabela 4.1 mostra que as médias dos parâmetros de completude e correção foram de 99,19% e 99,94%, respectivamente, valores que confirmam que os contornos de telhados de edifícios foram extraídos com sucesso. O menor valor de completude foi obtido pelo contorno C2 (98,28%) e o menor valor de correção foi obtido pelo contorno C1 (99,87%). O contorno C3 obteve valores máximos de completude e correção.

4.4.2 Experimento 2

Essa seção apresenta o segundo experimento realizado para avaliação do método proposto. Esse experimento tem por finalidade a extração de contornos de telhado de edifícios que encontram-se isolados na imagem aérea e apresentam interação com árvores.

A área teste selecionada para a realização do experimento 2 foi uma região da FCT/UNESP de Presidente Prudente/SP (Figura 4.6).


Figura 4.6 – Imagem aérea da região do experimento 2.



Na Figura 4.6 pode ser observado que a área selecionada para o experimento 2 contém cinco edifícios, regulares descritos por formas retilíneas, e possui bastante árvores que ocultam partes dos telhados de edifícios.

A Figura 4.7 mostra o MDSn obtido para o experimento 2. Verifica-se que (Figura 4.8) os três edifícios aparecem no MDSn com uma grande quantidade de árvores ao redor.

Figura 4.7 - MDSn obtido para o experimento 2.



A Figura 4.8 apresenta os polígonos obtidos a partir da segmentação do MDSn/LASER (Subseção 3.3.1, Capítulo 3), sobrepostos na imagem aérea. Foram extraídos dez polígonos dos dados VLA, três desses polígonos compreendem os cinco edifícios que compõem a cena (Polígonos 1, 2 e 3) e os demais polígonos envolvem vegetação alta (Polígonos 4, 5, 6, 7, 8, 9 e 10). Pode ser visto que o polígono 2 engloba três edifícios, o que representa uma falha do método de segmentação do MDSn/LASER causada pela dificuldade em separar estruturas de telhados de edifícios que estão bastante próximas e que possuem mesma altura. Os polígonos 1 e 3 apontam corretamente a localização dos telhados de edifícios, no entanto não definem bem seus contornos. Verifica-se que (Figura 4.8) os polígonos projetados apresentam uma forma bastante irregular e em alguns casos incorporam a vegetação alta próxima ao telhado de edifício.

Figura 4.8 - Polígonos extraídos dos dados VLA e projetados na imagem no experimento 2.



Na Figura 4.9 pode ser observado o resultado obtido com a aplicação do método proposto para segmentação da imagem com restrição do espaço de busca (Subseção 3.3.2 do Capítulo 3). A partir da segmentação da imagem foram extraídos dez polígonos correspondentes aos dez polígonos extraídos dos dados VLA, dos quais três compreendem os telhados de edifícios. Pode-se verificar que (Figura 4.9) os polígonos extraídos da

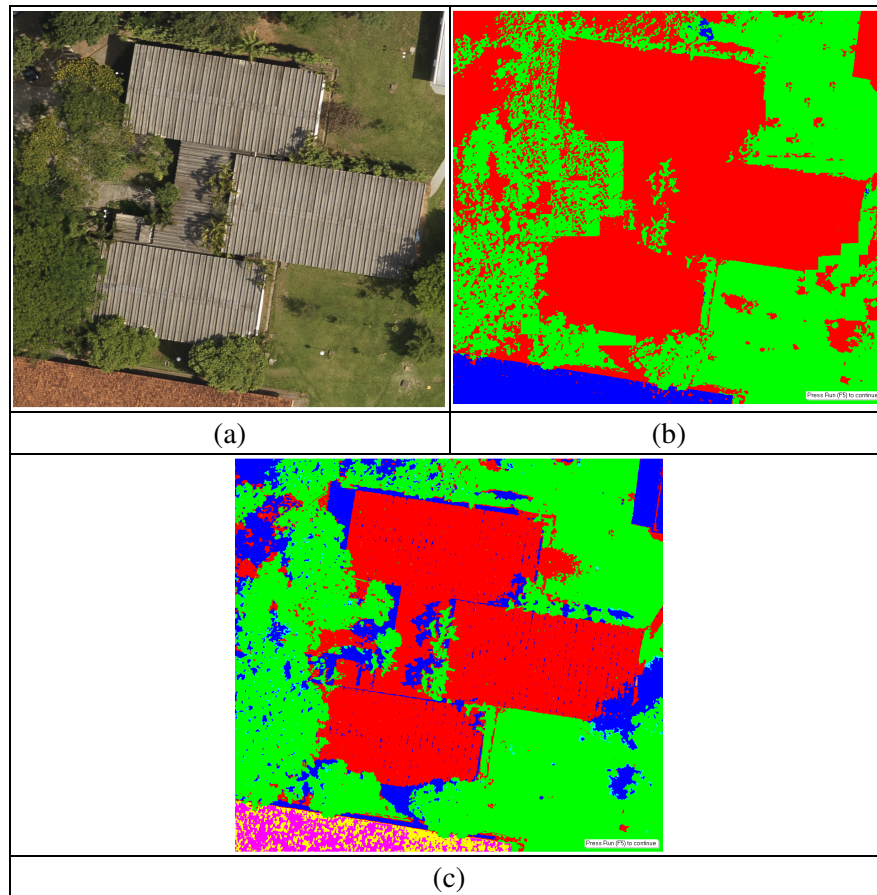
imagem correspondentes aos polígonos 1 e 3 (Figura 4.8) definem melhor os limites dos telhados de edifícios em comparação com os extraídos do MDSn/LASER. No entanto, existem algumas falhas na definição correta dos contornos dos telhados causadas por áreas ocultas por vegetação e pela presença de sombras.

Figura 4.9 - Polígonos extraídos da Imagem para o experimento 2.



No caso do polígono 2 (Figura 4.8) verifica-se que também na imagem foi obtido um único polígono que compreende os três telhados de edifícios. Essa situação pode ser verificada a partir da Figura 4.10, que apresenta o resultado da segmentação em regiões do correspondente recorte da imagem.

Figura 4.10 – Segmentação em regiões obtida na imagem para o polígono 2.
 (a) Recorte da Imagem RGB; (b) Imagem segmentada com suavização do histograma pela média de dimensão 9x9; e (c) Imagem segmentada com suavização do histograma pela média de dimensão 3x3.



Pode ser visto (Figura 4.10 (b)) que o método de segmentação da imagem uniu os três telhados de edifícios devido à similaridade em textura e cor entre as três estruturas. A Figura 4.10 (c) apresenta o resultado da segmentação em regiões do mesmo recorte com mudança na dimensão da máscara de suavização do histograma para 3x3. Verifica-se que nesse caso com a alteração desse parâmetro é possível separar os três telhados de edifícios. Como o objetivo é manter os mesmos parâmetros para todos os experimentos, essa simulação foi apenas para exemplificar a possibilidade de melhorar a segmentação para esse caso.

Na Figura 4.11 é apresentado o resultado do processo de otimização da função de energia pelo método AG.

Figura 4.11 - Resultado do processo de otimização da função de energia para o experimento 2.



A Figura 4.11 apresenta os três polígonos mantidos pelo processo de otimização da função de energia. Pode-se observar que os três polígonos conservados compreendem os telhados de edifícios presentes na cena. Apesar dos contornos representativos de telhados de edifícios apresentarem algumas irregularidades, conforme já mencionado, as características presentes nos polígonos representativos de telhados, tanto os extraídos dos dados VLA quanto os extraídos na imagem, foram suficientes para que no processo de otimização da função de energia o resultado os polígonos correspondentes a vegetação fossem eliminados. Pode-se observar que os polígonos desconsiderados não apresentam forma regular, uma vez que envolvem árvores.

O resultado final apresentou dois contornos de telhados de edifícios corretos dos cinco telhados presentes na cena (40%). Dos três polígonos presentes no resultado um não está correto, embora represente três telhados de edifícios, o que caracteriza a presença de um falso positivo (33,3%) e dos cinco telhados, três não foram extraídos, o que corresponde a 60% de falsos negativos. Esses valores apresentados refletem a dificuldade encontrada nesse experimento na etapa de segmentação do MDSn, conforme já discutido.

Na Figura 4.12 são apresentados os contornos de telhado (sobrepostos na imagem aérea) utilizados como referência para a comparação numérica dos resultados obtidos neste experimento.

Figura 4.12 – Contornos de referência utilizados na análise quantitativa dos resultados obtidos no experimento 2.



Os parâmetros de qualidade de completudeza e correção são apresentados pela Tabela 4.

Tabela 4.2 - Parâmetros de qualidade estimados na análise quantitativa dos contornos de telhado obtidos pelo método proposto para o experimento 2.

| Polígono | Completeza (%) | Correção (%) |
|-----------------|-----------------------|---------------------|
| C1 | 96,45 | 96,87 |
| C2 | - | - |
| C3 | 97,15 | 98,06 |
| Mínima | 96,45 | 96,87 |
| Máxima | 97,15 | 98,76 |
| Média | 96,8 | 97,46 |

A análise quantitativa apresentada na Tabela 4.2 mostra que as médias dos parâmetros de completudeza e correção foram de 96,8% e 97,46%, respectivamente, valores que confirmam a boa qualidade dos contornos de telhados de edifícios extraídos. Os

menores valores de completeza e correção foram obtidos pelo contorno C1, 96,45% e 96,87%, respectivamente. Os valores dos parâmetros de qualidade obtidos para esse experimento foram um pouco menores que os apresentados no experimento 1. Pode-se atribuir tal diferença à forte interação entre os telhados de edifícios e as árvores presentes na cena avaliada, que acabou por prejudicar o resultado final. Conforme já mencionado, o contorno C2 não está correto e, dessa forma, foi desconsiderado nessa etapa de análise quantitativa.

4.4.3 Experimento 3

Nesta seção são apresentados os resultados obtidos no terceiro experimento. Para a realização dos testes foi selecionada uma região da imagem aérea correspondente a um trecho de quadra urbana de uma área residencial (Figura 4.13), contendo cinco telhados de edifícios, dos quais três telhados de edifícios possuem anexos integrados.


Figura 4.13 – Imagem aérea da região do experimento 3.



A área selecionada para o experimento 3 (Figura 4.13) caracteriza o caso mais comum de ocorrência em áreas urbanas, onde a maioria dos telhados de edifícios é representada pela união de duas ou mais faces planas inclinadas e alguns deles apresentam forte interação com seus vizinhos principalmente devido à proximidade de seus telhados.

Na Figura 4.14 é apresentado o MDSn obtido para o experimento 3.

Figura 4.14 - MDSn obtido para o experimento 3.



Pode-se observar (Figura 4.14) que os edifícios presentes na região foram evidenciados, o que proporcionou boa diferenciação entre o terreno e o topo dos telhados de edifícios.

Foram obtidos a partir do método de segmentação do MDSn/LASER (Subseção 3.3.1 do Capítulo 3) oito polígonos (Figura 4.15), dos quais quatro são representativos dos telhados de edifícios e outros quatro envolvem vegetação alta. Nesse caso, nota-se uma falha na identificação da quantidade exata de telhados de edifícios presentes na cena, cinco telhados de edifícios. Essa falha é atribuída à inexistência de separação entre os dois telhados (Figura 4.15 – elipse em azul) nos dados VLA e a semelhança em altura dos dois telhados vizinhos, o que impossibilitou a obtenção de um polígono para cada um desses telhados.

Figura 4.15 – Polígonos extraídos dos dados VLA e projetados na imagem no experimento 3.



Podem ser observados, dessa forma, quatro polígonos envolventes de telhados de edifícios (Polígonos 1, 2, 3 e 4) e quatro de árvores (Polígonos 5, 6, 7 e 8).

Na Figura 4.16 pode ser observado o resultado obtido com a segmentação da imagem.


Figura 4.16 - Polígonos extraídos da Imagem para o experimento 3.



Na imagem (Figura 4.16), com a aplicação do método proposto para segmentação da imagem foram obtidos oito polígonos correspondentes aos oito polígonos extraídos dos dados VLA (Figura 4.15). Nota-se quatro dos cinco telhados de edifícios presentes na cena foram delimitados.

Para um melhor entendimento do funcionamento do processo de segmentação da imagem, a seguir são apresentados os resultados da segmentação em regiões para cada um dos recortes gerados a partir dos quatro polígonos LASER que compreendem os telhados presentes na cena (Figura 4.17).

Figura 4.17 – Segmentação em regiões dos recortes.
(a) Edifício 1; (b) edifício 2; (c) edifício 3; e (d) edifícios 4 e 5.



Os telhados de edifícios presentes no experimento 3 (Figura 4.16), de um modo geral, apresentam diferenças em iluminação e textura em suas estruturas. Pode ser visto na Figura 4.17 a aplicação do método de segmentação em regiões para os quatro casos. Nota-se, que as faces dos telhados que possuem maiores diferenças em textura apresentam regiões internas às grandes regiões que correspondem aos telhados de edifícios. Isso pode ser constatado pois apesar de existirem essas regiões internas, no momento da seleção pela

maior área somente conserva-se os correspondentes contornos dos telhados, o que permite então desconsiderar essas regiões menores. Além disso, na Figura 4.17 (a) pode ser observado que há junção de uma área anexa ao telhado de edifício principal (região na cor verde), devido a um detalhe no chão parecido em cor com a do telhado. Na Figura 4.17 (b) pode se verificar que devido à presença de sombra no telhado (região na cor vermelha) (Figura 4.15 - polígono 2) causada por outro telhado de edifício, a segmentação apresenta uma pequena falha. Na Figura 4.17 (c) verifica-se que o telhado de edifício (região na vermelha) foi bem delimitado. Por fim, na Figura 4.17 (d) pode-se verificar que os dois telhados de edifícios (regiões na cor verde) presentes foram segmentados, mas devido ao critério de conservar um único contorno por recorte um deles acaba por ser desconsiderado (Figura 4.15 - polígono 4).

De um modo geral, verifica-se que o método apresentou um bom resultado, uma vez que foi possível obter contornos de telhados de edifícios em regiões únicas (Figura 4.16) e, dessa forma, foi capaz de lidar com as diferenças em textura e iluminação presentes na estrutura do telhado. Nota-se que os contornos de telhados extraídos (Figura 4.16) delimitaram de forma adequada os limites dos telhados de edifícios. Deve-se ressaltar o benefício do uso do espaço de cor YUV, que foi capaz de contornar o problema relacionado às diferenças em iluminação presentes nas diferentes faces de uma mesma estrutura de telhado de edifício. Também, o uso do método *watershed* possibilitou a separação adequada dos objetos presentes na cena. Vale ressaltar que o método *watershed* trabalha com detecção de descontinuidades, o que favorece o emprego desse método na detecção de contornos de telhados de edifícios caracterizados como um tipo de descontinuidade.

Nota-se (Figura 4.16) que os contornos dos telhados de edifícios foram melhorados significativamente e se apresentam mais acurados em comparação com os extraídos do MDSn/LASER.

Na Figura 4.18 é apresentado o resultado do processo de otimização da função de energia pelo método AG, no qual foram conservados quatro polígonos.

Figura 4.18 - Resultado do processo de otimização da função de energia para o experimento 3.



Pela análise visual verifica-se que os quatro polígonos conservados são representativos de quatro telhados de edifícios presentes na cena. Os polígonos que envolvem os telhados de edifícios, tanto os extraídos dos dados VLA quanto os extraídos na imagem, apresentam-se aproximadamente regulares e seguem o padrão de agrupamento de telhados (paralelos ou perpendiculares entre eles). Os polígonos desconsiderados não apresentam formas regulares.

No resultado final são apresentados quatro contornos de telhados dos cinco presentes na cena, o que implica em 80% de acertos. Um dos telhados não foi extraído, o que acarreta na presença de um falso negativo (20%).

A inspeção visual dos resultados mostra uma boa correspondência entre os contornos extraídos C1 e C2 (Figura 4.18) e os reais presentes na imagem aérea. Nota-se com relação aos contornos C3 e C4 que devido aos diferentes materiais que constituem os telhados, não foi possível delimitar de forma totalmente correta os limites dos correspondentes telhados de edifícios.

A Figura 4.19 apresenta os contornos de telhado (sobrepostos na imagem aérea) utilizados como referência para a análise numérica dos resultados obtidos nesse experimento.

Figura 4.19 – Contornos de referência utilizados na análise quantitativa dos resultados obtidos no experimento 3.



Os parâmetros de qualidade de completude e correção são apresentados pela Tabela 4.3.

Tabela 4.3 - Parâmetros de qualidade estimados na análise quantitativa dos contornos de telhado obtidos pelo método proposto para o experimento 3.

| Polígono | Completude (%) | Correção (%) |
|-----------------|-----------------------|---------------------|
| C1 | 99,07 | 98,6 |
| C2 | 97,68 | 100 |
| C3 | 90,06 | 99,66 |
| C4 | 75,04 | 99,04 |
| Mínima | 75,04 | 98,6 |
| Máxima | 99,07 | 100 |
| Média | 90,46 | 99,32 |

A análise quantitativa apresentada na Tabela 4.3 mostra que as médias dos parâmetros de completude e correção são de 90,46% e 99,32%, respectivamente, valores que confirmam o bom desempenho do método de extração de contornos de telhados. O menor valor de completude foi obtido pelo contorno C3 (75,04%), devido à dificuldade de extração

de contornos em telhados compostos por diferentes materiais (Figura 4.18), e o menor valor de correção foi obtido pelo contorno C1 (98,6%), em decorrência da inclusão no contorno de uma pequena área correspondente ao chão (Figura 4.18).

4.4.4 Experimento 4

Esta seção descreve o quarto experimento realizado para avaliar o método desenvolvido. Para a realização deste experimento, foi selecionada uma área na imagem aérea que compreende alguns edifícios de uma quadra urbana (Figura 4.20).

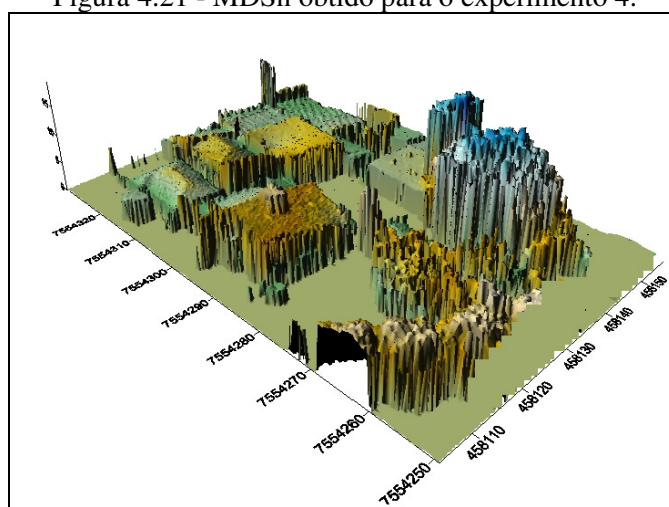
Figura 4.20 – Imagem aérea da região do experimento 4.



Na Figura 4.20 pode ser observado que a área selecionada para o experimento 4 contém sete edifícios regulares e uma edícula descritos por formas retilíneas.

Na Figura 4.21 pode ser observado o MDSn obtido para a região do experimento 4. Nota-se (Figura 4.21) que os edifícios presentes na cena foram bem destacados, o que acentuou a diferença em altura entre o terreno e topo da edificação.

Figura 4.21 - MDSn obtido para o experimento 4.



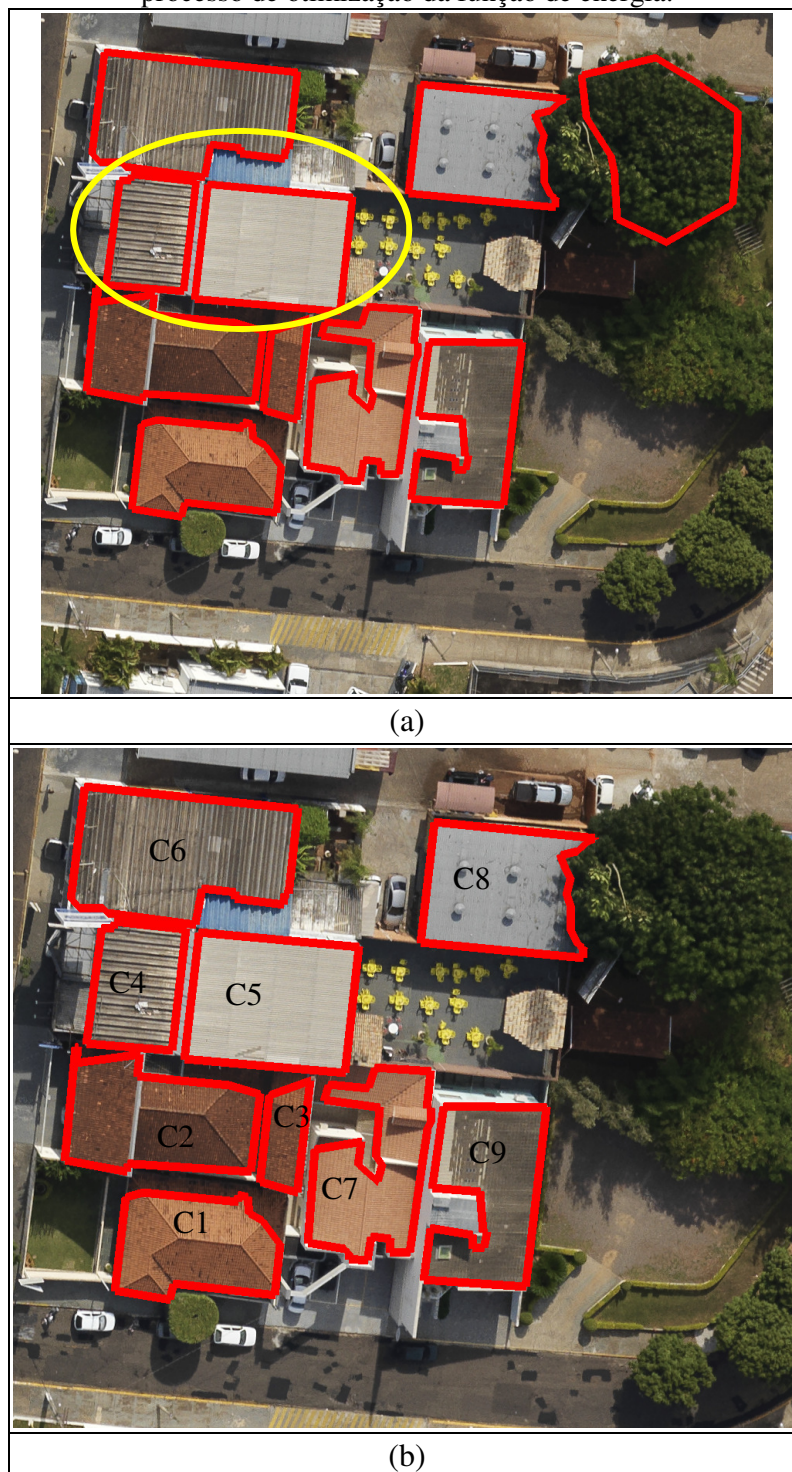
A Figura 4.22 apresenta os polígonos obtidos a partir da segmentação do MDSn/LASER (Subseção 3.3.1 do Capítulo 3), sobrepostos na imagem aérea. Foram extraídos dez polígonos dos dados VLA, dos quais nove são representativos de telhados de edifícios (Polígonos 1, 2, 3, 4, 5, 6, 7, 8 e 9) e um compreende (Polígono 10) vegetação alta. Os polígonos 4 e 5 representam um único telhado de edifício, uma vez que a mesma estrutura de telhado possui duas alturas distintas que acarretaram na segmentação do telhado em duas partes. No entanto, pode-se notar que os polígonos representativos de telhados apontam corretamente a localização dos telhados de edifícios. Verifica-se que foi obtido apenas um único polígono referente à vegetação, apesar de existirem mais áreas com árvores. Deve-se destacar que devido a grande fragmentação em segmentos nessas áreas, polígonos foram eliminados pelo critério de área mínima.

Figura 4.22 – Polígonos extraídos dos dados VLA e projetados na imagem no experimento 4.



Na Figura 4.23 (a) pode ser observado o resultado obtido com a segmentação da imagem e na Figura 4.23 (b) o resultado obtido com o processo de otimização da função de energia.

Figura 4.23 – Experimento 4. (a) Polígonos extraídos da Imagem; e (b) resultado do processo de otimização da função de energia.



Na imagem (Figura 4.23 (a)), com a aplicação do método proposto para a segmentação da imagem foram obtidos dez polígonos correspondentes aos dez polígonos extraídos dos dados VLA (Figura 4.19). Conforme já mencionado, nove desses polígonos são representativos de telhados de edifícios e entre esses polígonos um único telhado de edifício (Figura 4.20 (a) – elipse amarela). Verifica-se (Figura 4.23 (a)) que os contornos dos

Fernandes, V. J.M.

telhados de edifícios foram melhorados significativamente e se apresentam mais regulares em comparação com os extraídos do MDSn/LASER.

A Figura 4.23 (b) apresenta os nove polígonos mantidos pelo processo de otimização da função de energia. Pode-se observar que os polígonos conservados são representativos dos telhados de edifícios presentes na cena. A função de energia favoreceu os polígonos, tanto extraídos dos dados VLA quanto extraídos na imagem, que apresentam-se aproximadamente regulares e seguem o padrão de agrupamento de telhados (paralelos ou perpendiculares entre eles), dando mais peso para os polígonos extraídos da imagem. Vale lembrar que os polígonos que envolvem árvores dificilmente apresentam tais características e são descartados no processo de otimização. O resultado final não possui a presença de falsos positivos ou falsos negativos.

A análise visual dos resultados mostra que a extração dos contornos de telhado foi bem sucedida, uma vez que se observa boa correspondência entre os contornos extraídos e os reais presentes na imagem aérea. O método de segmentação de imagem empregado (Subseção 3.3.2 do Capítulo 3) proporcionou bons resultados, no entanto nota-se que esse método não foi capaz de segmentar corretamente regiões de sombras sobre as estruturas de telhados como os contornos C1, C2 e C3 (Figura 4.23 (b)), e também de lidar com diferença acentuada de textura e cor em um mesmo telhado (Figura 4.23 (b) – contornos C6 e C9).

A seguir, na Figura 4.24 são apresentados os contornos de telhado, sobrepostos na imagem aérea, utilizados como referência para a comparação quantitativa dos resultados obtidos nesse experimento.

Figura 4.24 – Contornos de referência utilizados na análise quantitativa dos resultados obtidos no experimento 4.



Os parâmetros de qualidade estimados nesta análise são apresentados pela Tabela 4.4. Estes valores se referem à completeza e correção.

Tabela 4.4 - Parâmetros de qualidade estimados na análise quantitativa dos contornos de telhado obtidos pelo método proposto para o experimento 4.

| Polígono | Completeza (%) | Correção (%) |
|-----------------|-----------------------|---------------------|
| C1 | 78,92 | 100 |
| C2 | 84,25 | 99,98 |
| C3 | 78,91 | 100 |
| C4 | 40,32 | 98,33 |
| C5 | 59,68 | 99,20 |
| C6 | 88,91 | 99,57 |
| C7 | 92,08 | 99,41 |
| C8 | 92,55 | 99,95 |
| C9 | 87,11 | 98,89 |
| Mínima | 40,32 | 98,33 |
| Máxima | 92,55 | 100 |
| Média | 78,08 | 99,48 |

A análise quantitativa apresentada na Tabela 4.4 mostra que as médias dos parâmetros de completeza e correção são de 78,08% e 99,48%, respectivamente, o que confirma um bom resultado do método de extração de contornos de telhados. Verifica-se, nesse experimento que os valores de completeza refletem a dificuldade do método de segmentação da imagem em lidar com sombras e diferenças acentuadas em cores. No entanto, nota-se que os contornos de telhados extraídos têm um alto nível de correção. Os menores valores de completeza correspondem aos contornos C4 e C5, uma vez que esses dois contornos correspondem a um único telhado de edifício.

4.4.5 Experimento 5

Esta seção descreve o quinto experimento realizado para avaliar o método desenvolvido. Para a realização deste experimento, foi selecionada uma área na imagem aérea que compreende edifícios de uma quadra urbana (Figura 4.25).

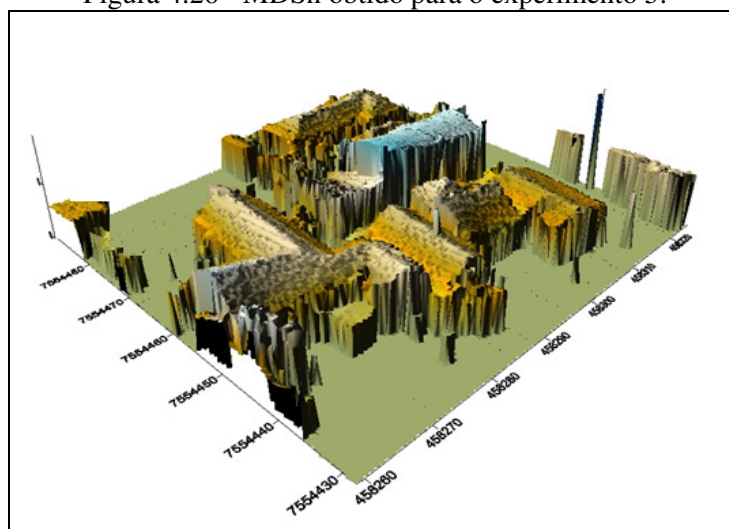
Figura 4.25 – Imagem aérea da região do experimento 5.



Na Figura 4.25 é apresentada a área selecionada para o experimento 5, que contém sete edifícios principais e duas edículas regulares descritos por formas retilíneas. Os telhados de edifícios estão relativamente próximos e existem algumas áreas com vegetação alta.

Na Figura 4.26 pode ser observado o MDSn obtido para a região do experimento 5. Nota-se (Figura 4.26) que os edifícios presentes na cena foram bem destacados, o que acentuou a diferença em altura entre o terreno e topo da edificação.

Figura 4.26 - MDSn obtido para o experimento 5.



A Figura 4.27 apresenta os polígonos obtidos a partir da segmentação do MDSn/LASER, sobrepostos na imagem aérea.

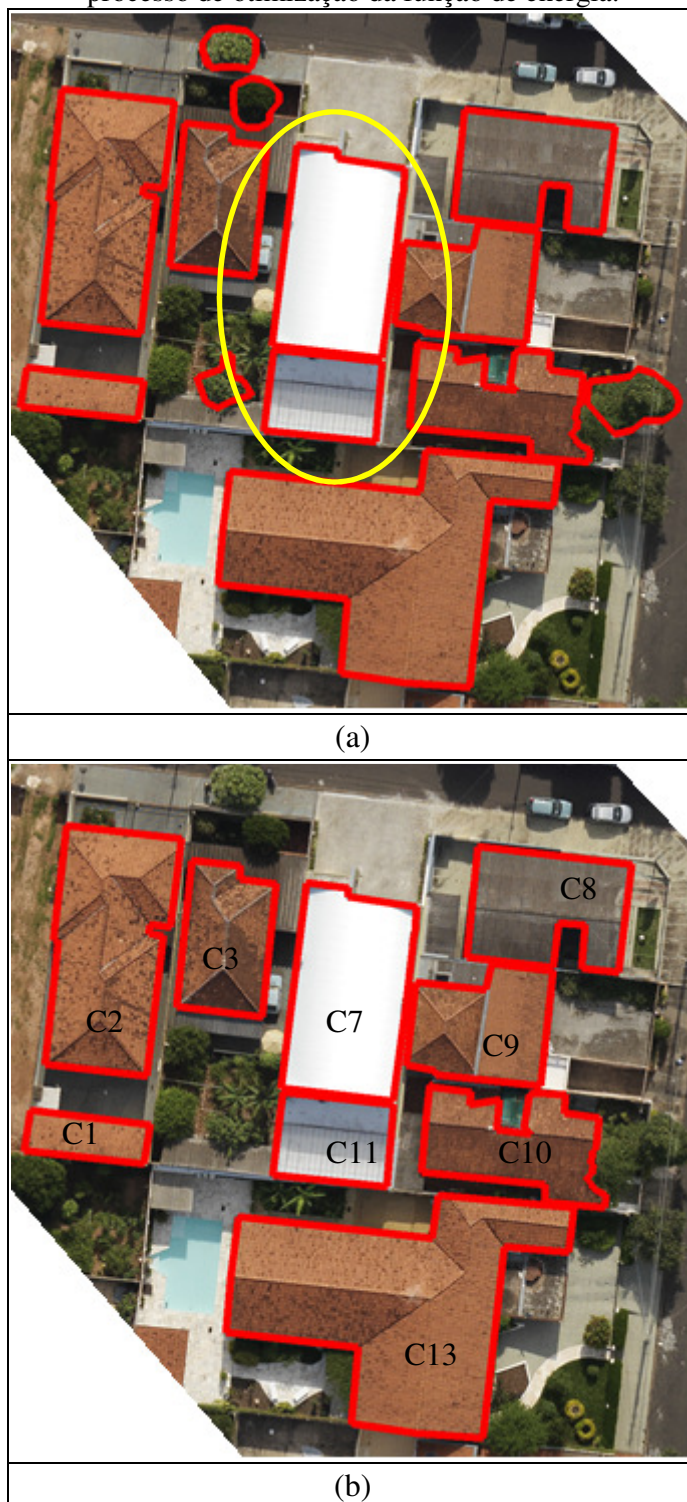
Figura 4.27 – Polígonos extraídos dos dados VLA e projetados na imagem no experimento 5.



Foram extraídos treze polígonos dos dados VLA, dos quais nove são representativos de telhados de edifícios (Polígonos 1, 2, 3, 7, 8, 9, 10, 11 e 13) e os demais compreendem vegetação alta. No entanto, deve-se notar que os polígonos 7 e 11 compreendem um único telhado de edifício, que foi segmentado em duas partes. Isso porque o telhado em questão possui duas alturas distintas em sua estrutura.

Na Figura 4.28 (a) pode ser observado o resultado obtido com a aplicação do método proposto para segmentação da imagem com restrição do espaço de busca (Subseção 3.3.2 do Capítulo 3), e na Figura 4.28 (b) é apresentado o resultado do processo de otimização da função de energia pelo método AG.

Figura 4.28 - Experimento 5. (a) Polígonos extraídos da Imagem; e (b) resultado do processo de otimização da função de energia.



A partir da segmentação da imagem foram extraídos treze polígonos correspondentes aos treze polígonos extraídos dos dados VLA (Figura 4.27), dos quais nove correspondem a contornos de telhados de edifícios. Conforme destacado na Figura 4.28 (a) (elipse amarela) dois dos polígonos que compreendem telhados de edifícios correspondem a

um único telhado. Pode-se verificar que (Figura 4.28 (a)) os polígonos extraídos da imagem definem melhor os limites dos telhados de edifícios em comparação com os extraídos do MDSn/LASER. A inspeção visual dos resultados mostra que a extração dos contornos de telhado foi novamente bem sucedida, uma vez que há correspondência adequada entre os contornos extraídos e os reais presentes na imagem aérea. Somente o contorno C10 que apresentou maiores irregularidades, uma vez que o telhado envolvido por esse contorno possui vegetação alta próxima que ocultou parte de seus limites e também por esse telhado conter diferentes materiais em sua composição (de diferentes cores), o que acaba por prejudicar a segmentação na imagem.

Na Figura 4.28 (b) é apresentado o resultado do processo de otimização da função de energia pelo método AG, no qual foram conservados nove polígonos. Pela análise visual verifica-se que os polígonos conservados são representativos dos telhados de edifícios presentes na cena. Os polígonos que envolvem cada um dos telhados de edifícios (Figura 4.27 e 4.28 (a)), principalmente os extraídos na imagem, apresentam forma aproximadamente retilínea (Termo 1 – Equação 3.5), seguem o padrão de agrupamento de telhados (paralelos ou perpendiculares entre eles) (Termo 2 – Equação 3.6) e apresentam orientação relativa similar (Termo 3 – Equação 3.7), o que não aconteceu com os polígonos desconsiderados que não apresentam tais características. O resultado final não apresentou falsos positivos ou falsos negativos, o que evidencia o bom funcionamento da função de energia proposta em conjunto com o método de otimização AG.

Na Figura 4.29 podem ser vistos os contornos de telhado (sobrepostos na imagem aérea) utilizados como referência para a análise quantitativa dos resultados.

Figura 4.29 – Contornos de referência utilizados na análise quantitativa dos resultados obtidos no experimento 5.



Os parâmetros de qualidade de completude e correção são apresentados pela Tabela 4.5.

Tabela 4.5 - Parâmetros de qualidade estimados na análise numérica dos contornos de telhado obtidos pelo método proposto para o experimento 5.

| Polígono | Completeza (%) | Correção (%) |
|-----------------|-----------------------|---------------------|
| C1 | 100 | 100 |
| C2 | 99,99 | 100 |
| C3 | 99,8 | 100 |
| C7 | 67,24 | 98,03 |
| C8 | 98,46 | 99,46 |
| C9 | 87,99 | 99,57 |
| C10 | 85,46 | 98,67 |
| C11 | 33,04 | 99,08 |
| C13 | 100 | 100 |
| Mínima | 33,04 | 98,03 |
| Máxima | 100 | 100 |
| Média | 85,77 | 99,42 |

Na Tabela 4.5 são apresentadas as médias dos parâmetros de completude e correção que foram de 85,77% e 99,42%, respectivamente. Esses valores mostram que os contornos

de telhados de edifícios foram extraídos de forma adequada. Os menores valores de completeza apresentados correspondem aos contornos de telhados C7 (67,24%) e C11 (33,04%), isso porque, conforme já mencionado esses dois contornos correspondem a um único telhado de edifício. O menor valor de correção apresentado corresponde ao contorno C10 (98,67%), o que evidencia que os contornos extraídos compreendem em maior parte somente as estruturas dos telhados.

4.4.6 Experimento 6

Essa seção apresenta o sexto experimento realizado para avaliar o método desenvolvido. Para a realização deste experimento, foi selecionada uma área na imagem aérea que compreende edifícios de uma quadra urbana (Figura 4.30).


Figura 4.30 – Imagem aérea da região do experimento 6.



Na Figura 4.30 pode ser observado que a área selecionada para o experimento 6 contém quinze edifícios principais e duas edículas regulares descritos por formas retilíneas. Alguns desses edifícios possuem anexos integrados. Pode-se observar que é uma quadra bastante densa de telhados e alguns deles apresentam forte interação com seus vizinhos principalmente devido à proximidade de seus telhados.

Na Figura 4.31 pode ser observado o MDSn obtido para a região do experimento 6. Nota-se (Figura 4.31) que os edifícios presentes na cena foram bem destacados, o que acentuou a diferença em altura entre o terreno e topo da edificação. Nota-se uma quantidade considerável de árvores.

Figura 4.31 - MDSn obtido para o experimento 6.



A Figura 4.32 apresenta os polígonos obtidos a partir da segmentação do MDSn/LASER e projetados na imagem aérea. Foram extraídos vinte e oito polígonos dos dados VLA, dos quais dezoito são representativos de telhados de edifícios (Polígonos 2, 3, 4, 5, 7, 8, 10, 11, 12, 13, 16, 17, 18, 19, 21, 22, 23 e 26). Apesar de apresentarem bastantes irregularidades, é possível localizar adequadamente os telhados de edifícios a partir desses polígonos.

Figura 4.32– Polígonos extraídos dos dados VLA e projetados na imagem no experimento 6.



Na Figura 4.33 (a) pode ser observado o resultado obtido com a aplicação do método proposto para segmentação da imagem. A partir da segmentação da imagem foram extraídos vinte e oito polígonos correspondentes aos vinte e oito polígonos extraídos dos dados VLA (Figura 4.32), dos quais dezoito correspondem a contornos de telhados de edifícios. Pode-se verificar que (Figura 4.33 (a)) os polígonos extraídos da imagem definem

Extração de contornos de telhados de edifícios a partir da integração de imagem aérea de alta-resolução e dados LASER, utilizando campos aleatórios de Markov

melhor os limites dos telhados de edifícios em comparação com os extraídos do MDSn/LASER. No entanto, existem algumas falhas na definição correta dos contornos dos telhados causadas por áreas ocultas por vegetação e pela presença de sombras. Observa-se uma correspondência adequada entre os contornos extraídos e os reais presentes na imagem aérea (Figura 4.33(a)).

Figura 4.33 – Experimento 6. (a) Polígonos extraídos da Imagem; e (b) resultado do processo de otimização da função de energia.



Na Figura 4.33 (b) pode ser visto o resultado do processo de otimização da função de energia pelo método AG. Foram conservados dezoito polígonos, os quais são representativos dos telhados de edifícios presentes na cena. Apesar dos contornos representativos de telhados de edifícios apresentarem algumas irregularidades, conforme já mencionado, as direções principais e secundárias obtidas, tanto para os polígonos extraídos dos dados VLA quanto para os extraídos na imagem, proporcionaram características de regularidade que foram suficientes para que no processo de otimização da função de energia o resultado correto fosse alcançado. Pode-se observar que os polígonos desconsiderados não apresentam forma regular. O resultado final não apresenta falsos positivos ou falsos negativos.

Na Figura 4.34 podem ser vistos os contornos de telhados utilizados como referência para a análise quantitativa dos resultados obtidos nesse experimento.

Figura 4.34 – Contornos de referência utilizados na análise quantitativa dos resultados obtidos no experimento 6.



Os parâmetros de qualidade de completudeza e correção são apresentados pela Tabela 4.6.

Tabela 4.6 - Parâmetros de qualidade estimados na análise quantitativa dos contornos de telhado obtidos pelo método proposto para o experimento 6.

| Polígono | Completeza (%) | Correção (%) |
|-----------------|-----------------------|---------------------|
| C2 | 94,86 | 99,59 |
| C3 | 85,79 | 99,32 |
| C4 | 96,93 | 98,83 |
| C5 | 66,04 | 100 |
| C7 | 98,21 | 99,18 |
| C8 | 94,20 | 98,99 |
| C10 | 97,84 | 100 |
| C11 | 43,14 | 97,82 |
| C12 | 97,50 | 99,8 |
| C13 | 99,71 | 100 |
| C16 | 90,89 | 100 |
| C17 | 98,31 | 99,57 |
| C18 | 99,08 | 100 |
| C19 | 94,56 | 99,62 |
| C21 | 55,78 | 98,71 |
| C22 | 77,05 | 98,56 |
| C23 | 97,65 | 100 |
| C26 | 100 | 100 |
| Mínima | 43,14 | 97,82 |
| Máxima | 100 | 100 |
| Média | 88,19 | 99,44 |

As médias dos parâmetros de completeza e correção (Tabela 4.6) foram de 88,19% e 99,44%, respectivamente, valores que confirmam a boa qualidade dos contornos de telhados de edifícios extraídos. Os menores valores de completeza e correção foram obtidos pelo contorno C11, 43,14% e 97,82%, respectivamente. Os menores valores de completeza (C5, C11, C21 e C22) são atribuídos à dificuldade do método de segmentação, em alguns casos, em definir corretamente os contornos dos telhados em regiões de sombras sobre as estruturas dos telhados.

4.4.7 Experimento 7

Essa seção descreve o último experimento realizado para avaliar o método desenvolvido. Para esse experimento, foi selecionada uma área maior na imagem aérea que compreende edifícios de uma quadra (Figura 4.35).

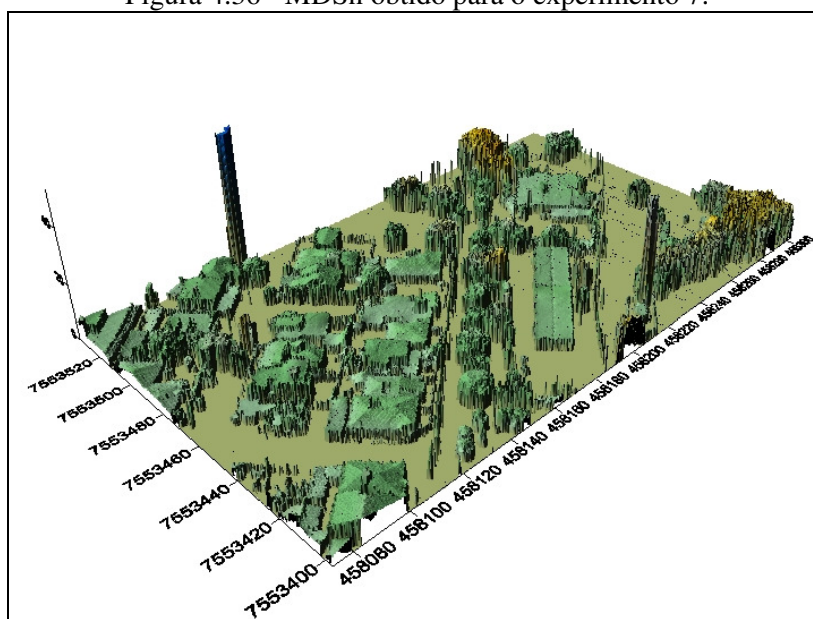
Figura 4.35 – Imagem aérea da região do experimento 7.



Na Figura 4.35 pode ser observada a área selecionada para o experimento 7. A cena contém treze edifícios principais e duas edículas regulares descritos por formas retilíneas e existem algumas áreas com vegetação alta.

Na Figura 4.36 pode ser observado o MDSn obtido para a área do experimento 7. Pode ser visto (Figura 4.36) uma boa diferenciação entre o terreno e o topo dos telhados de edifícios.

Figura 4.36 - MDSn obtido para o experimento 7.




Na Figura 4.37 são apresentados os polígonos obtidos a partir da segmentação do MDSn/LASER e que foram projetados na imagem aérea. Foram extraídos vinte e sete polígonos dos dados VLA. Nesse experimento, um fator que deve ser considerado é a incompatibilidade das datas entre a tomada da nuvem VLA (2013) e a imagem aérea (2011), uma vez que pode-se notar, a partir da sobreposição dos polígonos extraídos do MDSn/LASER na imagem e do MDSn (Figuras 4.36 e 4.37), que foram extraídos dezoito polígonos representativos de telhados de edifícios, dos quais dois telhados não aparecem na imagem aérea (Polígonos 8 e 12) e um está em fase de construção (Polígono 9). Nota-se que os telhados de edifícios foram bem localizados a partir dos dados VLA.

Figura 4.37 – Polígonos extraídos dos dados VLA e projetados na imagem no experimento 7.



Na Figura 4.38 (a) pode ser visto o resultado obtido com a segmentação da imagem. Foram extraídos vinte e sete polígonos correspondentes aos vinte e sete polígonos extraídos dos dados VLA e projetados na imagem (Figura 4.37), dos quais quinze desses polígonos são representativos de telhados de edifícios. Verifica-se que os contornos dos telhados de edifícios foram melhorados com relação aos obtido com os dados VLA e se apresentam mais acurados. Verifica-se que o método apresentou um bom resultado, uma vez que segmentou os telhados de edifícios em uma única região e, dessa forma, foi capaz de lidar com as diferenças em textura e iluminação presentes nas estruturas dos telhados.

Figura 4.38 – Experimento 7. (a) Polígonos extraídos da Imagem; e (b) resultado do processo de otimização da função de energia.



Na Figura 4.38 (b) observa-se o resultado do processo de otimização da função de energia pelo método AG, no qual foram conservados quinze polígonos. Por análise visual verifica-se que os polígonos conservados são representativos dos telhados de edifícios presentes na cena. Os polígonos que envolvem cada um dos telhados de edifícios (Figura

4.37 e 4.38 (a)), principalmente os polígonos extraídos na imagem, apresentam as características favorecidas pela função de energia proposta, que são: forma aproximadamente retilínea, seguem o padrão de agrupamento de telhados (paralelos ou perpendiculares entre eles) e apresentam orientação relativa similar, o que não aconteceu com os polígonos eliminados que não apresentam tais características. Nesse último caso, também encontram-se os polígonos que nos dados VLA representavam telhados de edifícios. No entanto, na imagem, devido às diferentes épocas de aquisição dos dados, esses edifícios não existiam. O resultado final mostrado na Figura 4.38 (b) não apresenta falsos positivos ou falsos negativos.

Nota-se que os contornos de telhados extraídos apresentam boa correspondência com os reais. Em alguns casos existem pequenos problemas de definição dos limites dos telhados de edifício (Figura 4.38 (b)), causadas por diferentes motivos como, partes do telhado ocultas por vegetação alta (caso do contorno C6), grande semelhança em cor entre o chão e o telhado (nos contornos C3 e C5) e presença de sombra (contorno C7). A análise quantitativa dos índices de completeza e correção foi realizada com base em contornos de telhados de referência, os quais são apresentados sobrepostos na imagem aérea na Figura 4.39.

Figura 4.39 – Contornos de referência utilizados na análise quantitativa dos resultados obtidos no experimento 7.



Os parâmetros de qualidade de completeza e correção são apresentados pela Tabela 4.7.

Tabela 4.7 - Parâmetros de qualidade estimados na análise quantitativa dos contornos de telhado obtidos pelo método proposto para o experimento 7.

| Polígono | Completeza (%) | Correção (%) |
|-----------------|-----------------------|---------------------|
| C1 | 99,97 | 100 |
| C2 | 99,14 | 100 |
| C3 | 98,16 | 83,13 |
| C4 | 100 | 100 |
| C5 | 98,5 | 90,27 |
| C6 | 97,20 | 98,48 |
| C7 | 86,04 | 100 |
| C10 | 99,19 | 97,3 |
| C11 | 100 | 100 |
| C15 | 100 | 98,99 |
| C16 | 98,69 | 98,67 |
| C17 | 99,33 | 98,33 |
| C18 | 99,46 | 99,25 |
| C20 | 100 | 100 |
| C21 | 97,98 | 100 |
| Mínima | 86,04 | 83,13 |
| Máxima | 100 | 100 |
| Média | 98,24 | 97,62 |

As médias dos parâmetros de completeza e correção (Tabela 4.7) foram de 98,24% e 97,62%, respectivamente, valores que confirmam a boa qualidade dos contornos de telhados de edifícios extraídos. O menor valor de completeza foi obtido pelo contorno C7 (86,04%) e o menor valor de correção pelo contorno C3 (83,13%).

5. CONCLUSÕES E RECOMENDAÇÕES FUTURAS

5.1 Conclusões

Nesse trabalho foi desenvolvido um método para a extração automática de contornos de telhados de edifícios com a integração de dados VLA e imagem aérea. Os polígonos extraídos dos dados VLA que representam objetos altos da cena, obtidos a partir da segmentação do MDSn, são projetados na imagem para restringir o espaço de busca e realizar a segmentação da imagem em regiões. Esse processo possibilita a extração de polígonos da imagem que representem objetos altos. O processo de identificação de contornos de telhados, em meio aos objetos altos detectados na imagem, na etapa anterior, é realizado através da otimização pelo método AG da função de energia estabelecida com base em MRF que modela propriedades específicas de contornos de telhados de edifícios.

Na avaliação experimental do método de extração desenvolvido foram descritos e analisados sete experimentos. Os detalhes referentes à análise dos resultados obtidos nesses experimentos são apresentados no Capítulo 4. Os experimentos 1 e 2 foram apresentados com o objetivo de avaliar o desempenho do método desenvolvido na tarefa de extração dos contornos de edifícios isolados na cena. Os demais experimentos tiveram por finalidade avaliar cenas mais complexas, nas quais os telhados de edifícios apresentavam-se mais próximos uns dos outros e a cada experimento havia o aumento da quantidade de objetos altos analisados na cena.

A avaliação do método proposto foi realizada a partir da análise visual dos resultados, através da sobreposição dos contornos extraídos sobre a imagem aérea; e a partir da análise quantitativa, através do cálculo dos parâmetros de completeza e correção. Pode-se concluir que os resultados obtidos foram satisfatórios, mostrando que o método proposto é capaz de extrair contornos de telhados de edifícios de forma eficiente.

A obtenção de polígonos representativos de objetos altos a partir do MDSn/LASER proporcionou boas aproximações de contornos de telhados de edifícios e possibilitou de forma eficiente a restrição do espaço de busca de objetos altos na imagem. Algo a ser considerado nessa etapa é a dificuldade de separar telhados bastante próximos (ou encostados) e de mesma altura. Quando acontece esse tipo de situação, a estratégia apresentada pelo método proposto para a segmentação do MDSn acaba por não apresentar

nenhum tipo de forma de diferenciação entre os dois telhados e proporciona um único polígono para dois telhados. Essa situação foi apresentada nos experimentos 2 e 3. Outra dificuldade é quando um mesmo telhado de edifício possui partes com diferenças grandes em alturas, o que acaba por segmentar o telhado em duas ou mais partes. Esse caso foi apresentado nos experimentos 4 e 5.

O método de segmentação de imagem empregado proporcionou bons resultados. Deve-se ressaltar o benefício do uso do espaço de cor YUV, que foi capaz de contornar o problema relacionado às diferenças em iluminação presentes em uma mesma estrutura de telhado de edifício. Também, o uso do método *watershed* possibilitou a separação adequada dos objetos presentes na cena. Vale ressaltar que o método *watershed* trabalha com detecção de descontinuidades, o que favorece o emprego desse método na detecção de contornos de telhados de edifícios caracterizados como um tipo de descontinuidade. No entanto a estratégia adotada para a segmentação de imagens ainda apresenta dificuldades em segmentar corretamente telhados de edifícios que apresentam sombras sobre as suas estruturas ou que apresentam cor semelhante ao calçamento próximo.

A função de energia estabelecida com base em MRF, contendo características de contornos de edifícios, associada ao método de otimização AG proporcionou resultados satisfatórios, uma vez que foi possível diferenciar corretamente os telhados de edifícios dos demais objetos altos presentes nas cenas. Foi possível observar que, na maioria dos casos, os polígonos que envolvem os telhados de edifícios, tanto os extraídos dos dados VLA quanto os extraídos na imagem, apresentam forma aproximadamente retilínea (Termo 1 – Equação 3.5), seguem o padrão de agrupamento de telhados (paralelos ou perpendiculares entre eles) (Termo 2 – Equação 3.6) e apresentam orientação relativa similar (Termo 3 – Equação 3.7), claro que a característica de retangularidade é mais acentuada nos polígonos extraídos na imagem.

Por fim, vale destacar que o método apresentado reflete bem a sinergia existente entre os dados VLA e fotogramétricos no contexto de extração de contornos de telhados de edifícios, uma vez que, o uso dos dados VLA possibilitou encontrar mais facilmente os objetos altos presentes na cena e a imagem proporcionou contornos com maior acurácia horizontal.

5.2 Recomendações para trabalhos futuros

Essa seção apresenta algumas recomendações para melhorar o desempenho do método proposto, bem como facilitar a tarefa de extração, citadas a seguir:

- Desenvolver uma estratégia para separar telhados bastante próximos (ou encostados) e de mesma altura no MDSn;
- Aplicar técnicas de pré-processamento na imagem para contornar problemas relacionados a sombras sobre as estruturas dos telhados de edifícios;
- Aplicar algoritmos de pós-processamento para a regularização geométrica e reconstrução das partes do contorno afetadas por obstrução, normalmente provocadas por vegetação.

Outra recomendação é a realização de experimentos utilizando ortoimagem verdadeira, o que possibilitaria expandir a aplicação do método em áreas que na imagem são afetadas por múltiplas oclusões. Por fim, recomenda-se realizar testes com dados VLA de diferentes densidades.

REFERÊNCIAS

AHOKAS, E.; KAARTINEN, H.; HYYPPÄ, J. A quality assessment of airborne LASER scanner data. In: Workshop 3-D Reconstruction from Airborne LASER scanner and InSAR Data 2003, Dresden. **Proceedings...** 2003

ANDERSEN, H.; REUTEBUCH, S.; SCHREUDER, G. Bayesian object recognition for the analysis of complex forest scenes. In: Symposium Photogrammetric Computer Vision, 2002, Austria. **Proceedings...** 2002.

AXELSSON, P. Processing of LASER scanner data - algorithms and applications. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, p. 138–147, 1999.

AWRANGJEB, M.; ZHANG, C. FRASER, C. S. Automatic extraction of building roofs using LIDAR data and multispectral imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 83, p. 1–18, 2013.

AWRANGJEB, M.; ZHANG, C. FRASER, C. S. Automatic reconstruction of building roofs through effective integration of lidar and multispectral imagery. In: XXII ISPRS Congress, 2012, Melbourne. **ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. I-3, Melbourne, 2012.

BALLARD, H.; BROWN, C. M. **Computer Vision**. Englewood Cliffs, NJ: Prentice-Hall, 1982, 523p.

BALTSAVIAS, E. P. Airborne LASER Scanning: basic relation and formulas. **ISPRS Journal of Photogrammetry & Remote Sensing**, Zurich, v. 54, p.199–214, 1999.

BEUCHER, S., MEYER, F. The morphological approach to segmentation: The watershed transformation. In: Mathematical Morphology in Image Processing. New York, 1993. **Proceedings...**, 1993.

BETTINI, C. Conceitos básicos de geoestatística. In.: **Geomática: Modelos e Aplicações Ambientais**. Brasília, DF: Embrapa Informação tecnológica, 2007. p. 192-234.

BONSKPEN, L., COY, W. Stable segmentation using color information. In: *4th Int. Conference on Computer Analysis of Images and Patterns, 1991*, Drctsdn, Germany. **Proceedings...**, Drctsdn, Germany, 1991.

BOTELHO, M. F. **Modelagem tridimensional de edificações usando dados do sistema LASER scanner e imagem orbital de alta.** Tese de Doutorado. Programa de Pós-Graduação em Ciências Geodésicas - Universidade Federal do Paraná, Curitiba - Paraná, 2007.

BOTELHO, F. M.; CENTENO, J. A. S. Reconstrução tridimensional de edificações utilizando dados LASER scanner aerotransportados. **Boletim de Ciências Geodésicas**, v. 13, n. 1, 2007, p. 107-126.

BRANDALIZE, A. A. Varredura a LASER: Comparação com métodos fotogramétricos. In: I Simpósio Brasileiro de Geomática, 2002, Presidente Prudente. **Anais...** 2002.

BROVELLI, M.A., Cannata, M., Longoni, U.M. Managing and processing LIDAR data within GRASS. In: **GRASS Users Conference**, Trento, Italy, 2002.

BROWN, D. G. An Advanced Plate Reduction for Photogrammetric Cameras. Report, Air Force Cambridge Research Laboratories, 1964.

CAMARGO, E. C. G.; FUCKS, S. D.; CÂMARA, G. **Análise espacial de superfícies.** Brasília: Embrapa, 2004.

CENTENO, J.A.S.; MITISHITA, E.A. **LASER scanner aerotransportado no estudo de áreas urbanas: A experiência da UFPR**, In: Anais XIII Simpósio Brasileiro de Sensoriamento Remoto, 2007, Florianópolis, INPE, p. 3645-3652. Disponível em: <<http://marte.dpi.inpe.br/col/dpi.inpe.br/sbsr@80/2006/11.15.00.45/doc/3645-3652.pdf>>. Acessado em: 10 agosto de 2010.

CHEN, L.; ZHAO, S., HAN, W.; LI, H. Building detection in an urban area using lidar data and QuickBird imagery. **International Journal of Remote Sensing**, v.33, p. 5135-5148, 2012.

CHEN, J.; DOWMAN I.; LI, S.; LI Z.; MADDEN M.; MILLS J.; PAPANODITS N.; ROTTENSTEINER F.; SENTER M.; TOTH C.; TRINDER J.; HEIPKE C. Information from imagery: ISPRS scientific vision and research agenda. **International Society for Photogrammetry and Remote Sensing**, v. 115, p. 3-21, 2016.

CHENG, L.; GONG, J.; CHEN, X.; HAN, P. Building boundary extraction from high resolution imagery and LIDAR data. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 37, p. 693-698, 2008.

CONRADY, A. E. Decentered Lens System. **Monthly Notices of the Royal Astronomical Society**, v. 79, p. 384-90, 1919.

COTE, M., SAEEDI, P. Automatic rooftop extraction in nadir aerial imagery of suburban regions using corners and variational level set evolution. **IEEE Transactions Geoscience and Remote Sensing**, v. PP, p. 1-16, 2012.

DAL POZ, A. P. Modelos e estratégias para a extração da malha viária em imagens digitais. Relatório FAPESP, Universidade Estadual Paulista (UNESP), 2002.

DAL POZ, A. P.; FAZAN, A. J.; CORREIA, L. S.; MARCATO, V. J. Automated building extraction: comparison of paradigms and examples. In: 6th International Symposium on Mobile Mapping Technology, 2009, Presidente Prudente. **Proceedings of 6th ISMMT**, 2009a.

DAL POZ, A. P.; HABIB, A. F.; MARCATO, V. J.; CORREIA, L. S. Uso de dados fotogramétricos no refinamento geométrico de contornos de telhados de edifícios extraídos de dados LASER. **Boletim de Ciências Geodésicas**, v.15, n. 4, p. 594 – 614, 2009b.

DALMOLIN, Q.; SANTOS, D. R. **Sistema LASER SCANNING: Conceitos e princípios de funcionamento**. UFPR, Curitiba. 2004.

DEVI, M., MANDOWARA, S. Extended Performance Comparison of Pixel Window Size for Colorization of Grayscale Images using YUV Color Space. In: Nirma University International Conference on Engineering (NUiCONE), 2012, Gujarat, India. **Proceedings**...IEEE Publisher, 2012, p. 1-5. On-line. ISBN 978-1-4673-1720-7. Disponível em:< <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=6493197>>. Acesso em: 23 out. 2014.

ELBERINK, S. O.; MASS, H. G. The use of anisotropic height texture for the segmentation of airborne LASER scanner data. In: International Archives of Photogrammetry and Remote Sensing, v. 33, Part B3, Commission III, Amsterdam, pp. 616-623, 2000.

ELMQVIST, M. Ground estimation of lasar radar data using active shape models. **In: OEEPE Workshop on Airborne LASERscanning and Interferometric SAR for Detailed Digital Elevation Models**, 2001, CD-ROM.

EL-SHEIMY, N. **Digital terrain modelling**. Calgary, 1999.

EL-SHEIMY, N.; VALEO, C.; HABIB, A.; **Digital terrain modeling: Acquisition, manipulation and applications**. Calgary, 2005.

FALCÃO, A. X.; LOTUFO, R. A.; ARAUJO, G. The Image Foresting Transformation. **Technical Report IC-00-12**, Institute of Computing – State University of Campinas, 2000.

FAZAN, A. J.; DAL POZ, A. P. Rectilinear building roof contour extraction based on snakes and dynamic programming. **International Journal of Applied Earth Observation and Geoinformation**, v. 25, p. 1- 10, 2013.

FERNANDES, V. J. M.; DAL POZ, A. P. A Markov-Random-Field Approach for Extracting Straight-Line Segments of Roofs From High-Resolution Aerial Images. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v.PP, p.1 - 13, 2016.

FUA, P.; HANSON, A. J. **Resegmentation using generic shape: Locating general cultural objects**. Pattern Recognition Letters, v. 5, p. 243-252, 1987.

GALVANIN, E. A. S. **Extração automática de contornos de telhados de edifícios em um modelo digital de elevação, utilizando inferência Bayesiana e campos aleatórios de Markov**. Presidente Prudente, 2007. Dissertação (doutorado) – Curso de Pós-Graduação em Ciências Cartográficas, FCT/UNESP.

GALVANIN, E. A. S.; DAL POZ, A. P. Extraction of building roof counters from Lidar using a Markov-Random-Field-Based approach. **IEEE Transactions Geoscience and Remote Sensing**, v.50, p. 981-987, 2012.

GEMAN, S.; GEMAN, D. Stochastic relaxation, Gibbs distribution, and Bayesian restoration of images. In: IEEE Transactions on Pattern Analysis and Machine, v.6, 1984. **Proceedings...** 1984, p.721-741.

GEUSEBROEK, J. M., VAN DEN BOOMGAARD, R., SMEULDERS, A. W. M., GEERTS, H. Color Invariance. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 23, p. 1338 – 1350, 2001.

GOLDEBERG, D. E. **Genetic Algorithms in search, optimization, and machine learning**. Alabama: Addison-Wesley publishing company, 412p. 1989.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. 3. ed. São Paulo: Edgard Blücher, 2000. 509p.

GONZALEZ, R.C.; WOODS, R.E. **Digital Image Processing**. 2^o.ed. New Jersey: Edition. Prentice-Hall, 2002. 793p.

GONZALEZ, Rafael C.; WOODS, Richard C. **Processamento Digital de Imagens**. 3.ed; São Paulo: Pearson Prentice Hall, 2010.

GORDON, S.; LICHTI, D.; STEWART, M. Application of a high-resolution, ground-based LASER scanner for deformation measurements. In: 10th FIG International Symposium on Deformation Measurements, California, USA, 2001. **Proceedings...** 2001, p. 23-32.

HAALA, N.; BRENNER, C. Extraction of buildings and trees in urban environments. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.54, p. 130-137, 1999.

HABIB, A.; GHANMA, M.; MITISHITA, E. A. Co-registration of photogrammetric and LIDAR data: Methodology and case study. **Revista Brasileira de Cartografia**, v. 56, n. 1, p. 1-13, 2004.

HUMMEL, R. A.; ZUCKER, S. W. On the foundation of relaxation labeling process. In: IEEE Transactions on Pattern Analysis and Machine Intelligence, v. PAMI-5, 1983. **Proceedings...** 1983, p.267-287.

JAIN, R.; KASTURI, R; SCHUNCK, B. G. **Machine vision**. MIT Press and McGraw-Hill, Inc New York, 1995.

KABOLIZADE, M., EBADI, H., AHMADI, S. An improved snake model for automatic extraction of buildings from urban aerial images and LiDAR data. **Computers, Environment and Urban Systems**, v. 34, p. 435-441, 2010.

KATARTZIS, A.; SAHLI, H. A Stochastic Framework for the Identification of Building Rooftops using a single Remote Sensing Image. **IEEE Transactions Geoscience and Remote Sensing**, v. 46, p. 259-271, 2008.

KAARTINEN et al. Accuracy of 3D city models: EUROSDR comparison. In: ISPRS Workshop "LASER scanning 2005", **Proceedings...** Enschede, CDROM, 2005.

KIM, I. Y.; YANG, H. S. An integrated approach for scene understanding based on Markov Random Field. **Pattern Recognition**, p. 1887-1897, 1995.

Extração de contornos de telhados de edifícios a partir da integração de imagem aérea de alta-resolução e dados LASER, utilizando campos aleatórios de Markov

KINDERMAN, R.; SNELL, J. L. **Markov Random Fields and their applications**. Providence, R.I: American Mathematical Society, 1980.

KOSCHAN, A., ABIDI, M. Digital color image processing. Canada: Wiley-Interscience, 2008.

KOPPARAPU, S. K.; DESAI, U. B. **Bayesian approach to image interpretation**. New York: Kluwer Academic Publishers, 127p., 2001.

KRAUS, K., PFEIFFER, N. Determination of terrain models in wooded areas with airborne LASER scanner data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, p. 193-203, 1998.

KRAUS, K.; WALDHAUSL, P. Photogrammetry: Fundamentals and Standard Processes. Institute for Photogrammetry Vienna University of Technology. Vienna, 1992.

KRISHNAMACHARI, S.; CHELLAPPA, R. Delineating buildings by grouping lines with MRFs. In: IEEE TRANSACTION ON IMAGE PROCESSING. v. 5, 1996. **Proceedings...**1996, p.164-168.

LAFARGE, F.; DESCOMBES, X.; ZERUBIA, J.; PIERROT-DESEILLIGNY, M. **Automatic building extraction from DEMs using an object approach and application to the 3D-city modeling**. ISPRS Journal of Photogrammetry and Remote Sensing, v. 63, 2008, p. 365-381.

LANDIM, P. M. B.; STURARO, J. R.; MONTEIRO, R. C. **Krigagem ordinária para situações com tendência regionalizada**. Rio Claro: DGA, IGCE, UNESP, 2002.

LI, Y., WU, H., AN, R., XU, H., HE, Q., XU, J. An improved building boundary extraction algorithm based on fusion of optical imagery and LIDAR data. **Optik**, v. 124, p. 5357-5362, 2013.

LUGNANI, J. B. **Introdução à fototriangulação**. Universidade Federal do Paraná, Curitiba, 1987.

MACHADO, A. M. L.; MITISHITA, E. A. Detecção automática de contornos de edificações utilizando imagem gerada por câmara digital de pequeno formato e dados lidar. **Boletim de Ciências Geodésicas**, v. 12, n. 2, p. 215-233, 2006.

Extração de contornos de telhados de edifícios a partir da integração de imagem aérea de alta-resolução e dados LASER, utilizando campos aleatórios de Markov

MARCATO, V. J., DAL POZ, A. P. Refinamento geométrico de contornos e cumeeiras de telhados de edifícios extraídos de dados LASER com uso de imagem aérea. **Boletim de Ciências Geodésicas**, v. 20, n°3, p.647-668, 2014.

MAYER, H. Automatic Object Extraction from Aerial Imagery - A Survey Focusing on Buildings. **Computer Vision and Image Understanding**, v. 74, n. 2, p. 139-149, 1999.

MEYER, F. Topographic distance and watershed lines. **Signal Processing**, v. 38, p. 113-125, 1994.

MEYER, F.; BEUCHER, S. Morphological segmentation. **Journal of Visual Communications and Image Processing**, v. 1, p. 21-46, 1990.

MIKHAIL, E; BETHEL, J. S.; MCGLONE, J. C. **Introduction to Modern Photogrammetry**. Chichester: John Wiley & Sons, 2001.

MITCHELL, M. **An Introduction to Genetic Algorithms**. Massachusetts: The MIT Press, 1999.

MITISHITA, E. A. **Monorestituição digital de aerofotos, associada com sistema de computação gráfica C.A.D., para fins de mapeamento na área florestal**. 1997. 253 f. Tese (Doutorado em Ciências Florestais) – Universidade Federal do Paraná, Curitiba.

MODESTINO, J. A; ZHANG, J. A Markov Random Field model based approach to image interpretation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 6, p. 606 - 615, 1992.

MÜLLER, S.; ZAUM, D. W. *Robust building detection in aerial images*. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 36, p. 143-148, 2005.

MULAWA, D. C.; MIKHAIL, E. M. Photogrammetric treatment of linear features. In: **International Archives for Photogrammetry and Remote Sensing**, Kyoto, Japão, 1988.

PACHECO, M. A. C. **Algoritmos Genéticos: Princípios e Aplicações**. Disponível em: <<http://www.ica.ele.puc-rio.br>>. Acesso em: 25 de março de 2012.

Extração de contornos de telhados de edifícios a partir da integração de imagem aérea de alta-resolução e dados LASER, utilizando campos aleatórios de Markov

PFEIFER, N., KOSTLI, A., KRAUS, K. Interpolation and filtering of LASER scanner data - implementation and first results. In: XXXII International Archives of Photogrammetry and Remote Sensing, **Proceedings**... p. 153–159, 1998.

ROERDINK, J. B.; MEIJSTER, A. The watershed transform: Definitions, algorithms and parallelizations strategies. **Fundamentae Informaticae**, v. 41, p. 187-228, 2000.

ROGGERO, M. Airborne LASER scanning: clustering in raw data. In: International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XXXIV (Pt. 3/W4), 227– 232, 2001.

ROSENFELD, A.; HUMMEL, R. A.; ZUCKER, S. W. Scene labeling by relaxation operations. **IEEE Trans. Syst. Man Cybern.** v. SMC-6, p.420-433, 1976.

ROTTENSTEINER, F.; TRINDER, J.; CLODE, S.; KUBIK, K. Automated delineation of roof planes from LIDAR data. In: **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 35, 2005.

SHAFARENKO, L., PETROU, M., KITTLER, J. Histogram-Based Segmentation in a Perceptually Uniform Color Space. **IEEE Transactions on Image Processing**, v. 7, n° 9, 1998.

SHUFELT, J. A. **Geometric constraints on hypothesis generation for monocular building extraction**. In: SPIE – Conference Integrating Photogrammetric Techniques with Scene Analysis and Machine Vision III, Orlando, USA, v. 3072, 1987.

SITHOLE, G. Filtering of LASER altimetry data using a slope adaptive filter. In: XXXIV International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, **Proceedings**... p. 203– 210, 2001.

SITHOLE, G.; VOSSelman, G. **Experimental comparison of filter algorithms for bare-Earth extraction from airborne LASER scanning point clouds**. In: ISPRS Journal of Photogrammetry and Remote Sensing, v. 59, p. 85-101, 2004.

SIRMAÇEK, B.; ÜNSALAN C. A. Probabilistic Framework to Detect Buildings in Aerial and Satellite Images. **IEEE Transaction on Geosciences and Remote Sensing**, vol.49, n.1, pp. 211-221, 2011.

Extração de contornos de telhados de edifícios a partir da integração de imagem aérea de alta-resolução e dados LASER, utilizando campos aleatórios de Markov

SOARES, G. L. **Algoritmos Genéticos: estudo, novas técnicas e aplicações**. Belo Horizonte, 1997. Tese (Doutorado) – Curso de Pós- Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais.

SOHN, G. Extraction of buildings from high-resolution satellite data and lidar. In: XX ISPRS CONGRESS, Istanbul, Turkey, 2004. **Proceedings...** 2004, 7p.

SOHN, G., DOWMAN, I. Terrain surface reconstruction by the use of tetrahedron model with the MDL Criterion. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XXXIV (Pt. 3A), 336– 344, 2002.

SOUZA, F. C. B. **Orientação absoluta de modelos utilizando feições digitalizadas como controle**. Curitiba, 1982. Dissertação (Mestrado) - Curso de Pós-Graduação em Ciências Geodésicas, Universidade Federal do Paraná.

SÜLI, E.; MAYERS, D. **An Introduction to Numerical Analysis**, Cambridge University Press, 2003.

SZIRÁNYI, T.; ZERUBIA, J.; CZÚNI, L.; GELDREICH, D.; KATO, Z. Image segmentation using Markov Random Field model in fully parallel cellular network architectures. **Real-Time Imaging**. v.6, p. 195-211, 2000.

TOMMASELLI, A. M. G. **Análise de Imagens – Conceitos básicos**. Presidente Prudente, 2004. Notas de aulas do Curso de Graduação em Engenharia Cartográfica - FCT/UNESP.

TOMMASELLI, A. M. G.; TOZZI, C. L. A Recursive Approach to Space Resection Using Straight Lines. **Photogrammetric Engineering and Remote Sensing**, v. 62, p. 57-56, 1996.

SOILLE, P.; VINCENT, L. Watersheds in digital spaces: An efficient algorithm based on immersion simulations. In: IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE. v. 13, n. 6. **Proceedings...** 1991. p.583-597.

VOSELMAN, G. **Building reconstruction using planar faces in very high density height data**. In: The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, v.37, pp. 87-92, 1999.

VOSELMAN, G. Fusion of LASER Scanning Data, Maps, and Aerial Photographs for Building Reconstruction. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, Toronto, Canada. **Proceedings...** 2002.

Extração de contornos de telhados de edifícios a partir da integração de imagem aérea de alta-resolução e dados LASER, utilizando campos aleatórios de Markov

YAMAMOTO, J. K.; LANDIM, P. M. B. **Geostatística: conceitos e aplicações**. Editora: Oficina de Textos, p. 216, 2013.

ZAREA A.; MOHAMMADZADEH A.. A Novel Building and Tree Detection Method From LiDAR Data and Aerial Images. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, vol. 9, n. 5, 2016.

ZHOU G.; ZHOU X.. Seamless Fusion of LiDAR and Aerial Imagery for Building Extraction. **IEEE Transactions on Geoscience and Remote Sensing**, vol. 52, n. 11, 2014.

WACK, R., WIMMER, A. Digital terrain models from airborne LASER scanner data—a grid based approach. In: **XXXIV International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, p. 293–296, 2002.

WOLF, P. R.; DEWITT, B. A. **Elements of Photogrammetry: with applications in GIS**. Boston: McGraw-Hill, 608p. 2000.