

UNIVERSIDADE ESTADUAL PAULISTA

CAMPUS DE PRESIDENTE PRUDENTE

FACULDADE DE CIÊNCIAS E TECNOLOGIA

Programa de Pós-Graduação em Ciências Cartográficas

VANESSA JORDÃO MARCATO

**RECONSTRUÇÃO DE CONTORNOS E CUMEEIRAS DE TELHADOS DE
EDIFÍCIOS A PARTIR DE IMAGENS AÉREAS DE ALTA-RESOLUÇÃO E
POLIEDROS REPRESENTATIVOS DE EDIFÍCIOS EXTRAÍDOS DE DADOS
LASER**



PRESIDENTE PRUDENTE

2013

UNIVERSIDADE ESTADUAL PAULISTA

CAMPUS DE PRESIDENTE PRUDENTE

FACULDADE DE CIÊNCIAS E TECNOLOGIA

Programa de Pós-Graduação em Ciências Cartográficas

VANESSA JORDÃO MARCATO

**RECONSTRUÇÃO DE CONTORNOS E CUMEEIRAS DE TELHADOS DE
EDIFÍCIOS A PARTIR DE IMAGENS AÉREAS DE ALTA-RESOLUÇÃO E
POLIEDROS REPRESENTATIVOS DE EDIFÍCIOS EXTRAÍDOS DE DADOS
LASER**



Dissertação de mestrado 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

2013

FICHA CATALOGRÁFICA

M262r Marcato, Vanessa Jordão.
Reconstrução de contornos e cumeeiras de telhados de edifícios a partir de imagens aéreas de alta-resolução e poliedros representativos de edifícios extraídos de dados LASER / Vanessa Jordão Marcato. - Presidente Prudente : [s.n], 2013
126 f.


Orientador: Aluir Porfirio Dal Poz
Dissertação (mestrado) - Universidade Estadual Paulista, Faculdade de Ciências e Tecnologia
Inclui bibliografia

1. Fotogrametria. 2. Extração de telhados. 3. Dados LASER. I. Dal Poz, Aluir Porfirio. II. Universidade Estadual Paulista. Faculdade de Ciências e Tecnologia. III. Título.

BANCA EXAMINADORA



PROF. DR. ALUIR PORFIRIO DAL POZ
ORIENTADOR



PROF. DR. MAURICIO GALO
UNESP/FCT




PROF. DR. FERNANDO MARQUES DE ALMEIDA NOGUEIRA
UFPR



VANESSA JORDÃO MARCATO

Presidente Prudente (SP), 25 de fevereiro de 2013.

RESULTADO: 

DEDICATÓRIA

A Deus.

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

Ao meu amado irmão, pela ajuda e incentivo.

Aos meus tios Pedro e Maria, pelo apoio e incentivo.

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

AGRADECIMENTOS

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

Aos professores do Departamento de Cartografia da FCT/UNESP, pelo ensino e formação acadêmica.

À banca de qualificação desse trabalho, composta pelos professores Antonio Maria Garcia Tommaselli e Mauricio Galo, pelas contribuições dadas.

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

Ao instituto LACTEC pelo fornecimento dos dados de varredura a laser.

Ao Prof. Edson A. Mitishita por disponibilizar a imagem aérea utilizada nesse trabalho.

Ao Prof. Ayman Habib por ceder um dos poliedros 3D utilizado nesse trabalho.

À UNESP, por proporcionar todos os meios para o desenvolvimento desse trabalho.

À FAPESP e à CAPES, pelo financiamento prestado a essa pesquisa.

EPÍGRAFE

*“Por vezes sentimos que aquilo que fazemos
não é senão uma gota de água no mar. Mas o
mar seria menor se lhe faltasse uma gota.”*

Madre Teresa de Calcutá

RESUMO

Esse trabalho propõe melhorias em uma metodologia preexistente para o refinamento geométrico de contornos de telhados extraídos de dados LASER, usando imagens aéreas de alta resolução e campos aleatórios de Markov (MRF - Markov Random Field). A metodologia original assume que a descrição 3D de cada telhado de edifício reconstruído de dados de varredura a LASER está topologicamente correta e que é necessário apenas melhorar sua acurácia. Uma vez que as cumeeiras de telhado são acuradamente extraídas de dados de varredura a LASER, o objetivo básico é usar imagens aéreas de alta resolução para melhorar somente a qualidade geométrica dos contornos de telhado. Para tanto, essa metodologia utiliza retas extraídas da imagem e as projeções dos contornos de telhados extraídos dos dados LASER para estabelecer uma descrição MRF com base em relações de comprimento, proximidade e orientação entre ambos os conjuntos de retas. A função de energia associada com a descrição MRF é minimizada através de uma versão modificada do algoritmo de força bruta, resultando em um agrupamento de retas para cada contorno de telhado. Uma das melhorias propostas nesse trabalho consiste em incluir na função de energia associada ao MRF uma restrição denominada junção de quina. Esta restrição leva em conta que a intersecção de duas retas adjacentes, correspondentes a lados de contorno, deve estar próxima de uma quina em 90° . As quinas são extraídas na imagem através de um algoritmo apropriado de processamento de imagem. Outra melhoria na função de energia baseia-se no fato de que as retas representativas de contornos de telhados são aproximadamente paralelas ou ortogonais entre si. Esta restrição foi denominada junção de retangularidade. Outra modificação na metodologia original refere-se ao algoritmo de otimização da função de energia. Na metodologia original foi utilizado o algoritmo de otimização de força bruta, associado com algumas heurísticas. Embora este método permita obter a solução ótima, caso exista, o espaço de busca fica intratável computacionalmente quando algumas dezenas de retas estão presentes no espaço de busca. Propõe-se usar o algoritmo genético para contornar este problema. Este algoritmo deverá possibilitar a solução do problema de otimização em situações inviáveis para a metodologia original. Também é proposta a inclusão da estrutura de cumeeira, viabilizada pela modificação do algoritmo de otimização. Embora a combinação de dados LASER com dados de imagem aérea de alta resolução é justificada mais para o refinamento de contorno de telhado, a estrutura de cumeeiras pode dar maior robustez na descrição topológica da estrutura de telhado, composta de segmentos de retas de contornos e cumeeiras. Os resultados obtidos na avaliação experimental mostraram que a metodologia funciona adequadamente na tarefa de refinar e reconstruir os telhados de edifício. As modificações realizadas no método contribuíram positivamente para suprir deficiências apresentadas pela metodologia original.

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

ABSTRACT

This paper proposes improvements in a previous methodology for the geometric refinement of building roof contours extracted from LASER data using high-resolution aerial images and Markov Random Field (MRF) models. The original methodology takes for granted that the 3D description of each building roof reconstructed from the laser scanning data is topologically correct and that it is only necessary to improve its accuracy. Since roof ridges are accurately extracted from laser scanning data, our main objective is to use high-resolution aerial images to improve the accuracy of roof outlines. For this, this methodology uses lines extracted from the image and the projection of the roof contours extracted from the LASER data to establish a MRF description based on relations of length, proximity and orientation between the two sets of straight lines. One of the proposed improvements is to include in the energy function associated with the MRF a restriction called corner injunction. This restriction considers that the intersection of two adjacent lines, corresponding to the contour sides, should be close to a corner in 90° . The corners are extracted from an image through an appropriate image processing algorithm. Other improvement in the energy function is based on the fact that the lines representing roof contours are approximately parallel or orthogonal. This restriction was called rectangularity injunction. Other modification in the original methodology refers to the energy function optimization algorithm. The original methodology used the brute force optimization algorithm associated with some heuristics. Although this method allows to obtain the optimal solution, if there is, the search space becomes computationally intractable when dozens of lines are in the search space. It is proposed to use a genetic algorithm in order to solve this problem. This algorithm should enable the solution of the optimization problem in situations not feasible for the original methodology. It is also proposed to include the ridge structure, made possible by the modification of the optimization algorithm. Although the combination of laser data with data from high-resolution aerial image is more justified to refine the contour of the roof, the ridge structure can provide greater robustness in the topological description of the roof structure, composed of straight line segments of edges and ridges. An experimental evaluation was performed and the results showed that the methodology works successfully in the task of refining and reconstructing building rooftops. The modifications performed in the method contributed positively to supply deficiencies presented by the original methodology.

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

LISTA DE TABELAS

Tabela 1: Complementaridade dos dados LASER e dos dados fotogramétricos.	35
Tabela 2: Cliques para os nós R_1 e R_5 da Figura 2.12.	42

LISTA DE FIGURAS

Figura 2.1 – Borda degrau.	18
Figura 2.2 – Detecção de bordas.	19
Figura 2.3 – Supressão não máxima.	22
Figura 2.4 – Modelo de linha ideal.	24
Figura 2.5 – Perfil de linha de mesma polaridade.	24
Figura 2.6 – Perfil de linha com polaridades diferentes.	25
Figura 2.7 – Algoritmo de divisão recursiva.	31
Figura 2.8 - Componentes de um sistema de varredura a LASER.	32
Figura 2.9 – Exemplo de perfilagem irregular obtida por varredura a LASER.	35
Figura 2.10 – Exemplo de agrupamento perceptual hierárquico.	38
Figura 2.11 – Grafo G(R, E).	40
Figura 2.12 – (a) Imagem segmentada; (b) RAG.	41
Figura 2.13 - Estrutura Básica de um AG.	49
Figura 3.1 – Principais etapas do método.	55
Figura 3.2 – Fluxograma do algoritmo da metodologia para detecção de contorno e cumeeira de edifício.	57
Figura 3.3 – Ilustração da janela envolvente.	58
Figura 3.4 – Exemplo.	59
Figura 3.5 – Fluxograma do método utilizado para a determinação da altura e erro de registro para cada pixel da imagem.	61
Figura 3.6 – Condição de colinearidade e proximidade.	62
Figura 3.7 – Elementos Geométricos para a definição das métricas de proximidade e de orientação.	65
Figura 3.8 – Função sigmóide para $\beta = 1$ e $\beta = 0,001$	66
Figura 3.9 - Quinas detectadas, exemplo de uma janela de busca.	69
Figura 3.10 – Exemplo.	70
Figura 3.11 – População inicial.	71
Figura 3.12 – Cruzamento.	72
Figura 3.13 – Mutação.	73
Figura 3.14 – Ilustração da estratégia de complementação.	74
Figura 4.1 – Edifício teste 1.	77
Figura 4.2 – Edifício teste 2.	78
Figura 4.3 – Edifício teste 3.	80
Figura 4.4 – Edifício teste 4.	81
Figura 4.5 – Edifício teste 5.	83
Figura 4.6 – Edifício teste 6.	84
Figura 4.7- Contribuição da estrutura de cumeeiras.	85
Figura 4.8- Exemplo relacionado a inunção de retangularidade e quina.	86

SUMÁRIO

1 INTRODUÇÃO	12
1.1 Considerações Gerais	12
1.2 Objetivos.....	15
1.2.1 Geral	15
1.2.2 Específicos.....	16
1.3 Estrutura do trabalho	16
2 REVISÃO BIBLIOGRÁFICA	17
2.1 Detecção de Bordas	17
2.1.1 Conceitos iniciais.....	17
2.1.2 Definição de Bordas	18
2.1.3 Detector de Borda de Canny.....	19
2.1.3.1 Princípio	19
2.1.3.2 Algoritmo de detecção de Bordas de Canny	21
2.2 Detecção de linhas	23
2.2.1 Modelos de linhas.....	23
2.2.2 Metodologia de Steger – Caso Unidimensional	25
2.2.3 Metodologia de Steger – Caso Bidimensional	26
2.3 Detecção de quinas	27
2.3.1 Detector de quinas de Harris	28
2.4 Vetorização e Poligonização	30
2.5 Varredura a LASER.....	31
2.5.1 Qualidade dos dados de varredura a LASER	33
2.5.2 Amostragem dos pontos LASER.....	34
2.5.3 Varredura a LASER versus aerofotogrametria para extração de edifícios.....	35
2.6 Agrupamento Perceptual	37
2.7 Campos Aleatórios de Markov (<i>Markov Random Field</i> - MRF)	39
2.7.1 MRF para análise de imagens por regiões.....	39
2.7.2 MRF em estrutura de grafo.....	40
2.7.3 Rotulação de imagem usando MRF.....	43
2.8 Solução MAP.....	45
2.9 Métodos de Otimização	46
2.9.1 Algoritmos Genéticos	47
2.9.1.1 Histórico	47
2.9.1.2 Algoritmo Genético	48
2.9.1.3 Operações de um AG.....	48
2.9.1.3.1 Cálculo da Aptidão	49
2.9.1.3.2 Seleção	50
2.9.1.3.3 Técnicas de Reprodução	51
2.9.1.3.4 Operadores Genéticos	51
2.9.1.3.5 Critérios de Parada.....	53
3 MATERIAL E MÉTODOS.....	54
3.1 Materiais	54
3.1.1 Dados	54
3.1.2 Recursos de Hardware e Software.....	54
3.2 Métodos	54
3.2.1 Pré-processamento.....	56

3.2.2	Formulação da Função de Energia	63
3.2.3	Integração da estrutura de cumeeira	69
3.2.4	Otimização da função de energia usando AG	70
3.2.5	Complementação dos agrupamentos de retas	74
4	RESULTADOS EXPERIMENTAIS	75
4.1	Considerações Iniciais	75
4.2	Limiares e parâmetros utilizados	76
4.3	Resultados e análise	76
5	CONCLUSÃO	88
5.1	Considerações Finais	88
5.2	Recomendações para Trabalhos Futuros	90
	REFERÊNCIAS	91
	APÊNDICES	100
	Apêndice A	100
	Apêndice B	124

1 INTRODUÇÃO

1.1 Considerações Gerais

Na Cartografia, a aquisição e a atualização de dados espaciais são de grande importância para o desenvolvimento e a manutenção de um Sistema de Informações Geográficas (SIG). Isso porque as informações contidas em um SIG podem auxiliar em propostas de planejamento, administração e monitoramentos socioeconômicos de cidades. O desenvolvimento de métodos para coleta de dados espaciais a partir de imagens ou de outros tipos de dados (por exemplo, dados de varredura a LASER - *Light Amplification by Stimulated Emission of Radiance*), é uma das principais finalidades de pesquisa em Fotogrametria.

Nesse contexto, as pesquisas na área de extração de feições têm crescido nos últimos anos. Em particular, a extração de telhados de edifícios tem sido, segundo Mayer (1999), iniciaram-se na primeira parte da década de 1980. Até meados da década de 1990 as imagens aéreas eram as fontes usuais de dados utilizadas para a extração. No final dessa mesma década outras fontes de dados (por exemplo, as imagens de satélites de alta-resolução e os dados de varredura a LASER) passaram a ser utilizadas. O uso de dados LASER em problemas de extração 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.

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 LASER 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. Quando se trata da obtenção de planos de telhados e sua orientação, os dados LASER apresentam melhores resultados, uma vez que as alturas são mais precisas nesse tipo de 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. Já com relação à extração de contornos de telhados as imagens apresentam melhores resultados, pois as informações posicionais ao longo das linhas de quebra são densas nesses dados, ao contrário dos dados LASER (DAL POZ et al, 2009a).

Várias metodologias dessa classe podem ser encontradas na literatura. Como por exemplo, Haala e Brenner (1999) combinaram imagens multiespectrais e dados MDE/LASER (Modelo Digital de Elevação gerado a partir de dados LASER) para separar edifícios de vegetação. Sohn e Dowman (2003) sugeriram outra metodologia, em que inicialmente os edifícios são extraídos separadamente de uma imagem Ikonos e de dados MDE/LASER e, em seguida, ambos os resultados são combinados para a remoção de inconsistências. Machado e Mitishita (2006) combinaram imagens aéreas de pequeno formato e dados LASER para extrair contornos de telhados. O sistema desenvolvido inicialmente segmenta a imagem no espaço de cores CEILUV e filtra as regiões correspondentes à vegetação e a objetos baixos (estes são identificados através dos dados LASER). O último passo consiste em regularizar os contornos remanescentes da filtragem usando o algoritmo de Douglas-Peucker. Já em Cheng et al. (2008) os edifícios segmentados nos dados LASER 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 LASER 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 LASER e registrados nas regiões da imagem, são eliminados. As retas remanescentes são agrupadas para gerar os contornos fechados dos edifícios. Awrangjeb et al. (2012) apresentam um método para reconstrução automática de telhados 3D através da integração de dados LASER 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 LASER 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 Chen et al. (2012) é proposto um método para detecção de edifícios com uso de dados LASER e imagem QuickBird. Os dados LASER são utilizados para gerar um MDSn (Modelo Digital de Superfície normalizado) e, assim serem obtidos os candidatos a representar edifícios, em seguida, a vegetação é filtrada com base em informações da imagem.

Com o objetivo de solucionar as dificuldades encontradas na extração automática de contornos e cumeeiras de telhados a partir de dados laser e de imagens aéreas de alta-resolução (pixels de 0,5 m ou menores), e tendo em vista que, os dados laser permitem extrair estes tipos de feições com relativa robustez, mas a qualidade geométrica desses resultados deixa a desejar, Dal Poz (2008) e Dal Poz et al. (2009) propuseram uma metodologia para o refinamento geométrico de contornos de telhados extraídos de dados de varredura a LASER, usando imagens aéreas de alta resolução e modelos de campo aleatório de Markov (MRF - *Markov Random Field*). Primeiramente, os contornos 3D representando contornos de telhados, dados de entrada da metodologia, 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 de uma versão modificada do algoritmo de força bruta, resultando num agrupamento de retas para cada contorno de telhado. Marcato (2010a) e Marcato (2010) desenvolveram uma metodologia para selecionar automaticamente o detector de descontinuidades relacionadas com contornos e cumeeiras de telhados. Essa combinação de detectores é necessária porque em imagens aéreas de alta resolução os contornos e cumeeiras de telhados geralmente manifestam-se como bordas degrau e linhas, respectivamente. Também foram desenvolvidos algoritmos para a filtragem de retas pertencentes ao terreno com base em dados LASER 3D e para a redução de fragmentação de retas via regras de agrupamento perceptivo. Uma desvantagem do método é que retas sobre e muito próximas aos telhados não podem ser eliminadas. Marcato (2010b) integrou os desenvolvimentos realizados em Marcato (2010a) na metodologia proposta em Dal Poz (2008) e Dal Poz et al. (2009). Como as técnicas de pré-processamento desenvolvidas em Marcato (2010a) reduzem significativamente a quantidade de retas não representativas de contornos de telhados (falsos positivos), os benefícios dessa integração são basicamente dois: menor probabilidade da presença de falsos positivos e negativos nos agrupamentos finais de retas obtidos por otimização; e redução do esforço computacional na etapa de otimização.

Essa pesquisa apresenta a continuidade do trabalho desenvolvido em Marcato (2010b), na qual, são apresentados basicamente três desafios:

- **Aperfeiçoar a função de energia proposta em Dal Poz (2008) e Dal Poz et al. (2009):** a função de energia original foi concebida levando em conta principalmente os critérios de proximidade e orientação. Propõem-se estendê-la levando em conta duas propriedades adicionais de contornos de telhados. A primeira propriedade é a de

retangularidade, pela qual as retas correspondentes aos contornos de telhados são aproximadamente perpendiculares ou paralelas. Esta propriedade dará origem a um termo de energia denominado *injunção de retangularidade*. A segunda propriedade baseia-se fato de que as retas correspondentes a contornos de telhados se interceptam próximas a quinas em 90°, detectadas via algoritmo específico de processamento de imagem. O termo de energia correspondente é denominado *injunção de quina*.

- **Modelar a estrutura de cumeeiras:** a estrutura de cumeeiras não foi considerada em Dal Poz (2008) e Dal Poz et al. (2009) para evitar a alta dimensionalidade do espaço de busca de otimização nos casos envolvendo edifícios mais complexos. Embora a combinação de dados LASER com dados de imagem aérea de alta resolução é justificada mais para o refinamento de contorno de telhado, a estrutura de cumeeiras pode dar maior robustez na descrição topológica da estrutura de telhado, composta de segmentos de retas de contornos e cumeeiras. Vale ressaltar que as injunções de retangularidade e quinas (em 90°) não são aplicáveis às retas de cumeeiras.
- **Usar o algoritmo genético (AG) para otimizar a função de energia:** Dal Poz (2008) e Dal Poz et al. (2009) utilizaram o algoritmo de otimização de força bruta associado com algumas heurísticas. Embora este método permita obter a solução ótima, caso exista, o espaço de busca fica intratável computacionalmente quando o número de retas supera algumas dezenas. O uso de AG permite contornar este problema, possibilitando a introdução da estrutura de cumeeiras de edifícios complexos.

1.2 Objetivos

1.2.1 Geral

Aperfeiçoar uma metodologia preexistente para o refinamento geométrico de contornos de telhados a partir de imagens aéreas de alta resolução e poliedros de edifícios extraídos de dados LASER.

1.2.2 Específicos

- 1) Modelar, implementar e avaliar experimentalmente a injeção de retangularidade para contornos de telhado;
- 2) Modelar, implementar e avaliar experimentalmente a injeção de quina para contornos de telhados;
- 3) Integrar a estrutura de cumeeira no problema de otimização e avaliar o impacto na solução;
- 4) Implementar o algoritmo AG para otimizar a função de energia modificada com as injeções de retangularidade e de quina; e
- 5) Comparar a metodologia modificada com a original.

1.3 Estrutura do trabalho

Esse trabalho está dividido em 6 capítulos principais e dois apêndices. O capítulo 2 trata dos fundamentos necessários para o desenvolvimento da metodologia proposta. No capítulo 3 é apresentado o método proposto. O capítulo 4 apresenta os resultados experimentais. O capítulo 5 apresenta as conclusões.

2 REVISÃO BIBLIOGRÁFICA

Este capítulo apresenta conceitos e ferramentas fundamentais para o desenvolvimento da pesquisa proposta. A Subseção 2.1 trata sobre a detecção de bordas, na qual são apresentados alguns conceitos iniciais como a definição de bordas, a detecção de bordas e o detector de Canny. A Subseção 2.2 apresenta modelos de linhas e a metodologia de detecção de linhas de Steger, no caso uni e bi-dimensional. A Subseção 2.3 versa sobre a detecção de quinas, e apresenta o detector de Harris. A Subseção 2.4 apresenta uma breve descrição do processo de vetorização e poligonização. Na Subseção 2.5 é apresentado, brevemente, a varredura a LASER, a qualidade e amostragem dos dados. A Subseção 2.6 conceitos básicos sobre agrupamento perceptual. A Subseção 2.7 versa sobre a teoria de Campos Aleatórios de Markov (MRF – Markov Random Field). Na Subseção 2.8 é introduzido o conceito de a solução MAP – Maximum a Posteriori. A Subseção 2.9 finaliza esse capítulo, apresentado os métodos de otimização, em especial o Algoritmo Genético. Existem outros assuntos, tal como o ligado à modelagem fotogramétrica, que também possuem alguma importância no desenvolvimento metodológico. Entretanto, por serem de domínio comum na área, foram organizados no Apêndice A.

2.1 Detecção de Bordas

2.1.1 Conceitos iniciais

O propósito de detectar bordas é a localização de variações ou descontinuidades dos níveis digitais da imagem. Assim, para que as bordas de uma imagem sejam detectadas pode-se aplicar um processo de diferenciação da imagem. Porém, quando a imagem é diferenciada, detectam-se também as bordas espúrias, provenientes de ruído ou textura da imagem, que são formas indesejáveis de variação (VALE e DAL POZ, 2002).

Para evitar esse problema, a imagem deve passar pelo processo de suavização, no entanto, ao aplicar esse procedimento, há uma perda de informação e o

deslocamento de suas bordas (VALE e DAL POZ, 2002). Além disso, as diferentes propriedades dos operadores de diferenciação geram diferentes bordas. Logo, torna-se difícil desenvolver algoritmos de detecção de bordas que tenham um bom desempenho em diferentes contextos. Por esse motivo, em todo o processo evolutivo do processamento digital de imagens, surgiu uma grande variedade de detectores de bordas.

2.1.2 Definição de Bordas

Um dos tipos mais comuns de bordas em imagens são as bordas do tipo degrau. Esse tipo de bordas, normalmente, ocorre entre duas regiões homogêneas, que diferem entre os tons de cinza. Uma borda desse tipo é matematicamente definida como $G(x) = A \cdot u_{-1}(x)$, em que A é a amplitude da borda e $u_{-1}(x)$ é dada por (VALE e DAL POZ, 2002):

$$u_{-1}(x) = \begin{cases} 0, & \text{para } x < 0 \\ 1, & \text{para } x \geq 0 \end{cases} \quad (2.1)$$

Em imagens reais, as bordas degrau são localizadas nos pontos de inflexão da imagem. Na realidade, o processo de formação da imagem gera bordas envolvidas por ruídos espalhados pela imagem, que acarretam certa distorção nas bordas, como pode ser visualizada na Figura 2.1.




Figura 2.1 – Borda degrau. (a) Borda degrau ideal; e (b) Borda degrau distorcida pelo espalhamento de ruídos.

(Fonte: ZIOU e TABBONE, 1998)

Consequentemente, as bordas degraus estão localizadas nos máximos ou nos mínimos da derivada primeira, ou nos zeros da derivada segunda, como mostra a Figura 2.2.




Figura 2.2 – Detecção de bordas. (a) Primeira derivada sem a influência de ruído; e (b) Segunda derivada sem a influência de ruído.
(Fonte: ZIOU e TABBONE, 1998)

Em duas dimensões, a primeira derivada é definida pelo gradiente e a segunda derivada é aproximada pelo Laplaciano ou pela segunda derivada na direção do gradiente.

2.1.3 Detector de Borda de Canny

2.1.3.1 Princípio

O processo de detecção de bordas, desenvolvido por Canny, é definido a partir de critérios básicos de desempenho, sendo eles (CANNY, 1986):

- Taxa de erro (detecção): corresponde à maximização da razão sinal/ruído, SNR (*Signal- to- noise Ratio*), assim quanto maior for o SNR, maior é a probabilidade de se detectar as bordas verdadeiras da imagem;
- Localização (L): os pontos, extraídos pelo detector, devem corresponder às bordas, ou seja, as distâncias entre os pontos extraídos pelo detector e as respectivas posições verdadeiras devem ser minimizadas;
- Injunção de resposta múltipla: o detector de bordas não deverá identificar múltiplos pixels de bordas onde só existe uma borda, ou seja, o detector de bordas deverá detectar uma única borda onde existe somente uma borda verdadeira.

A proposta de Canny é encontrar o filtro f que maximize o produto entre SNR e a localização, sujeito a limitação de respostas múltiplas.

O desenvolvimento de um filtro para a detecção de bordas arbitrárias envolve, inicialmente, a maximização dos dois primeiros critérios (taxa de erro e localização), o que é igual à maximização do produto entre ambos (SNR e L) (CANNY, 1986).

$$\left(\frac{\left| \int_{-w}^w G(-x) f(x) dx \right|}{n_0 \sqrt{\int_{-w}^w f^2(x) dx}} \right) \cdot \left(\frac{\left| \int_{-w}^w G'(-x) f(x) dx \right|}{n_0 \sqrt{\int_{-w}^w f^2(x) dx}} \right) \quad (2.2)$$

em que $f(x)$ é a resposta de impulso do filtro definido no intervalo $[-w; w]$, $G(x)$ é uma borda unidimensional e n_0 a quantificação do ruído da imagem. Assume-se que a borda está centrada em $x = 0$. Na Equação 2.2, a primeira quantidade entre parêntesis corresponde ao SNR e a segunda à L.

O filtro ótimo ainda deve se submeter ao terceiro critério, inunção de resposta múltipla. Para tanto, o detector de bordas deverá detectar uma única borda onde existe somente uma borda verdadeira. Seja (CANNY, 1986):

$$x_{\max} = 2\pi \left(\frac{\int_{-\infty}^{+\infty} f^2(x) dx}{\int_{-\infty}^{+\infty} f'^2(x) dx} \right)^{1/2} \quad (2.3)$$

a expressão matemática para a distância ($x_{\max}$) entre máximos adjacentes na resposta do filtro $f(x)$ devido ao ruído. Assim, ao maximizar a condição dada pela Equação 2.2, deve-se também garantir que $x_{\max}$ seja maior possível, aumentando a possibilidade de separação de máximos verdadeiros na saída do filtro $f(x)$.

Uma das principais constatações de Canny foi que o operador ótimo encontrado é muito semelhante à função gerada pela primeira derivada da função Gaussiana, o que possibilita a aproximação do filtro ótimo encontrado por Canny pela derivada primeira da função Gaussiana, de forma equivalente.

O principal motivo para que se utilize essa função, deve-se ao fato de apresentar uma forma analítica simples, e dada sua separabilidade, possibilita a convolução de uma imagem com a derivada primeira Gaussiana, inicialmente, em uma direção (linha ou coluna) e depois na outra, sendo eficiente para computar a extensão bidimensional do filtro.

O filtro ótimo f , para o caso unidimensional, fica então aproximado por (Equação 2.4):

$$G'(x) = \left(-\frac{x}{\sigma^2} \right) e^{-\frac{x^2}{2\sigma^2}} \quad (2.4)$$

2.1.3.2 Algoritmo de detecção de Bordas de Canny

No processo de detecção de bordas de Canny, inicialmente, a imagem a ser processada é lida.

Em seguida, efetua-se a suavização da imagem através do filtro de suavização Gaussiano, usando filtragem separável, pois, como se sabe, a convolução e a diferenciação são associáveis e a Gaussiana separável. O resultado será uma matriz $S[i, j]$ dada por (VALE e DAL POZ, 2002):

$$S[i, j] = G[i, j, \sigma] * I[i, j] \quad (2.5)$$

em que $*$ denota a convolução, $I[i, j]$ é a imagem de entrada, $G[i, j, \sigma]$ é o filtro Gaussiano, e σ é o desvio-padrão da Gaussiana, responsável pelo controle do grau de suavização.

A próxima etapa é criar máscaras unidimensionais para a diferenciação, assim o gradiente pode ser computado por uma máscara 2x2 de aproximações de primeira diferença, gerando duas derivadas parciais $G_x[i, j]$ (Equação 2.6), derivada em x, e $G_y[i, j]$ (Equação 2.7), derivada em y (VALE e DAL POZ, 2002).

$$G_x[I, j] \cong (S[i, j+1] - S[i, j] + S[i+1, j+1] - S[i+1, j])/2 \quad (2.6)$$

$$G_y[I, j] \cong (S[i, j] - S[i+1, j] + S[i, j+1] - S[i+1, j+1])/2 \quad (2.7)$$

A magnitude e a orientação do gradiente são obtidas por fórmulas de conversão de coordenadas retangulares para polar (VALE e DAL POZ, 2002):

$$M[i, j] = \sqrt{G_x[i, j]^2 + G_y[i, j]^2} \quad (2.8)$$

$$\theta[i, j] = \arctan(G_y[i, j] / G_x[i, j]) \quad (2.9)$$

O próximo procedimento é aplicar o método da supressão não máxima, que consiste em determinar uma melhor localização para a borda a partir da imagem de magnitude do gradiente ($M[i, j]$). Para tanto, busca-se na direção do gradiente da imagem, por valores de pixels que são máximos locais, e eliminam-se os pixels cujos valores não são máximos locais. Portanto, essa técnica é eficiente para afinar os cumes largos da matriz $M[i, j]$.

Na Figura 2.3 (a), o pixel central ($c, 1$) é analisado, verifica-se que ($c, 1$) é um máximo local e a direção do gradiente é de 45° . A partir do valor do pixel ($c, 1$), uma máscara 3×3 , percorre $M[i, j]$ e compara a magnitude desse pixel com a magnitude de seu vizinho no sentido do gradiente ($c+1, 1-1$) e com a magnitude de seu vizinho no sentido contrário ao do gradiente ($c-1, 1+1$). Assim, observa-se que os pixels em cinza terão seus valores igualados a zero.




Figura 2.3 – Supressão não máxima. (a) Esquema de supressão não máxima para $\theta = 45^\circ$; e (b) Setores considerados para a supressão não máxima.
(Fonte: VALE e DAL POZ, 2002)

A Figura 2.3 (b) ilustra a limitação do ângulo $\theta[i, j]$ do gradiente em um dos quatro setores (Equação 2.10) (VALE e DAL POZ, 2002).

$$\zeta[i, j] = \text{Setor}(\theta[i, j]) \quad (2.10)$$

Assim, de acordo com o setor $\zeta[i, j]$ determinado, a máscara 3×3 passa, de modo que a comparação do pixel central $M[i, j]$ é feita, ao longo da linha do gradiente, com seus dois vizinhos.

O próximo passo é a limiarização adaptativa (histerese), que consiste em utilizar dois limiares τ_1 e τ_2 , onde $\tau_1 \cong 2\tau_2$ ou $\tau_1 \cong 3\tau_2$. Aplicando a limiarização duas

vezes, uma para τ_1 e outra para τ_2 , o algoritmo efetua um processo de complementação das descontinuidades da primeira limiarização aproveitando o resultado da segunda.

2.2 Detecção de linhas

As linhas, assim como as bordas, são descontinuidades presentes em imagens digitais. Essas linhas apresentam um perfil de intensidade parecido, em um corte transversal, com uma cumeeira de telhado ou com uma barra estreita.

Normalmente, as linhas representam objetos alongados. Em uma imagem de baixa-resolução as linhas variam de um a três pixels, e, geralmente, são confundidas geometricamente com as próprias feições. Já em imagens de média e alta resolução, elas variam até dezenas de pixels, e apresentam-se como faixas estreitas e alongadas.

A extração de linhas é uma operação considerada como sendo de baixo nível, possuindo várias aplicações no processamento digital de imagens. De fato as linhas podem representar nas imagens, importantes feições, como rios, estradas e rodovias.

2.2.1 Modelos de linhas

Assim como as bordas, as linhas podem ser modeladas unidimensionalmente no espaço bidimensional. Essas feições podem ser moldadas por curvas paramétricas do tipo $s(t)$ que, normalmente, são caracterizadas pelos níveis de cinza em perfis transversais.

A linha pode ser considerada como uma combinação de duas bordas e, esse fato torna necessária à análise dos perfis das duas bordas a fim de verificar se possuem ou não a mesma polaridade (STEGGER, 2000).

Se as bordas possuem a mesma polaridade, tem-se o perfil de linha em forma de barra. Esse perfil é tido como ideal, possui largura $2w$ e altura h e pode ser modelado pela Equação 2.11 e visualizado na Figura 2.4.

$$f_b(x) = \begin{cases} h, & |x| \leq w \\ 0, & |x| > w \end{cases} \quad (2.11)$$




Figura 2.4 – Modelo de linha ideal.
(Fonte: ISHIBASHI, 2008)

Se a linha possui a mesma polaridade, mas contrastes laterais diferentes (Figura 2.5) utiliza-se a seguinte equação para modelar o perfil de linha:

$$f_a(x) = \begin{cases} 0, & x < -w \\ h, & |x| \leq w \\ a, & x > w \end{cases} \quad (2.12)$$




Figura 2.5 – Perfil de linha de mesma polaridade.
(Fonte: Adaptado de ISHIBASHI, 2008)

sendo que $a \in [0, 1[$

Para linhas com polaridades diferentes (Figura 2.6) pode-se utilizar a Equação 2.13 com $a > 1$. No entanto, segundo Steger (2000), uma linha com polaridade diferente é melhor representada por:

$$f_s(x) = \begin{cases} 0, & x < -w \\ a, & |x| \leq w \\ h, & x > w \end{cases} \quad (2.13)$$




Figura 2.6 – Perfil de linha com polaridades diferentes.
(Fonte: Adaptado de ISHIBASHI, 2008)

2.2.2 Metodologia de Steger – Caso Unidimensional

Para a detecção de linhas com o perfil dado pela Equação 2.12 em uma imagem $z(x)$ sem ruídos, é necessário que seja determinado o ponto onde a derivada primeira de $z(x)$ se anula ($z' = 0$). Para que as linhas mais salientes sejam selecionadas, é necessário verificar se a segunda derivada $z''(x) \gg 0$ no ponto onde $z' = 0$ (STEGGER, 1996).

Se as imagens contêm ruídos, o que ocorre na prática, esse método não é suficiente. Para solucionar esse problema, a primeira e a segunda derivadas de $z(x)$ podem ser estimadas convoluindo a imagem com as derivadas do núcleo Gaussiano, apropriado para essa finalidade. O núcleo Gaussiano e suas derivadas de primeira e segunda ordem, com desvio-padrão σ , são dados por (STEGGER, 1996),

$$g_{\sigma}(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2}{2\sigma^2}} \quad (2.14)$$

$$g'_{\sigma}(x) = \frac{-x}{\sqrt{2\pi}\sigma^3} e^{-\frac{x^2}{2\sigma^2}} \quad (2.15)$$

$$g''_{\sigma}(x) = \frac{x^2 - \sigma^2}{\sqrt{2\pi}\sigma^5} e^{-\frac{x^2}{2\sigma^2}} \quad (2.16)$$

A convolução com o núcleo Gaussiano das linhas dadas pela Equação 2.12, conduz a uma descrição do espaço-escala do perfil da linha, como segue (STEGGER, 1996):

$$r_a(x; \sigma; w; a) = g_{\sigma} * f_a(x) = \varphi_{\sigma}(x+w) + (a-1)\varphi_{\sigma}(x-w) \quad (2.17)$$

$$r'_a(x; \sigma; w; a) = g'_{\sigma} * f_a(x) = g'_{\sigma}(x+w) + (a-1)g'_{\sigma}(x-w) \quad (2.18)$$

$$r''_a(x; \sigma; w; a) = g''_{\sigma} * f_a(x) = g''_{\sigma}(x+w) + (a-1)g''_{\sigma}(x-w) \quad (2.19)$$

em que, $\varphi_\sigma(x)$ é a integral do núcleo Gaussiano, dada por:

$$\varphi_\sigma(x) = \int_{-\infty}^x e^{-\frac{t^2}{2\sigma^2}} dt \quad (2.20)$$

De uma forma geral, um determinado ponto da imagem é considerado como pertencente a uma linha saliente se, nesse ponto, $r'_a = 0$ e $r''_a \gg 0$.

Para preservar as linhas mais importantes, é necessário selecionar um desvio-padrão gaussiano que possibilite salientar essas linhas. Esse valor de desvio-padrão é sugerido por Steger (1998) como sendo $\sigma > \frac{w}{\sqrt{3}}$. Este valor de σ é obtido através da solução

de $\frac{\partial}{\partial \sigma}(r''_a(0, \sigma, w, h)) = 0$. A posição da linha pode ser determinada por (STEGGER, 2000),

$$x = -\frac{\sigma^2}{2w} \ln(1-a) \quad (2.21)$$

Como pode ser observada, a Equação 2.21 mostra que a linha será extraída na posição correta ($x = 0$) somente se o contraste em ambos os lados da linha forem iguais, isto é, $a = 0$.

2.2.3 Metodologia de Steger – Caso Bidimensional

No caso 2D, as linhas podem ser modeladas com uma curva $s(t)$ para o qual se tem na direção transversal um comportamento semelhante ao perfil unidimensional dado pela Equação 2.12. Assim, dado um ponto p de $s(t)$, deve-se analisar a direção transversal à linha em p , correspondente ao vetor normal $\vec{n}(t)$. Em consequência desse fato, podem-se extrair pontos de linhas em 2D utilizando a primeira derivada direcional na direção $\vec{n}(t)$. A direção do vetor normal $\vec{n}(t)$ pode ser obtida a partir do autovetor correspondente ao autovalor de maior magnitude da matriz Hessiana da imagem suavizada (STEGGER, 2000). A matriz Hessiana é dada por:

$$H(x, y) = \begin{pmatrix} r_{xx} & r_{xy} \\ r_{xy} & r_{yy} \end{pmatrix} \quad (2.22)$$

em que, r_{xx} é a derivada segunda em relação à direção x , r_{yy} é a derivada segunda em relação à direção y e r_{xy} é a derivada mista, todos tomados sobre a imagem suavizada. Segundo Steger (2000), uma maneira de se obter essas derivadas parciais é ajustar superfícies adequadas às janelas locais da imagem e depois obter as derivadas analiticamente.

Os autovalores (λ) de $H(X, Y)$ podem ser determinados a partir da seguinte equação:

$$\det(H(x, y) - I\lambda) = 0 \quad (2.23)$$

Obtidos os autovalores, torna-se possível o cálculo dos autovetores, responsáveis pela direção da linha, que podem ser determinados através da solução (X) da equação:

$$(H(x, y) - I\lambda)X = 0 \quad (2.24)$$

Para determinar onde a primeira derivada direcional ao longo de (n_x, n_y) se anula é necessário modelar localmente a imagem com o polinômio de Taylor de segunda ordem. Esse processo só é possível se forem encontrados os valores de r_x , r_y , r_{xy} , r_{xx} e r_{yy} .

Podem ser encontrados, em Ishibashi (2008), maiores detalhes a cerca desse assunto.

2.3 Detecção de quinas

Uma quina pode ser definida como a interseção de duas bordas, assim como, um ponto para o qual existem diferentes direções de borda em sua vizinhança local. Um ponto de interesse na imagem é um ponto que tem uma posição bem definida e pode ser detectado de forma robusta. Isso significa que esse ponto pode ser uma quina, mas pode ser também, por exemplo, um ponto isolado com intensidade local máxima ou mínima, final de linhas, ou um ponto em uma curva onde a curvatura é localmente máxima.

Assim, em se tratando da detecção de quinas deseja-se que um detector de quinas atenda alguns requisitos, dentre eles (WANG e DONY, 2004):

- Detecção de todas as quinas existentes na imagem;
- Não detecção de falsas quinas;
- Fidelidade na localização da quina;
- Eficiência sob diferentes circunstâncias de aplicação;
- Robustez com relação a ruídos; e
- Eficiência computacional.

O primeiro detector de quinas foi desenvolvido por Moravec (1977) e desde então, pesquisadores tem se dedicado no desenvolvimento de um detector de quinas ideal. Na literatura tem-se alguns métodos relacionados com bordas (KITCHEN e ROSENFELD, 1982; WANG e BRADY, 1995), outros métodos baseados em topologia (BEAUDET, 1978; DERICHE e GIRAUDON, 1993), outros com correlação (MORAVEC, 1977, HARRIS e STEPHENS, 1988; FÖRSTNER, 1986) e alguns outros métodos alternativos (SMITH e BRADY, 1997; MOKHTARIAN e SUOMELA, 1998).

Uma abordagem frequentemente utilizada é baseada no método proposto por Chris Harris e Mike Stephens (HARRIS e STEPHENS, 1988), o detector de quina de Harris. Esse detector desperta amplo interesse devido à sua invariância de rotação, escala, variação de iluminação e ruídos de imagem. E em se tratando dos requisitos desejáveis a um detector de quinas, esse detector apresenta vantagens com relação aos outros métodos.

2.3.1 Detector de quinas de Harris

O detector de Harris é baseado na função de auto-correlação local do sinal, em que a função de auto-correlação local mede as mudanças locais do sinal com correções de deslocamentos.

Dado um deslocamento $(\Delta x, \Delta y)$ e um ponto (x, y) , a função de auto-correlação é definida como (Equação 2.25),

$$c(x, y; \Delta x, \Delta y) = \sum_{(u,v) \in W(x,y)} w(u, v) [I(u, v) - I(u + \Delta x, v + \Delta y)]^2 \quad (2.25)$$

em que $W(x, y)$ é uma janela centrada em (x, y) ; $w(u, v)$ é uma constante ou a Gaussiana

$$e^{-\frac{(u-x)^2 + (v-y)^2}{2\sigma^2}}.$$

Para simplificar $\sum_{(u,v) \in W(x,y)} w(u, v)$ é substituído por $\sum_W$.

Em seguida, a função de deslocamento é aproximada pela expansão de Taylor de primeira ordem (Equação 2.115).

$$I(u + \Delta x, v + \Delta y) \approx I(u, v) + I_x(u, v)\Delta x + I_y(u, v)\Delta y = I(u, v) + [I_x(u, v), I_y(u, v)] \begin{bmatrix} \Delta x \\ \Delta y \end{bmatrix} \quad (2.26)$$

em que I_x e I_y são derivadas parciais de $I(x, y)$.

$$\begin{aligned} c(x, y; \Delta x, \Delta y) &= \sum_W [I(u, v) - I(u + \Delta x, v + \Delta y)]^2 \\ &\approx \sum_W \left\{ [I_x(u, v), I_y(u, v)] \begin{bmatrix} \Delta x \\ \Delta y \end{bmatrix} \right\}^2 \\ &= [\Delta x, \Delta y] C(x, y) \begin{bmatrix} \Delta x \\ \Delta y \end{bmatrix} \end{aligned} \quad (2.27)$$

em que,

$$\begin{aligned} C(x, y) &= \sum_W \begin{bmatrix} I_x(x, y)^2 & I_x(x, y)I_y(x, y) \\ I_x(x, y)I_y(x, y) & I_y(x, y)^2 \end{bmatrix} \\ &= \begin{bmatrix} \sum_W I_x(x, y)^2 & \sum_W I_x(x, y)I_y(x, y) \\ \sum_W I_x(x, y)I_y(x, y) & \sum_W I_y(x, y)^2 \end{bmatrix} \end{aligned} \quad (2.28)$$

onde, $C(x, y)$ captura a estrutura de intensidade da vizinhança local. Dessa forma, deve-se considerar três condições referentes aos autovalores (λ_1, λ_2) da matriz $C(x, y)$ (HARRIS e STEPHENS, 1988):

- 1) Os autovalores (λ_1, λ_2) são pequenos, significando que a região na imagem é aproximadamente constante em intensidade;
- 2) Se um autovalor é grande e o outro pequeno, isso indica a presença de uma borda;
- 3) Se os dois autovalores são altos, isso indica uma quina.

2.4 Vetorização e Poligonização

O processo de vetorização consiste em varrer todos os pixels de uma imagem binária e formar uma lista ordenada de pixels, 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 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 2.7(a), inicialmente a curva inicial é modelada grosseiramente pelo segmento de reta definido pelos pontos A e B. Na sequência (Figura 2.7(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 que se aproxima mais da 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 2.7(c)). O procedimento prossegue até que nenhum ponto da curva inicial esteja a uma distância da linha poligonal superior a um limiar pré-definido.




Figura 2.7 – Algoritmo de divisão recursiva.
(Fonte: Adaptado de JAIN et al., 1995)

2.5 Varredura a LASER

Com o avanço das tecnologias, os métodos utilizados no levantamento tridimensional de pontos no terreno veem se aprimorando. Ao mesmo tempo, são desenvolvidas técnicas, que utilizam a representação digital do terreno, assim como as elevações associadas com objetos (árvores, edificações, entre outros), para a representação direta da superfície terrestre.

Na representação contínua da superfície física da Terra e das elevações nela presentes, em meio digital, seriam necessários um número infinito de pontos e, conseqüentemente, um potencial computacional para o armazenamento infinito de dados. Tendo em vista a impossibilidade computacional para o armazenamento de tamanha

quantidade de dados, tem-se como alternativa o uso de uma quantidade finita de pontos que representem o terreno. Para tanto, atualmente utiliza-se a amostragem de dados, o MDT (Modelo Digital do Terreno) e o MDS (Modelo Digital de Superfície).

A obtenção de um MDT ou MDS 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). Todas essas técnicas são válidas, no entanto são bastante onerosas.

Uma alternativa que se tornou viável atualmente é a aquisição de dados por meio de sistemas de 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 2.8 - 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, será apresentada apenas os fatores que afetam a qualidade dos dados de varredura a LASER e amostragem dos pontos LASER, maiores detalhes podem ser vistos em Dalmolin e Santos (2004) e Baltsavias (1999).

2.5.1 Qualidade dos dados de varredura a LASER

Durante os últimos anos a qualidade dos dados de varredura a LASER vem sendo extensivamente estudada (KRAUS e PFEIFFER, 1998; BALTSAVIAS, 1999; GORDON, LICHTI e STEWART, 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 de varredura a LASER 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 de varredura a LASER 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 de varredura a LASER 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 de varredura a LASER 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.

2.5.2 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 LASER advêm de uma perfilagem irregular na qual não é conhecido o exato espaçamento de pontos no perfil ou entre perfis (Figura 2.9).




Figura 2.9 – Exemplo de perfilagem irregular obtida por varredura a LASER.

Para a elaboração de modelos de superfícies existem vários processos. De um modo geral, esses processos se resumem à formação de poliedros a partir de triângulos que, por sua vez, foram formados por meio da interligação dos pontos amostrados. Dessa forma, a superfície é aproximada por um poliedro em que os vértices são os pontos amostrados (WOLF e DEWITT, 2000). O *Triangulated Irregular Network* (TIN) e a malha regular são as formas de representação mais usados para representar superfícies em meio digital.

2.5.3 Varredura a LASER versus aerofotogrametria para extração de edifícios

No contexto de extração de telhados de edifícios, o uso de dados de varredura a LASER, 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 1 (DAL POZ, 2009b).

Tabela 1: Complementaridade dos dados LASER 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 de varredura a LASER 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 LASER 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 LASER 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 de varredura a LASER 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, 2009b).

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 de varredura a LASER, ou dados fotogramétricos ou a combinação de ambos, e possuem diferentes níveis de refinamento e automação. Os experimentos realizados corresponderam as expectativas teóricas. Os dados LASER são superiores na determinação de elevações, planos de telhado e cumeeiras de telhado. Os principais fatores que influenciaram na obtenção desse resultado foram: a densidade de pontos, a inclinação do telhado e as dimensões do telhado. Já os dados fotogramétricos são superiores na determinação de contornos de telhados e distâncias. Os principais fatores para obtenção desses resultados foram: a densidade dos pontos, as sombras de árvores e a complexidade das estruturas de edifícios.

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

2.6 Agrupamento Perceptual

O agrupamento perceptual é uma técnica que organiza ou agrupa elementos do plano da imagem em unidades maiores a partir de relações estabelecidas no plano imagem e em regras Gestalt de organização (TRYTTEN e TUCERYAN, 1991). As regras Gestalt de organização fundamentam-se na idéia de que o mundo físico é bem estruturado e comportado. Nesse sentido, as estruturas 3D dos objetos, quando imageadas, são conservadas de modo que mesmo a partir de uma imagem ruidosa é possível deduzir a forma do objeto de interesse. Um objeto de interesse pode ser entendido como um conjunto de partes elementares, sendo assim, pode-se considerar o espaço de todos os subconjuntos das partes deste objeto para a escolha de uma hierarquia das partes particularmente apropriada. A construção dessa hierarquia, em muitos trabalhos pesquisados, obedece às regras Gestalt de organização, que são: proximidade, boa continuidade, similaridade e simetria.

O conceito de agrupamento perceptual, segundo Trytten e Tuceryan (1991), tem chamado a atenção tanto da área de visão computacional quanto da área de psicologia, de modo que esses têm chegado à concepção de "propriedades não acidentais de detecção". As propriedades não acidentais, no que diz respeito à análise de imagens, são peculiaridades presentes nas imagens que possuem baixa probabilidade de ocorrer naturalmente, como por exemplo, a colinearidade, a curvilinearidade, paralelismo, entre outros.

Na Figura 2.10, pode ser observado um modelo ilustrativo do agrupamento perceptual. Essa figura mostra os níveis de hierarquia.




Figura 2.10 – Exemplo de agrupamento perceptual hierárquico.
(Fonte: Adaptado de SCHÜTER et al., 2000)

No nível 1D (Figura 2.10) os segmentos de contorno são agrupados levando em consideração a presença de duas propriedades: colinearidade e proximidade. Segundo Schlüter et al. (2000), nesse nível, quando os elementos agrupados possuem aspecto linear, curvas ou segmentos retos, os grupos formados podem ser chamados de grupos lineares, o que esclarece a utilização da notação 1D (uma dimensão). A junção de pares de elementos dos grupos lineares origina os elementos do nível 2x1D. Nessa fase do agrupamento são utilizadas propriedades como simetria, paralelismo, perpendicularismo, entre outros, que são definidas em função de pares de elementos. Já no nível 2D, os grupos lineares são organizados em contornos fechados. Para tanto, os pontos extremos dos elementos lineares são tomados como nós de um grafo não direcionado e os contornos como arestas. Assim, o fechamento do contorno é realizado com base na proximidade dos vértices.

Vale salientar que, existem duas formas principais de agrupamento perceptual (DO VALE, 2007): o hierárquico e o não hierárquico. No agrupamento hierárquico as partes dos objetos são agrupadas por etapas, processo apresentado na Figura 2.10. Ao final,

se tem um objeto complexo organizado e as lacunas do referido objeto, presentes na imagem original, preenchidas. Já no agrupamento não hierárquico o processo é tratado por uma única regra. Dessa forma, uma função-objetivo a incorpora e, assim, por meio de uma técnica de otimização, as partes do objeto complexo são organizadas e suas lacunas preenchidas.

2.7 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 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. Normalmente, a função de energia associada com problemas de visão é não-convexa, podendo, dessa forma, ter vários mínimos locais e, assim, a solução não corresponder a um mínimo global. Desse modo, devem ser utilizados algoritmos apropriados de otimização.

O MRF pode, também, 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. Essa abordagem pode ser estendida para tratar outras primitivas, como segmentos de retas.

2.7.1 MRF para análise de imagens por regiões

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 dá-se de acordo com um 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.

2.7.2 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 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 2.11).




Figura 2.11 – 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 2.12).




Figura 2.12 – (a) Imagem segmentada; (b) RAG.
(Fonte: KOPPARAPU e DESAI, 2001)

Na Figura 2.12, 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:

$$\eta = \{\eta(R_1), \eta(R_2), \dots, \eta(R_n)\} \quad (2.29)$$

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 $P[X_i = x_i \mid X_j = x_j \forall j \neq i] = P[X_i = x_i \mid X_j = x_j \forall j \mid R_j \in \eta(R_i)]$.

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, uma clique c é um subconjunto de nós de G tal que cada par de diferentes nós em c são vizinhos. O conjunto de todas as 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 2.30).

$$P[X = x] = \frac{1}{Z} \exp^{-U(x)} \quad (2.30)$$

em que, x é uma realização de X e Z é a constante de normalização, conforme pode ser visto na Equação 2.31 e $U(x)$ é a função de energia de Gibbs (Equação 2.32).

$$Z = \sum_{\text{toda conf. } x} e^{-U(x)} \quad (2.31)$$

$$U(x) = \sum_{c \in C(G, \eta)} V_c(x^c) \quad (2.32)$$

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 2.12. A seguir, será apresentada a Tabela 2, na qual são mostradas as cliques para dois nós desse RAG.

Tabela 2: Cliques para os nós R_1 e R_5 da Figura 2.12.

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: Kopparapu 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 interação (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.

2.7.3 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 2.12(a) toma a forma do grafo de adjacência (Figura 2.12(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):

$$F = \{F^c \mid \forall c \in C(G, \eta)\} \quad (2.33)$$

em que, $F^c = \{F_1^c, \dots, F_q^c\}$ é o conjunto de q atributos medidos sobre a 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 2.85) (KOPPARAPU e DESAI, 2001).

$$P[X = x \mid F = f, k] = \frac{1}{Z} \exp^{-U(x|f, k)} \quad (2.34)$$

em que:

$$U(x \mid f, k) = \sum V_c(x^c \mid f^c, k) \quad (2.35)$$

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 2.36).

$$x_* = \arg \max_x P[X = x \mid F = f, k] \quad (2.36)$$

De forma equivalente:

$$x_* = \arg \min_x U(x \mid f, k) \quad (2.37)$$

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

2.8 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 2.38) (KOPPARAPU e DESAI, 2001).

$$x_* = \arg \min_x \left[\sum_{\forall c=um \text{ nó clique}} V_c^l(x^c | f^c, k) + \sum_{\forall c=múltiplos \text{ nós clique}} V_c^m(x^c | f^c, k) \right] \quad (2.38)$$

Na Equação 2.38, 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.

Para a solução do problema da busca combinatorial tem sido proposto esquema de relaxação para encontrar a solução local ótima para o problema da estimativa MAP (ROSENFELD et al., 1976; HUMMEL e ZUCKER, 1983).

Existem outras soluções para esse tipo de problema como, por exemplo, o Simulated Annealing (SA) que encontra o mínimo da função de energia sem cálculos excessivos (GEMAN e GEMAN, 1984), bem como, o Algoritmo Genético que é um método de otimização que se baseia no processo de seleção natural e evolução das espécies (GOLDBERG, 1989). A aplicação desse método em problemas práticos, normalmente, leva a solução para um ótimo global ou, pelo menos, para soluções mais satisfatórias que as apresentadas por outros métodos.

2.9 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, como é o caso de alguns problemas em engenharia, 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.

2.9.1 Algoritmos Genéticos

2.9.1.1 Histórico

Em 1950 e 1960 muitos cientistas realizaram estudos sobre sistemas evolucionários com a ideia que a evolução poderia ser usada como uma ferramenta de otimização para problemas de engenharia. A ideia de todos esses sistemas era de desenvolver uma população de soluções candidatas para um dado problema, utilizando operadores inspirados pela variação da genética natural e da seleção natural (MITCHELL, 1999).

Os Algoritmos Genéticos foram inventados por John Holland na década de 1960 e foi desenvolvido por Holland, seus alunos e colegas da Universidade de Michigan nas décadas de 1960 e 1970. 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.

2.9.1.2 Algoritmo Genético

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.

2.9.1.3 Operações de um AG

A estrutura básica do algoritmo genético é mostrada na Figura 2.13:




Figura 2.13 - 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, seleção e reprodução (aplicação dos operadores genéticos) (GOLDBERG, 1989).

2.9.1.3.1 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).

2.9.1.3.2 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 2.39):

$$p_i = \frac{f_i}{\sum_{j=1}^N f_j} \quad (2.39)$$

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 dificultar 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 possuírem 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).

E 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).

2.9.1.3.3 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.

2.9.1.3.4 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 tem-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).

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

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

Resulta em:

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

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

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):

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

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

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.

2.9.1.3.5 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).

3 MATERIAL E MÉTODOS

3.1 Materiais

3.1.1 Dados

Os dados utilizados na execução desse trabalho foram: 1- Poliedros representando telhados de edifícios; 2- Imagem aérea digital (com parâmetros de orientação interior e exterior), de dimensões 4500 x 3000 pixels e resolução espacial de 20 cm, da mesma área; e 3 – Nuvem de pontos LASER com densidade de aproximadamente 2 pontos/m².

3.1.2 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 da MVTec, especialmente as referentes aos detectores de Canny, Steger e Harris; compilador Builder C++; microcomputadores disponíveis no Laboratório de Fotogrametria da FCT/UNESP.

3.2 Métodos

A Figura 3.1 apresenta as principais etapas do método proposto para o refinamento e reconstrução de contornos e cumeeiras de telhados de edifícios previamente extraídos de dados LASER com o uso de dados de imagem.




Figura 3.1 – Principais etapas do método.

As principais etapas do método (Figura 3.1) são o pré-processamento, que inclui basicamente a projeção na imagem dos telhados 3D e a extração de retas ao redor dos contornos e cumeeiras projetados, o estabelecimento da função de energia ($U(x)$) com base em um modelo MRF, a otimização da função de energia através de um algoritmo de otimização e a complementação dos agrupamentos de retas obtidos para a geração de telhados completos.

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

3.2.1 Pré-processamento

O pré-processamento consiste da extração automática de segmentos de retas correspondentes a bordas e linhas de imagem, com heurísticas para filtrar parte das retas que não correspondem a contornos e cumeeiras de edifícios. Essa etapa de pré-processamento foi desenvolvida em Marcato (2010a) (Figura 3.2).




Figura 3.2 – Fluxograma do algoritmo da metodologia para detecção de contorno e cumeeira de edifício.

Como pode ser observado (Figura 3.2), os contornos 3D de telhados de edifícios, a imagem aérea e os pontos de apoio são os dados de entrada da metodologia. O primeiro passo é transformar os vértices 3D dos contornos de telhados no sistema de coordenadas de imagem (LC) através de técnicas fotogramétricas descritas brevemente na Subseção A.2 do Apêndice A e, em seguida, gerar janelas retangulares contendo as feições retas projetadas, de tal forma que: 1) cada feição reta projetada é coincidente com o eixo de simetria da janela que a contém; 2) as dimensões das janelas são calculadas em função dos comprimentos e erros de registro das respectivas feições retas projetadas; e 3) o erro de registro pode ser estimado através da lei de propagação de erros aplicada às equações de transformação dos vértices 3D para o espaço-imagem ou através da observação visual do erro de registro na imagem. A partir dessa janela retangular, cria-se uma janela envolvente, também retangular, só que dessa vez paralela a linhas e colunas. A partir das coordenadas dos cantos da primeira janela seleciona-se o valor de coluna e linha menores e o valor de coluna e linha maiores. Os novos cantos do retângulo envolvente são obtidos acrescentando ou subtraindo a elas 10 pixels, como pode ser observado a seguir (Figura 3.3).




Figura 3.3 – Ilustração da janela envolvente.

Em seguida, o segmento da imagem original, pertencente a esse retângulo envolvente, é salvo. Esse passo é desenvolvido, visando à utilização do software Halcon 7.1, tendo em vista que para conhecê-lo no processamento com os detectores de Canny e Steger é necessário fornecer o diretório em que a imagem a ser processada está salva.

No segundo passo, nesse recorte, aplica-se sequencialmente o detector de bordas de Canny, o algoritmo de vetorização e o de poligonização por divisão recursiva. E em seguida, repete-se o mesmo processo, só que dessa vez usando o detector de linhas de Steger. O objetivo é extrair retas usando Canny e Steger.

O problema de análise de imagem em questão é relativamente complexo, demandando cuidados com a escolha de operadores de bordas ou linhas para eficientemente extrair os contornos e cumeeiras de telhado. Esses cuidados decorrem do fato de que, geralmente, os contornos de telhados se manifestam geralmente como os perfis mais comuns encontrados em imagens, isto é, as descontinuidades do tipo degrau. Já as cumeeiras manifestam-se geralmente como linhas, assemelhando-se a duas bordas de degraus bem próximas. Portanto, a aplicação de um detector de bordas como o de Canny, desenvolvido especificamente para detectar bordas de degrau, apresenta bom desempenho para os contornos de telhados, mas detecta duas bordas paralelas e bem próximas para cada cumeeira. Já a aplicação de um detector de linhas, como o de Steger, que se baseia na detecção de pontos onde a segunda derivada é máximo local, permite extrair a cumeeira com alta precisão, mas geralmente não encontra as bordas correspondentes aos contornos de telhados.

A seguir delimita-se a região de busca, mantendo somente as retas que estejam dentro da primeira janela (Figura 3.4).




Figura 3.4 – Exemplo. (a) janela da imagem; (b) resultado da detecção de Steger na janela envolvente; (c) delimitação do espaço de busca.

Esse processo de delimitação do espaço de busca é feito a partir das coordenadas obtidas no processo de vetorização e poligonização. Como se sabe, as coordenadas obtidas estão no sistema de referência da janela envolvente e, para verificar se a reta está dentro da primeira janela, é feita uma transformação de coordenadas utilizando a transformação ortogonal. Se for constatado que o ponto pertence à primeira janela, armazena-se esse ponto.

A seguir pode ser observada a descrição do procedimento aplicado em uma janela de aresta projetada. Vale ressaltar que esse procedimento é repetido até que todas as n janelas que contenham as feições projetadas sejam analisadas.

Após a aplicação do detector de Steger na primeira janela ($i = 1$), é feita uma busca por retas detectadas por ele (m – número de retas detectadas por Steger dentro da janela correspondente). Se forem encontradas, é feita uma nova busca ($j = 1$), só que dessa vez por duas retas paralelas e bem próximas geradas por Canny que contenham a reta detectada por Steger. Se as retas de Canny forem encontradas, elas são descartadas e mantém-se a reta encontrada por Steger. Ao contrário, elimina-se a reta encontrada por Steger. Esse processo é repetido até que $j < m$ e, quando isso acontecer, mantém-se as retas restantes de Canny. Então verifica-se i ($i = 2$) $> n$, se for o processo é encerrado, ao contrário repete-se todo o procedimento anterior, até que $i > n$.

Se na primeira busca a reta gerada por Steger não for encontrada, retêm-se as retas geradas por Canny e deve-se verificar se i ($i = 2$) $> n$, se for o processo encerrado, ao contrário repete-se todo o procedimento anterior, até que $i > n$.

Foram adotadas algumas tolerâncias com relação ao paralelismo e a distância entre as duas retas de Canny, e também com relação à discrepância entre as distâncias entre a reta de Steger e as duas retas de Canny. As tolerâncias adotadas foram 3° , 4 pixels e 1 pixel, respectivamente.

Nessa fase do trabalho, também, foi adotado um procedimento de limiarização por comprimento mínimo a priori, que objetiva a eliminação de pequenos ruídos extraídos pelos detectores de Canny e Steger. O comprimento mínimo adotado para esse trabalho foi de 4 pixels.

Em seguida, foram aplicadas técnicas de eliminação de retas pertencentes ao terreno e de redução da fragmentação das retas remanescentes.

Para a eliminação de retas pertencentes ao terreno é necessário detectar quais as retas que pertencem ao terreno, associando a essas retas dois parâmetros: a altura média e o erro de registro médio. Para tanto, torna-se necessário determinar para cada pixel da imagem um valor de altura e erro de registro. Esses valores são obtidos a partir da geração de uma imagem de altura e outra de erro de registro (Figura 3.5).




Figura 3.5 – Fluxograma do método utilizado para a determinação da altura e erro de registro para cada pixel da imagem.

Como pode ser observado (Figura 3.5), tem-se como dados de entrada para a metodologia proposta, uma nuvem de pontos LASER pertencente à área de estudo, as precisões dos pontos LASER e a respectiva MVC dos parâmetros de orientação da imagem, adquirida no processo de resseção espacial e a partir das variâncias dos pontos LASER, conforme visto na Subseção A.3 do Apêndice A. Para adquirir o valor de altura e erro de registro para cada pixel da imagem é necessário, inicialmente, transformar as coordenadas 3D dos pontos LASER em coordenadas de imagem (C, L), sendo esse processo realizado através de técnicas fotogramétricas descritas brevemente na Subseção A.2 do Apêndice A. Assim, ao final desse processo todas as coordenadas estarão no espaço-imagem e, além disso, para cada par de coordenadas estará associado um valor de altura (Z) do ponto correspondente ao terreno. O próximo passo consiste em, a partir desses pontos projetados, interpolar os valores de altura para cada pixel da imagem. Já para o cálculo do erro de registro, o procedimento utilizado é a propagação de variância-covariância aplicada às equações que transformam um ponto do terreno (X, Y, Z) em coordenadas imagem (C, L). O valor do erro de registro é obtido a partir das variâncias nas coordenadas do ponto projetado na imagem, utilizando a Equação 3.1:

$$e_{registro} = \sqrt{\sigma_C^2 + \sigma_L^2} \quad (3.1)$$

Ainda, foi considerada a incerteza esperada na definição de descontinuidades através de uma tolerância no sigma resultante (Equação 3.1) igual a $4 \cdot e_{registro}$.

Esse processo será aplicado para toda a nuvem de pontos LASER, o que resultará em valores de erro de registro para cada par de coordenadas de imagem (C, L) relacionadas com esses pontos. Em seguida, aplica-se um método de interpolação, para assim, obter para cada pixel da imagem o erro de registro. Vale lembrar que, tanto para a interpolação das alturas quanto para a interpolação do erro de registro é utilizado o método de interpolação vizinho mais próximo.

Com esses dois parâmetros calculados, são verificadas as retas com alturas compatíveis ao terreno, através da comparação da altura média da reta com a altura média do edifício, obtida do poliedro do edifício, e são eliminadas as que a distância média ao edifício forem maior que o erro de registro médio do local.

O próximo passo consiste em detectar e conectar as retas próximas e colineares, possibilitando a redução da fragmentação das retas remanescentes. As retas pertencentes ao terreno devem ser eliminadas primeiro, uma vez que este procedimento possibilita reduzir o espaço de fusão e as possíveis falhas.

Para a redução de fragmentação o método a ser utilizado é a fusão de retas colineares baseada em regras perceptuais, descritas na Subseção 2.6 (Agrupamento perceptual). Para um melhor entendimento da situação pode ser observada a Figura 3.6.




Figura 3.6 – Condição de colinearidade e proximidade.

Para a fusão das retas leva-se em conta propriedades como a colinearidade e a proximidade. Para tanto, é necessário que os valores de θ e d (Equação 3.4) sejam próximos de 0 (zero). Isto implica na seleção de limiares adequados para que duas retas sejam consideradas colineares. Outra possibilidade a ser avaliada é a combinação dos três parâmetros acima numa função objetiva e resolvê-la para encontrar as possíveis combinações de retas colineares.

$$d = \frac{d_1 + d_2}{2} \quad (3.4)$$

Os elementos d_1 e d_2 (Equação 3.4), como pode ser visto na Figura 3.6, são distâncias entre o ponto final de uma das retas em relação a outra reta. Ambos os pontos envolvidos são as extremidades mais próximas das duas retas.

Uma vez que as retas atendam as condições impostas, essas são fundidas. Dessa forma, os lados de contornos e cumeeiras que possuam lacunas nas quais o processo de extração falhou, são reconstruídos. Novos segmentos de lados de contorno e cumeeiras são gerados, preenchendo as lacunas remanescentes.

Na sequência, tendo por base as retas LASER projetadas, são eliminadas as retas menores que 15% em relação a sua referência e as que diferem muito em orientação (por exemplo, acima de 20°).

Esse pré-processamento descrito permite a detecção de retas imagem candidatas a representar lados de contorno e cumeeiras que compõem um telhado de edifício. Como esse processo é aplicado individualmente para cada lado de contorno e cumeeira com o uso das retas LASER projetadas, ao final, sabe-se especificamente quais retas imagem são candidatas a representar cada lado de contorno e cumeeira e suas quantidades.

3.2.2 Formulação da Função de Energia

A função de energia utilizada nesse trabalho está associada a cinco termos de energia, dos quais três foram propostos em DAL POZ et al. (2009) e dois propostos nesse

trabalho como aperfeiçoamento. A seguir os cinco termos de energia que compõem a função de energia são apresentados.

As feições retas extraídas na etapa de pré-processamento são usadas para construir um modelo MRF expressando formas específicas de telhados de edifícios, com referência nos polígonos obtidos da projeção dos poliedros 3D de telhados. A função de energia é definida de forma que cada reta é associada com uma variável randômica (x_i), que assume valores binários de acordo com a regra especificada na Expressão 3.1 (DAL POZ et al., 2009).

$$x_i = \begin{cases} 1 & \text{se e somente se a } i\text{ésima feição reta pertencer ao telhado} \\ 0 & \text{caso contrário} \end{cases} \quad (3.1)$$

Essa regra (Expressão 3.1) dá origem a um vetor aleatório n-dimensional, em que n é o número de retas. Esse vetor randômico é a incógnita a ser determinada no processo de otimização. Em teoria, o espaço de busca possui 2^n combinações a serem consideradas no cálculo do mínimo global da função de energia (DAL POZ et al., 2009).

Para um melhor entendimento da função de energia, no que diz respeito à definição do sistema de vizinhança, primeiro é necessário definir duas métricas, que são a métrica de proximidade e métrica de orientação. Essas métricas baseiam-se nos elementos geométricos apresentados na Figura 3.7 (DAL POZ et al., 2009).




Figura 3.7 – Elementos Geométricos para a definição das métricas de proximidade e de orientação.
(Fonte: DAL POZ et al., 2009)

A métrica de proximidade é definida para duas retas F_i e F_j , da forma mostrada na Equação 3.5.

$$P(i, j) = \frac{1}{2} (d_i^1 + d_i^2 + d_j^1 + d_j^2) \quad (3.5)$$

em que, d_i^1 e d_i^2 são as distâncias entre pontos extremos da reta F_i e a reta projetada mais próxima de F_i ; e d_j^1 e d_j^2 são as distâncias entre pontos extremos da reta F_j e a reta projetada mais próxima de F_j .

A Equação 3.5 baseia-se no princípio de que as retas que estão de alguma forma inter-relacionadas e próximas entre si, são percebidas como uma unidade. Na situação em questão, a unidade é o contorno de telhado de referência, ou seja, o contorno de telhado projetado. Essa Equação (Equação 3.5) é assim uma medida indireta de proximidade entre F_i e F_j , uma vez que explicita a proximidade entre um par de retas e o contorno 3D do telhado. Dessa forma, pode-se interpretar que se F_i e F_j estão próximas da unidade, as retas estão próximas também. É fácil verificar que as seguintes propriedades ocorrem: $P(i, j) \geq 0$ e

$P(i, j) = P(j, i)$. Em particular, $P(i, j) = 0$ se ambas as retas (F_i e F_j) superpõem aos respectivos lados do contorno 3D de telhado projetado (DAL POZ et al., 2009).

A métrica de orientação é definida com base na função sigmóide (Equação 3.6) e segue o mesmo princípio da métrica de proximidade.

$$s_{\theta} = \frac{2}{1 + \exp[-\beta \cdot (\theta - \theta_0)^2]} - 1 \quad (3.6)$$

em que, $\theta = \theta_i + \theta_j$, θ_i é o ângulo entre a reta F_i e a reta projetada mais próxima dela; θ_j é o ângulo entre a reta F_j e a reta projetada mais próxima dela, β é uma constante positiva; θ_0 é o valor ótimo (0° ou 180°) do parâmetro θ (DAL POZ et al., 2009).




Figura 3.8 – Função sigmóide para $\beta = 1$ e $\beta = 0,001$.
(Fonte: DAL POZ et al., 2009)

Essa função (Equação 3.6) tem algumas propriedades importantes (Figura 3.8), como: apenas um ponto de mínimo em $\theta = \theta_0$; varia no intervalo $[0, 1]$; é simétrica em relação ao valor de $\theta = \theta_0$; e a constante β pode ser usada para controlar a forma da função sigmóide, quanto maior esse parâmetro, maior será a penalização dos desvios entre θ e θ_0 (DAL POZ et al., 2009).

A função de energia $U(x)$ é formulada baseada em cinco termos de energia. O primeiro termo é definido com base em uma clique de primeira ordem e tem por finalidade favorecer retas longas com referência a reta projetada mais próxima. Esse primeiro termo $U_1(x)$ é definido na Equação 3.7.

$$U_1(x) = \sum_{i=1}^n x_i \frac{L_{F_i}^L}{L_{F_i}} \quad (3.7)$$

em que, n é o número de retas extraídas da imagem; $L_{F_i}^L$ é o comprimento da reta projetada mais próxima da i -ésima reta extraída da imagem (F_i); L_{F_i} é o comprimento da i -ésima reta extraída da imagem (F_i) (DAL POZ et al., 2009).

O segundo termo da função de energia tem por base um clique de segunda ordem e objetiva favorecer as retas mais próximas do contorno de telhado projetado. Esse termo de energia é chamado termo de proximidade e é dado a seguir (Equação 3.8) (DAL POZ et al., 2009).

$$U_2(x) = \sum_{i=1}^n \sum_{j|j \in N_i} x_i \cdot x_j \cdot P(i, j) \quad (3.8)$$

O terceiro termo, assim como o anterior, é baseado em uma clique de segunda ordem e tem por finalidade favorecer retas com orientações similares aos lados de contorno de telhado projetados. Esse termo é chamado de termo de orientação e é apresentado a seguir (Equação 3.9) (DAL POZ et al., 2009).

$$U_3(x) = \sum_{i=1}^n \sum_{j|j \in N_i} x_i \cdot x_j \cdot S_\theta(i, j) \quad (3.9)$$

A função de energia proposta em Dal Poz et al. (2009) apresenta três termos de energia, os quais referem-se a propriedades de comprimento (Equação 3.7), proximidade (Equação 3.8) e orientação (Equação 3.9) das retas extraídas da imagem, com a aplicação da técnica de pré-processamento, com referência as retas resultantes da projeção de contornos 3D de telhados, que foram extraídas dos dados LASER. Assim, a equação de energia é formulada em Dal Poz et al.(2009) da seguinte maneira:

$$U(x) = \alpha_1 \cdot U_1(x) + \alpha_2 \cdot U_2(x) + \alpha_3 \cdot U_3(x) \quad (3.10)$$

em que, α_1 , α_2 e α_3 são constantes positivas e a soma delas é igual a 1.

Como aperfeiçoamento na função de energia, esse trabalho apresenta a inclusão de dois novos termos de energia, que são: a injunção de retangularidade e a injunção de quina.

A injunção de retangularidade é baseada em um clique de segunda ordem e entra como o quarto termo na equação de energia e é dada pela Equação 3.11. Como os contornos de telhados são compostos por retas adjacentes aproximadamente ortogonais ou paralelas, o correspondente termo de energia pode ser expresso na forma,

$$U_4(x) = \sum_{i=1}^n \sum_{j|j \in N_i} x_i \cdot x_j \cdot |\sin(2\alpha_{ij})| \quad (3.11)$$

em que, α_{ij} é o ângulo entre as retas F_i e F_j .

Essa injunção trabalha com a comparação de pares de retas extraídas da imagem, na verificação da ortogonalidade ou do paralelismo, isto é, $\sin(2 \times 0^\circ) = \sin(2 \times 90^\circ) = 0$.

A injunção de quina deve beneficiar pares de retas que se interceptam mais proximamente de quinas em 90° . Esse princípio pode ser matematicamente representado na forma,

$$U_5(x) = \sum_{i=1}^n \sum_{j|j \in N_i} x_i \cdot x_j \cdot D_{ij} \cdot \cos(\lambda_{ij}) \quad (3.12)$$

em que, D_{ij} é a distância entre o ponto de intersecção entre as retas F_i e F_j e a quina (q_{ij}) mais próxima detectada na imagem e λ_{ij} é o ângulo entre as bordas incidentes na quina q_{ij} .

A detecção de quinas na imagem é feita pelo detector de Harris, com o uso da biblioteca de classes C/C++ Halcon da MVTec. Nesse processo é adotada a estratégia de aplicar o detector em recortes da imagem que possuam as quinas do telhado de edifício. Para tanto, são utilizadas as projeções na imagem dos vértices dos lados de contorno do poliedro representativo do telhado do edifício que foi extraído dos dados LASER. Dessa maneira, é possível reduzir o espaço de busca (Figura 3.9, quadrado vermelho).




Figura 3.9 - Quinas detectadas, exemplo de uma janela de busca.

Por fim, a equação de energia é formulada como,

$$U(x) = \alpha_1.U_1(x) + \alpha_2.U_2(x) + \alpha_3.U_3(x) + \alpha_4.U_4(x) + \alpha_5.U_5(x) \quad (3.13)$$

em que, α_1 , α_2 , α_3 , α_4 e α_5 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.

3.2.3 Integração da estrutura de cumeeira

No trabalho desenvolvido em Dal Poz et al. (2009), as estruturas de cumeeiras de telhados de edifício não foram integradas no processo de otimização para evitar a alta dimensionalidade do espaço de busca nos casos envolvendo edifícios mais complexos. Nesse trabalho, essas estruturas são integradas.

Nesse processo o quarto e o quinto termo de energia devem ser aplicados apenas para retas candidatas a representar lados de contornos de telhados. Para tanto, deve-se conhecer a priori quais são as retas candidatas a representar lados de contornos e cumeeiras.

Esse conhecimento a priori é facilmente adquirido, uma vez que o pré-processamento aplicado permite saber especificamente quais retas imagem são candidatas a representar cada lado de contorno e cumeeira e, também, através da organização do arquivo de entrada que contem as retas do poliedro representativo de telhado de edifício, que foi extraído dos dados LASER, é possível saber quais retas projetadas representam lados de contorno e quais representam cumeeiras.

3.2.4 Otimização da função de energia usando AG

Nesse capítulo (Subseção 3.2.2), foi mostrado que 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.

O primeiro passo para aplicar esse método de otimização consiste em inicializar a população. Nessa etapa, deve-se considerar a heurística de unicidade, ou seja, cada lado de contorno e cumeeira possui uma única correspondência. Para um melhor entendimento é apresentado um exemplo ilustrativo (Figura 3.10).




Figura 3.10 – Exemplo. (a) Ilustração de um telhado; (b) retas extraídas da imagem.

Na Figura 3.10(a) tem-se a ilustração de uma situação hipotética de um telhado de edifício que é composto por quatro lados de contorno e cinco cumeeiras. A Figura 3.10(b) ilustra o resultado obtido a partir do pré-processamento, ou seja, as retas candidatas a

representar cada lado de contorno e cumeeira que foram extraídas da imagem. Como pode ser observado (Figura 3.10(b)), alguns lados de contorno e cumeeiras possuem mais de uma reta candidata. Tem-se que os lados de contorno 1 e 2 e as cumeeiras 6 e 7 possuem duas retas candidatas, os lados de contorno 3 e 4 possuem três retas candidatas e as cumeeiras 5, 8 e 9 apenas uma candidata.

A população inicial de n indivíduos é gerada atendendo a heurística de unicidade e para cada indivíduo da população a reta candidata a representar cada lado de contorno e cumeeira é selecionada aleatoriamente. Por exemplo, na Figura 3.11, tem-se vetores binários (1, 2,..., n) (cromossomos), em que cada célula (gene) representa uma reta candidata. Se determinada reta candidata a representar um lado de contorno ou cumeeira for selecionada, a variável aleatória associada com essa reta (gene) recebe o valor 1 e as demais retas candidatas aquele lado de contorno ou cumeeira recebe o valor 0. Assim, cada cromossomo dessa população inicial possui uma configuração de retas representativas de lados de contornos e cumeeiras a ser testada.

	1		2		3			4			5	6		7		8	9
Retas candidatas	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
Cromossomos																	
1	1	0	0	1	0	1	0	1	0	0	1	1	0	0	1	1	1
2	1	0	1	0	1	0	0	1	0	0	1	1	0	1	0	1	1
3	0	1	1	0	0	0	1	0	1	0	1	0	1	1	0	1	1
n	0	1	0	1	0	0	1	0	0	1	1	0	1	0	1	1	1

Figura 3.11 – População inicial.

No problema em questão, sempre é considerado que a reta correta está entre as candidatas e no caso de lados de contornos e cumeeiras não possuírem candidatas, as retas projetadas correspondentes são integradas ao processo.

Dessa forma, cada um dos indivíduos da população (configurações de retas extraídas da imagem) representa uma possível solução para o problema, ou seja, um ponto no espaço de soluções.

Gerada a população inicial, em seguida, é calculada a aptidão de cada cromossomo da população com o uso da função desempenho. A função desempenho corresponde ao inverso da função de energia. Essa função é utilizada, pois o AG sempre busca por indivíduos mais aptos, ou seja, busca maximizar a função.

A seleção dos cromossomos tem por base o retorno da função desempenho. 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 $n - 1$ 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. Considerando ainda a heurística de unicidade, o ponto de corte (Figura 3.12 – seta) selecionado de forma aleatória deve corresponder a um dos lados de contorno ou cumeeiras (Figura 3.12).



	1		2		3			4			5	6		7		8	9
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
Dupla selecionada																	
1	1	0	0	1	0	1	0	1	0	0	1	1	0	0	1	1	1
2	1	0	1	0	1	0	0	1	0	0	1	1	0	1	0	1	1
Cruzamento																	
1'	1	0	0	1	0	1	0	1	0	0	1	1	0	1	0	1	1
2'	1	0	1	0	1	0	0	1	0	0	1	1	0	0	1	1	1

Figura 3.12 – Cruzamento.

São formados a partir de dois indivíduos outros dois novos. 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 (Figura 3.12).

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. Na mutação, também deve ser considerada a heurística de unicidade. O ponto de mutação é selecionado aleatoriamente, da mesma maneira que o ponto de corte e é realizada a mutação por inversão (Figura 3.13).



	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
Cromossomo																	
1	1	0	0	1	0	1	0	1	0	0	1	1	0	1	0	1	1
Mutação																	
1	1	0	1	0	0	1	0	1	0	0	1	1	0	1	0	1	1

Figura 3.13 – Mutação.

A mutação é realizada com uma determinada probabilidade de mutação, normalmente bastante baixa.

É realizado, em seguida, o cálculo da aptidão de cada cromossomo dessa nova população e é realizado todo o procedimento novamente.

Esse processo repete-se até que se atinja um critério de parada pré-estabelecido. Nesse trabalho utiliza-se um valor limite de iterações para término do processo. O resultado será a escolha do indivíduo que ao final possuir a maior aptidão, ou seja, a configuração de retas selecionadas é estabelecida pelo cromossomo mais apto encontrado durante o processo de otimização por AG.

3.2.5 Complementação dos agrupamentos de retas

O método de otimização gera para cada telhado de edifício um agrupamento de retas. Essas retas, normalmente, apresentam-se desconexas, conforme pode-se observar no exemplo ilustrativo na Figura 3.14 (a). Para realizar a complementação do agrupamento de retas é necessário utilizar a topologia do correspondente polígono projetado (por exemplo, polígono azul na Figura 3.14 (b)) para selecionar as retas adjacentes.




Figura 3.14 – Ilustração da estratégia de complementação. (a) agrupamento das retas resultantes da otimização da função de energia; (b) poliedro 3D de telhado projetado e agrupamento das retas resultantes da otimização da função de energia; e (c) polígono representando o telhado refinado.

O exemplo de telhado de edifício apresentado na Figura 3.14 ilustra duas situações possíveis com relação ao número de retas que se encontram em um único vértice do telhado.

No caso mais simples, em que se deve complementar o espaço entre duas retas, basta determinar o vértice do polígono através da intersecção de retas. Já quando o problema envolve determinar um ponto comum a três retas é realizado o ajuste de um ponto as três retas com o uso da equação da reta e do método paramétrico.

4 RESULTADOS EXPERIMENTAIS

4.1 Considerações Iniciais

Esse capítulo tem por finalidade apresentar os resultados obtidos a partir do método desenvolvido nesse trabalho.

Os resultados experimentais foram analisados visual e numericamente, tendo por base comparações entre os telhados (contorno e cumeeiras) extraídos computacionalmente e os correspondentes telhados obtidos visualmente na imagem aérea. Foram calculadas e analisadas, também, as porcentagens de lados de contorno e cumeeiras não extraídos (falsos negativos), extraídos incorretamente (falsos positivos) e corretamente (acertos). Adicionalmente, foi calculado o parâmetro RMSE (raiz do erro médio quadrático) (Equação 4.1). Esses parâmetros estão relacionados com a qualidade geométrica de cada reta, presente no resultado.

$$RMSE = \sqrt{\frac{(L_R - L)^2 + (C_R - C)^2}{n}} \quad (4.1)$$

em que n é o número de vértices de contorno que compõem o telhado; L_R e C_R são valores de coordenadas linha e coluna de cada vértice, respectivamente, obtidos visualmente na imagem e considerados como valores de referência e; L e C são os valores de coordenadas linha e coluna para cada vértice, respectivamente, obtidos pelo método proposto.

Ao final foi realizada a avaliação individual dos impactos causados nos resultados ao utilizar as injunções de retangularidade e quina e de se integrar a estrutura de cumeeira. Também foram realizadas comparações entre a metodologia modificada nesse trabalho e a metodologia original desenvolvida em Dal Poz et al. (2009).

4.2 Limiares e parâmetros utilizados

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

- Precisão dos pontos LASER: altimetria 15 cm e planimetria 48 cm;
- Tolerâncias para fusão de retas colineares e próximas $\theta = 9^\circ$ e $d = 3$ pixels;
- Constante para controlar a forma da função sigmoide $\beta = 20$; e
- Pesos $\alpha_1 = \alpha_2 = \alpha_3 = \alpha_4 = \alpha_5 = 0,2$. Nesse trabalho, foram considerados pesos iguais para todos os termos de energia.
- Probabilidade de cruzamento, $pc = 0,7$, e mutação, $pm = 0,01$.

Vale lembrar que esses parâmetros e limiares foram mantidos iguais para todos os experimentos.

Também foram estabelecidos parâmetros relacionados ao tamanho da população gerada aleatoriamente para inicialização do AG e número de gerações (iterações) como critério de parada do método de otimização. A escolha desses valores dependeu fundamentalmente da quantidade de retas projetadas que compõem o telhado de edifício a ser testado, bem como, da quantidade de retas candidatas extraídas da imagem. Esses valores são específicos para cada experimento e serão apresentados junto aos resultados.

4.3 Resultados e análise

A seguir serão descritos e discutidos os resultados obtidos pela avaliação do método desenvolvido. Para demonstrar o potencial desse método foram realizados experimentos com diferentes telhados de edifícios.

Nesse trabalho foram utilizados nos experimentos realizados seis poliedros 3D de telhados de edifícios extraídos dos dados de varredura a LASER, dos quais os três primeiros foram gerados de forma semi-automática pelo método desenvolvido em Correia (2010), o quarto poliedro utilizado foi gerado automaticamente e disponibilizado pelo Prof. Ayman Habib e os dois contornos 3D telhado foram gerados automaticamente pelo método proposto em Yano et al. (2012).

O primeiro edifício teste possui um telhado de quatro águas composto por quatro lados de contorno e cinco cumeeiras (Figura 4.1). A Figura 4.1(a) mostra o poliedro 3D do telhado projetado e sobreposto na imagem. Pode-se notar claramente que a projeção não apresentou bons resultados com os lados de contorno 3 e 4 e a cumeeira 8 e ainda erros de registro são visíveis nos demais lados de contorno e cumeeiras.




Figura 4.1 – Edifício teste 1. (a) telhado projetado; (b) retas extraídas da imagem; (c) resultado da otimização da função de energia; e (d) resultado após aplicação das regras de complementação.

Na Figura 4.1 (b) estão sobrepostas dezesseis retas extraídas da imagem através das técnicas de pré-processamento propostas. Essas retas são candidatas a substituir os lados de contorno e cumeeiras projetados do telhado. Pode-se notar nessa figura (Figura 4.1 (b)) que o lado de contorno 1 e as cumeeiras 6 e 8 possuem apenas uma reta candidata, os lados de contorno 2 e 4 possuem duas retas candidatas e o lado de contorno 3 e as cumeeiras 5 e 9 possuem três retas candidatas. Ainda nessa figura, deve-se destacar que a reta projetada representando a cumeeira 7 não apresentou candidatas e por esse motivo, como previsto no método, na falta de retas candidatas, a própria reta projetada é usada no processo de otimização.

A Figura 4.1 (c) apresenta o resultado obtido no processo de otimização. Nesse experimento, foram gerados aleatoriamente quinze ($n = 15$) indivíduos (cromossomos) para a inicialização do AG, também, foi considerado como critério de parada o valor igual 20 gerações. Verifica-se que a única falha encontrada está relacionada à reta projetada 4. Essa reta apresentava duas candidatas a sua substituição sendo que uma delas representava melhor o lado de contorno em questão. No entanto, no processo de otimização a reta mantida não é a correta. Sendo assim, esse telhado de edifício é composto por nove retas das quais sete estão corretas (77,8%), uma (11,1%) está incorreta (falsa positiva) e uma (11,1%) não possui correspondência. A falha apresentada (falsa positiva) pode ser justificada, pois a reta conservada atende melhor as condições impostas pela função de energia. Verifica-se que essa reta possui orientação bastante similar e, também, está bastante próxima à reta de referência.

Na Figura 4.1 (d) pode ser observado o resultado obtido após a aplicação da estratégia proposta de complementação. Oito retas de lados de contorno e cumeeiras de telhado projetado foram substituídas pelas correspondentes retas selecionadas via otimização da função de energia. Essas retas são potencialmente melhores que as correspondentes retas projetadas. A reta projetada 7 foi mantida devido a ausência de candidatas. O telhado de edifício refinado no espaço-imagem é determinado através do agrupamento de retas resultante das regras acima, juntamente com a topologia do telhado projetado. O telhado obtido é melhor que o telhado projetado, pois a maioria de seus lados de contorno e cumeeira representa de forma mais fiel os respectivos lados de contornos e cumeeiras. O valor do parâmetro RMSE é igual a 2,06 *pixels*.

A Figura 4.2 (a) apresenta o segundo poliedro 3D de telhado, sobreposto em uma subimagem que contém o segundo edifício teste. Pode-se observar que a projeção não apresentou bons resultados para praticamente todos lados de contorno e cumeeiras. Além disso, próximo a reta 5 o telhado de edifício possui detalhes não representados. Isso ocorre devido a erros na geração do modelo 3D do edifício a partir de dados de varredura a LASER.

Na Figura 4.2 (b) estão sobrepostas dezoito retas extraídas da imagem através das técnicas de pré-processamento propostas. Os lados de contorno 1, 2, 3 e 6 e a cumeeira 9 possuem um reta candidata, os lados de contorno 4 e 5 e as cumeeiras 7, 8 e 10 possuem duas retas candidatas e a cumeeira 11 possui três retas candidatas. Destaca-se, nesse experimento a dificuldade de se extrair retas completas nessa imagem.




Figura 4.2 – Edifício teste 2. (a) telhado projetado; (b) retas extraídas da imagem; (c) resultado da otimização da função de energia; e (d) resultado após aplicação das regras de complementação.

Nesse experimento, foram gerados aleatoriamente quinze ($n = 15$) cromossomos para a inicialização do AG, também, foi considerado como critério de parada o valor igual 20 gerações. As retas selecionadas, via método de otimização AG, como pertencentes ao telhado do edifício podem ser observadas na Figura 4.2 (c). Nota-se que a

única falha encontrada está relacionada à reta projetada 5. Essa reta apresentava duas candidatas à sua substituição, conforme dito anteriormente, sendo que uma delas representava de forma fiel o lado de contorno em questão. No entanto, no processo de otimização a reta mantida não é a correta. Sendo assim, esse telhado de edifício é composto por onze retas das quais dez estão corretas (91%) e uma (9%) está incorreta (falsa positiva). Essa falha pode ser justificada através de dois motivos: 1) o pré-processamento falhou na eliminação da reta que parece pertencer ao terreno; e 2) devido aos erros na geração do modelo 3D a reta que melhor atende as condições impostas pela função de energia é a incorreta. Quando se trata dos termos de energia de orientação e retangularidade ambas as retas respondem de forma similar, no entanto, para os termos de comprimento, proximidade e quina a reta incorreta é favorecida. A injeção de quina favoreceu a reta incorreta, pois dentre as quinas detectadas na imagem, justamente pelo fato dos vértices do telhado para esse lado de contorno não serem representados por apenas uma quina (presença de detalhes omitidos pelo polígono projetado), não existia uma quina que favorecia o agrupamento da reta correta, ao contrário da situação para a reta incorreta.

Na Figura 4.2 (d) é apresentado o resultado obtido com a complementação do agrupamento de retas. Todas as onze retas foram substituídas pelas correspondentes retas selecionadas via otimização da função de energia. Assim, para esse procedimento foi necessário somente usar a topologia do polígono projetado. O parâmetro RMSE é igual a 3,34 *pixels*.

A Figura 4.3 mostra o terceiro edifício teste utilizado. Na Figura 4.3 (a) o poliedro 3D do telhado do edifício está sobreposto na imagem. Nota-se que o polígono resultante tem um deslocamento bastante acentuado para a direita.

Para esse telhado de edifício foram extraídas da imagem dezoito retas. Essas retas são candidatas a substituir os lados de contorno e cumeeiras projetados e sua distribuição ao redor do telhado projetado é a seguinte: todos os quatro lados de contorno possuem duas retas candidatas, duas cumeeiras possuem uma reta candidata, outras duas cumeeiras possuem duas retas candidatas e uma cumeeira possui quatro retas candidatas (Figura 4.3(b)).




Figura 4.3 – Edifício teste 3. (a) telhado projetado; (b) retas extraídas da imagem; (c) resultado da otimização da função de energia; e (d) resultado após aplicação das regras de complementação.

De modo semelhante aos experimentos anteriores, o tamanho da população inicial do AG é igual a quinze ($n = 15$) e o número de gerações é igual a 20.

A Figura 4.3 (c) apresenta o resultado obtido no processo de otimização. Nota-se que a função de energia proposta combinada com o método de otimização AG apresentou um bom resultado, uma vez que dentre as retas candidatas optou pelas que melhor representavam o telhado de edifício. Sendo assim, esse telhado de edifício é composto por nove retas das quais todas estão corretas (100%).

Na Figura 4.3 (d) é apresentado o resultado obtido com a complementação do agrupamento de retas. Todas as nove retas foram substituídas pelas correspondentes retas selecionadas via otimização da função de energia. Assim, para esse procedimento foi necessário somente usar a topologia do polígono projetado. O parâmetro RMSE é igual a 2,06 *pixels*, que mostra uma boa qualidade geométrica do polígono que representa o telhado do edifício refinado.

O próximo edifício teste possui a forma de um ‘E’ invertido e é definido por dezenove retas de contorno e vinte retas de cumeeiras. A Figura 4.4 (a) mostra os lados de contorno e cumeeiras de telhado 3D projetado e sobreposto na imagem. De um modo geral, o polígono resultante está relativamente próximo aos lados de contorno e cumeeiras do telhado de edifício, uma vez que o erro de registro máximo é de cerca de 5 pixels. O maior erro de registro pode ser observado na reta 5 do polígono. Também, pode-se observar que as retas 13 e 15 não representam corretamente os detalhes do telhado e há uma pequena falha, no poliedro 3D gerado, próxima as cumeeiras 20, 23, 38 e 39, nesse caso, também, o detalhe no telhado do edifício não foi representado.




Figura 4.4 – Edifício teste 4. (a) telhado projetado; (b) retas extraídas da imagem; (c) resultado da otimização da função de energia; e (d) resultado após aplicação das regras de complementação.

Na Figura 4.4 (b) estão sobrepostas trinta e nove retas extraídas da imagem através das técnicas de pré-processamento. Essas retas são candidatas a substituir os lados de contorno e cumeeiras projetados do telhado. Sua distribuição em torno do telhado projetado é a seguinte: trinta e uma retas projetadas possuem apenas uma reta candidata, quatro retas projetadas possuem duas retas candidatas e quatro retas projetadas não possuem candidatas. Ainda nessa figura, deve-se destacar que as retas projetadas representando os lados de contorno 11, 13, 15 e 17 não apresentaram candidatas e por esse motivo, como previsto no

método, na falta de retas candidatas, a própria reta projetada é considerada no processo de otimização. Nota-se nesse resultado que as técnicas de pré-processamento aplicado foram eficientes na filtragem de detalhes irrelevantes.

Nesse experimento, o tamanho da população inicial gerada aleatoriamente pelo o processo de otimização AG é igual a 25 e o número de gerações é igual a 40. As retas selecionadas como lados de contorno e cumeeiras podem ser observadas na Figura 4.4 (c). O método proposto identificou 34 (87,2%) retas corretas, uma (2,6%) incorreta (falsa positiva) e quatro (10,2%) não possuíam correspondência. A reta incorreta está relacionada com a presença de somente de uma candidata inválida.

A Figura 4.4 (d) mostra o resultado obtido com a aplicação da técnica de complementação do agrupamento de retas. Trinta e cinco retas de lados de contorno e cumeeiras de telhado projetado foram substituídas pelas correspondentes retas selecionadas via otimização da função de energia. As retas projetadas 11, 13, 15 e 17 foram mantidas devido à ausência de candidatas entre as retas extraídas pelas técnicas de pré-processamento. O método proposto não foi capaz de fornecer resultados satisfatórios ao longo de três lados de contorno do polígono refinado. Isso devido a ausência de candidata válida para a reta projetada 5 e, também, pela pobre descrição dos detalhes do telhado 3D ao longo dos lados 13 e 15. Observa-se, também, que houve um problema na complementação do agrupamento de retas próximo as cumeeiras 20, 23, 38 e 39, isso porque nesse local, conforme dito anteriormente, houve uma falha no processo de geração do poliedro 3D do telhado. Deve-se destacar que, o método proposto objetiva refinar os lados de contornos e cumeeiras do telhado do edifício com referência no polígono projetado, ou seja, para cada reta projetada busca-se encontrar uma reta correspondente extraída da imagem que melhor descreva o respectivo lado de contorno ou cumeeira. Assim, problemas com relação a falta dessa reta projetada de referência não são corrigidos. O RMSE é igual a 1,47 *pixels*, que mostra uma excelente qualidade geométrica do contorno de telhado obtido.

Na sequência, serão apresentados alguns resultados obtidos utilizando somente o contorno de telhado 3D do edifício.

Na Figura 4.5 (a) pode-se observar o contorno de telhado 3D projetado e sobreposto. Nota-se claramente que a projeção não apresentou bons resultados para os lados 1, 4 e 5 e erros de registro são visíveis nos demais lados.

Na Figura 4.5 (b) estão sobrepostas quatorze retas extraídas da imagem através das técnicas de pré-processamento propostas. A distribuição em torno das retas

projetadas é a seguinte: um lado possui uma reta candidata, três lados possuem duas retas candidatas, um lado possui três retas candidatas e um lado possui quatro retas candidatas.




Figura 4.5 – Edifício teste 5. (a) contorno de telhado projetado; (b) retas extraídas da imagem; (c) resultado da otimização da função de energia; e (d) resultado após aplicação das regras de complementação.

Nesse experimento, foram gerados aleatoriamente onze ($n = 11$) cromossomos para a inicialização do AG, também, foi considerado como critério de parada o valor igual 20 gerações. As retas selecionadas, via processo de otimização AG, como lados de contorno podem ser observadas na Figura 4.5 (c). Sendo assim, todas as retas foram selecionadas corretamente (100%).

Na Figura 4.3 (d) é apresentado o resultado obtido com a complementação do agrupamento de retas. Todas as seis retas foram substituídas pelas correspondentes retas selecionadas via otimização da função de energia. Assim, para esse procedimento foi necessário somente usar a topologia do polígono projetado. O parâmetro RMSE é igual a 4,79 *pixels*, que mostra que existem algumas retas que apresentam pequenos desvios com relação as bordas dos respectivos lados de contorno.

A Figura 4.6 mostra o último edifício teste utilizado. Na Figura 4.6 (a) o contorno 3D do telhado do edifício está sobreposto na imagem. Nota-se que, o polígono resultante não apresentou bons resultados para todos os seus lados.




Figura 4.6 – Edifício teste 6. (a) contorno de telhado projetado; (b) retas extraídas da imagem; (c) resultado da otimização da função de energia; e (d) resultado após aplicação das regras de complementação.

Na Figura 4.6 (b) estão projetadas cinco retas extraídas da imagem através das técnicas de pré-processamento propostas. Nota-se que o pré-processamento proposto foi capaz de filtrar detalhes irrelevantes. Assim, somente um de seus lados projetados (lado 3) apresentou duas retas candidatas e os demais somente uma reta candidata.

O problema a ser resolvido, pelo método de otimização, apresenta baixa complexidade, uma vez que era um problema bastante simples de se resolver. Foi estabelecido para este experimento o tamanho da população inicial igual a 5 ($n = 5$) e número de gerações igual a 3. Dessa forma, esse contorno de telhado de edifício é composto por quatro retas das quais todas estão corretas (100%).

Na Figura 4.6 (d) é mostrado o resultado obtido com a complementação do agrupamento de retas. As quatro retas projetadas foram substituídas pelas correspondentes retas selecionadas via otimização da função de energia. Assim, para esse procedimento foi

necessário somente usar a topologia do polígono projetado. O parâmetro RMSE é igual a 2,5 *pixels*.

- **Integração da estrutura de cumeeira**

Na imagem, alguns telhados de edifícios apresentam problemas relacionados à iluminação, como sombras e baixo contraste, presença de vegetação cobrindo parte do telhado, entre outros, o que dificulta a detecção de retas imagem ao longo dos lados de contorno e algumas vezes o resultado não corresponde corretamente aos detalhes do telhado do edifício. As cumeeiras por não sofrerem com as interferências externas tem uma detecção na imagem mais clara e limpa e em sua maioria corretas.

A contribuição da estrutura de cumeeiras está relacionada ao processo de agrupamento de retas do telhado de edifício (Subseção 3.2.5) ao final do processo, quando o problema envolve o ajuste de três retas a um ponto (uma reta corresponde à cumeeira e duas ao contorno). Em alguns casos, as retas ou uma das retas correspondentes ao contorno não delimitam corretamente os detalhes do telhado, nesse caso a reta correspondente à cumeeira, detectada de forma correta, pode melhorar a localização das retas que constituem o contorno. Para um melhor entendimento, observa-se a Figura 4.7.




Figura 4.7- Contribuição da estrutura de cumeeiras. (a) reta preservada no processo de otimização e; (b) resultado após o processo de agrupamento de retas

Por exemplo, nota-se que (Figura 4.7(a)) as retas representantes do contorno destacadas (retângulo vermelho) não delimitam muito bem os respectivos lados de contorno. Após o processo de agrupamento de retas, utilizando a cumeeira, observa-se uma melhor localização dos lados de contorno.

Deve-se destacar que, o aumento da complexidade do telhado de edifício proporcionado por essa inclusão não prejudicou o procedimento, uma vez que esse problema

foi contornado através da implementação do AG como método de otimização, e esse respondeu em todos os casos de forma bastante satisfatória.

- **Contribuição dos quarto e quinto termos de energia**

Os dois novos termos de energia implementados nesse trabalho, injeção de retangularidade e quina, tem por objetivo modelar matematicamente características relacionadas ao contorno do telhado de edifício. A injeção de retangularidade favorece o agrupamento de retas adjacentes aproximadamente ortogonais ou paralelas. E a injeção de quina beneficia retas que se interceptam em quinas em 90° .

O uso desses dois termos de energia permitiu integrar ao processo uma perspectiva de contexto. Anteriormente, os três termos de energia dependiam fundamentalmente das retas projetadas de referência. Com a inclusão desses dois novos termos, o processo de otimização deixou de depender somente do poliedro 3D de referência e passou a considerar o contexto. Assim, passaram a ser realizadas comparações entre retas extraídas da imagem considerando características próprias do objeto de interesse.

Em vários casos mostrados, o poliedro 3D do telhado de edifício não possui bons resultados para alguns de seus lados. Somente considerar na função de energia termos de proximidade, comprimento e orientação com relação as retas projetadas pode implicar escolhas erradas. Como é o caso do exemplo apresentado a seguir (Figura 4.8 (c)).




Figura 4.8- Exemplo relacionado a injeção de retangularidade e quina. (a) reta projetada; (b) retas extraídas da imagem; e (c) resultado do método original.

A Figura 4.8 (a) mostra a reta projetada representando um determinado lado de contorno. Essa reta encontra-se bastante deslocada do local onde deveria ser sua posição correta. Aplicado o pré-processamento proposto, para esse lado de contorno foram extraídas quatro retas imagem. Considerados somente os três primeiros termos da função de energia, a

reta que melhor se adequou a reta de referência, e que, dessa forma, foi selecionada no processo de otimização não está correta. Conforme mostrado em experimento anterior (Figura 4.5), considerando os dois novos termos de energia implementados nesse trabalho, o resultado encontrado foi superior. Nesse caso, comprova-se que com a aplicação do método proposto nesse trabalho foi possível suprir uma deficiência apresentada pelo método original quando as candidatas possuíam orientação e comprimento similares, no caso, a reta mais próxima era escolhida.

- **Uso do AG como método de otimização**

No método original é utilizado o algoritmo de otimização de força bruta com algumas heurísticas (DAL POZ et al., 2009). Apesar desse método fornecer a solução ótima, caso exista, o espaço de busca fica intratável computacionalmente quando o número de retas supera algumas dezenas.

Em Dal Poz et al. (2009), foi apresentado um exemplo hipotético de um edifício relativamente complexo com um contorno definido por 20 retas. Foi considerado que, as técnicas de pré-processamento propostas extraem de uma a três retas no entorno de cada lado do contorno de edifício projetado. Foi assumida, então, uma média de duas retas extraídas em torno de cada lado de contorno de telhado projetado ($n = 40$). Assim, tem-se que o número de configurações que necessita ser checado, para esse exemplo, considerando somente o método de força bruta sem as heurísticas é igual a $2^n = 1.099.511.627.776$. Considerando as heurísticas propostas (unicidade e número mínimo de correspondências esperadas (DAL POZ et al., 2009)), esse valor cai consideravelmente, no entanto não seria possível resolver com força bruta o problema do telhado de edifício 'E' invertido (Figura 4.4) (DAL POZ et al., 2009). Nesse sentido, o AG supriu essa necessidade e proporcionou como já dito, resultados bastante satisfatórios.

5 CONCLUSÃO

5.1 Considerações Finais

Nesse trabalho foi proposto um método para reconstruir contornos e cumeeiras de telhados de edifícios a partir de imagens aéreas de alta-resolução e poliedros representativos de edifícios extraídos de dados LASER. Nesse método buscou-se refinar geometricamente os telhados 3D extraídos dos dados de varredura a LASER com o uso de uma imagem aérea de alta-resolução. Uma descrição MRF para agrupamento de retas foi desenvolvida, assumindo que cada lado de contorno e cumeeira projetado está topologicamente correto e necessita somente de refinamento geométrico. O modelo MRF é formulado baseado em relações (de comprimento, proximidade e orientação) entre as retas extraídas da imagem e o polígono que representa o telhado de edifício projetado e, também, em injunções de retangularidade e quina. O agrupamento de retas é obtido através da otimização da função de energia associada à descrição MRF. O método de otimização utilizado nesse trabalho é o algoritmo genético. Em seguida, o agrupamento de retas obtido é complementado para formar um polígono completo, que representa de forma mais fiel o telhado. A topologia do telhado projetado é utilizada na reconstrução topológica do polígono refinado.

Para a avaliação do método proposto foram realizados experimentos com diferentes edifícios. Os resultados obtidos foram satisfatórios. Esse método foi capaz de fornecer polígonos de telhado de edifícios refinados em que a maioria de seus lados de contorno e cumeeira foram geometricamente melhorados.

O primeiro teste teve por base um telhado de edifício composto por quatro lados de contorno e cinco cumeeiras. O método proporcionou um polígono refinado melhorado geometricamente. O parâmetro RMSE é igual a 2,06 *pixels*. O segundo teste envolveu um telhado de edifício que possui seis lados de contorno e cinco cumeeiras. O poliedro 3D representando esse telhado possui falhas relacionadas a omissão de detalhes, o que acabou prejudicando um dos lados de seu contorno. O parâmetro de RMSE igual a 3,34 *pixels*. O terceiro teste proporcionou um resultado bastante satisfatório, o parâmetro de qualidade obteve o valor de 2,06 *pixels*. A combinação das retas selecionadas pelo processo

de otimização e a topologia do telhado projetado possibilitou a correta reconstrução do telhado de edifício. O quarto teste teve por base um telhado de edifício cuja a complexidade geométrica é bastante alta. Além disso, o baixo contraste das faces do telhado em relação às adjacências do edifício prejudicou a obtenção de retas com boa qualidade e, em um caso, não possível extrair a reta correta. Mesmo assim, a maior parte do polígono refinado foi geometricamente melhorada. O parâmetro RMSE obtido é igual a 1,47 *pixels*.

Também foram realizados dois testes com contornos 3D de telhados disponíveis. Ambos os testes apresentaram bons resultados. Os valores de RMSE foram de 4,79 *pixels* e 2,5 *pixels*, respectivamente, para ambos os testes.

Como já mencionado, esse trabalho propôs melhorias em uma metodologia preexistente. As principais modificações nessa metodologia foram: inclusão de dois novos termos de energia (injunção de retangularidade e quina) na função de energia, integração da estrutura de cumeeira e o uso do algoritmo genético como método de otimização.

A inclusão das injunções de retangularidade e quina teve por objetivo contribuir para melhores resultados para o contorno do telhado do edifício. O uso desses dois termos de energia permitiu integrar ao processo uma perspectiva de contexto. Anteriormente, os três termos de energia dependiam fundamentalmente das retas projetadas de referência. Esse aspecto é bastante interessante, pois como visto, alguns poliedros 3D de telhados extraídos de dados de varredura a LASER não apresentam bons resultados para alguns de seus lados e, em alguns casos, depender somente deles, como na metodologia original, causava uma deficiência em que quando as candidatas possuíam orientação e comprimento similares, a reta mais próxima era escolhida e, nem sempre estava correto. O método proposto foi capaz de suprir essa deficiência, conforme comprovado anteriormente.

A integração da estrutura de cumeeira, também, contribuiu positivamente no processo. Sabe-se que as cumeeiras sofrem menos com as interferências externas e, dessa forma, tem uma detecção na imagem mais clara e limpa e em sua maioria corretas.

O uso do algoritmo genético como método de otimização foi bastante satisfatório. Em todos os experimentos realizados não foram constatadas falhas produzidas por esse método. Deve-se destacar que a implementação do AG foi bastante simples e os resultados obtidos corresponderam a expectativa. Esse método, também, possui uma vantagem básica em relação ao método de força bruta, que é o tratamento de casos com alta dimensionalidade, caso do edifício em ‘E’ invertido.

5.2 Recomendações para Trabalhos Futuros

Algumas recomendações para melhorar o desempenho do método proposto, bem como facilitar a tarefa de extração, são citadas a seguir:

- Refinar a função de energia com conhecimentos relacionados a cor, sombras, entre outros, o que pode melhorá-la substancialmente; e
- Adaptar o Algoritmo Genético para lidar com situações em que a candidata correta não está entre as candidatas.

Recomenda-se, também, realizar mais experimentos com telhados de edifícios de maior complexidade e utilizar os resultados obtidos para refinar o poliedro LASER. Por fim, recomenda-se realizar testes com poliedros gerados com dados de varredura a LASER de diferentes densidades. Espera-se que esse método seja mais útil para poliedros gerados a partir de nuvens de pontos menos densas.

REFERÊNCIAS

AHOKAS, E.; KAARTINEN, H.; HYYPPÄ, J. A quality assessment of airborne laser scanner data. In: Workshop 3-D Reconstruction from Airborne Laserscanner 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.

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.

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

BEAUDET, P. Rotationally invariante image operations. In: International Joint Conference on Pattern Recognition, 1978, Kioto, Japão. **Proceedings...** p.579-583, 1978.

BLACHUT, T. J.; CHRZANOWSKI, A.; SAASTAMOINEN, T. J. **Urban surveying and mapping**. New York : Spring-Verlag, 1979, 372p.

BOAVENTURA NETTO, P. O. **Teoria e modelos de grafos**. E. Blücher, São Paulo, 249p, 1979.

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

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

CANNY, J. A Computational Approach to Edge Detection. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 8, n. 6, p. 679-698, 1986.

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.

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.

CORREIA, L. S. **Uma solução fotogramétrica para projetar lados de contornos de telhado extraídos de uma imagem aérea sobre um poliedro representando um edifício**. Presidente Prudente, 2010. Relatório de Iniciação Científica (FAPESP), FCT/UNESP, Campus de Presidente Prudente.

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

DAL POZ, A. P. **Extração automática da malha viária rural a partir de imagens de média e alta resoluções**. Relatório de Pesquisa, Processo FAPESP no. 2001/01168-5, 107p, 2002.

DAL POZ, A. P. **Integração de dados de LASER e de imagem para extração de contornos de telhados usando uma abordagem Bayesiana**. Relatório Científico, Processo no. 200167/2007-3, 2008.

DAL POZ, A. P. Extração automática de edifícios: Comparação de paradigmas e exemplos. In: XIV Simpósio Brasileiro de Sensoriamento Remoto, 2009b, Natal, Brasil. **Anais...**, 2009b, p. 5015-5022.

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, 2009.

DERICHE, R.; GIRAUDON, G. A computational approach for corner and vertex detection. **International Journal of Computer Vision**, v. 10, n. 2, p.101-124, 1993.

DO VALE, G. M. **Uso de técnicas de otimização e agrupamento hierárquico para a complementação automática da malha viária em regiões rurais a partir de imagens aéreas de média e alta resolução.** Presidente Prudente, 2007. Dissertação (doutorado) – Curso de Pós-Graduação em Ciências Cartográficas, FCT/UNESP.

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

FÖRSTNER, W. A feature based correspondence algorithm for image matching. **International Architecture Photogrammetry remote Sensing**, v.26, p.150-166, 1986.

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

GALO, M. **Revisão sobre Sistemas de Coordenadas.** Presidente Prudente, 2008. Notas de aulas do Curso de Graduação em Engenharia Cartográfica - FCT/UNESP.

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.; SOUZA, A. D. P. **Extração automática de contornos de telhados usando dados de varredura a LASER e Campos Randômicos de Markov.** Boletim de Ciências Geodésicas, v. 14, n. 2, 2008, p. 221-241.

GEMAEL, C. **Introdução ao Ajustamento de Observações: Aplicações Geodésicas.** Universidade Federal do Paraná, Curitiba, 1994.

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

GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization, and Machine Learning.** Addison-Weslly publishing company, 412p., 1989.

GONZALES, R. C.; WOODS, R. E. **Digital Image Processing,** Addison-Weslly publishing company, 716p., 2000.

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.

HARRIS, C.; STEPHENS, M. A combined corner and edge detector. In: Fourth Alvey Vision Conference, 1988, University of Manchester, **Proceedings...**, 1988, p. 147-151.

HOFMANN, A. D.; MAAS, H. G.; STREILEIN, A. Derivation of roof types by cluster analysis in parameter spaces of airborne LASER scanner point clouds. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 34, 2003.

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.

ISHIBASHI, R. **Extração de segmentos de rodovias em imagens de resolução variadas usando o princípio de bordas paralelas**. Presidente Prudente, 2008. Dissertação (mestrado) – Curso de Pós-Graduação em Ciências Cartográficas, FCT/UNESP.

JAIN, R.; KASTURI, R.; SCHUNCK, B. G. **Machine Vision**. New York: MIT Press and McGraw-Hill, Computer Science Series, 1995.

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

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.

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

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

KITCHEN, L.; ROSENFELD, A. Grey-level corner detection. **Pattern Recognition Letters**, v. 1, p. 95 – 102, 1982.

KOPPARAPU, S. K.; DESAI, U. B. **Bayesian approach to image interpretation**. 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.

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, p. 365-381, 2008.

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

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.

MACHADO, A. M. L.; MITISHITA, E. A. Detecção automática de contornos de edificações utilizando imagem gerada por câmera digital de pequeno formato e dados LIDAR. **Boletim de Ciências Geodésicas**, v. 12, n. 3, p. 215-233, 2006.

MARCATO, V. J. **Seleção automática dos métodos de Canny e Steger para a detecção acurada e confiável de linhas e bordas associadas com contornos e cumeeiras de edifícios**. Presidente Prudente, 2010a. Relatório de iniciação científica (FAPESP), Curso de Graduação em Engenharia Cartográfica, Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista.

MARCATO, V. J. **Seleção automática dos métodos de Canny e Steger para a detecção acurada e confiável de linhas e bordas associadas com contornos e cumeeiras de edifícios**. Presidente Prudente, 2010b. Relatório de iniciação científica (FAPESP), Curso de Graduação em Engenharia Cartográfica, Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista.

MARCATO, V. J. Metodologia híbrida para a extração de segmentos de contornos e cumeeiras de telhados de edifícios em imagens aéreas de alta resolução. In: VI Workshop de Visão Computacional, 2010, Presidente Prudente, São Paulo. **Anais...** 2010.

MIKHAIL, E; BETHEL, J. S.; MCGLONE, J. C. **Introduction to Modern Photogrammetry**. Chichester: John Wiley & Sons, 2001. 479 p.

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

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.

MOKHTARIAN, F. e SUOMELA, R. Robust image corner detection through curvature scale space. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 20, n. 12, p.1376-1381, 1998.

MORAVEC, H. P. Towards Automatic Visual Obstacle Avoidance. In: 5th International Joint Conference on Artificial Intelligence, 1977, Cambridge. **Proceedings...** 1977.

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

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.

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.

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.

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.

SCLÜTER, D.; WACHSMUTH, S.; SAGERER, G.. Towards an integrated framework for contour-based grouping and object recognition using Markov Random Fields. In: IEEE - International Conference on image processing, 2000, Vancouver. **Proceedings...**, v. II, 2000, p. 100-103.

SMITH S., BRADY, J. SUSAN a new approach to low level image processing. **International Journal of Computer Vision**, v. 23, n.1, p.45-78, 1997.

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.; DOWMAN, I. J. Extraction of buildings from high resolution satellite data. In: **Automatic Extraction of Man Made Objects from Aerial and Space Images**. 2001.

SOHN, G.; DOWMAN, I. J. Building extraction using Lidar DEMs and Ikonos images. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 34, 2003.

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

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.

STEGER, C. Extracting Lines Using Differential Geometry and Gaussian Smoothing. **International Archives of Photogrammetry and Remote Sensing**, v. 31, Part B3, p. 821-826, 1996.

STEGER, C. **Analytical and empirical performance evaluation of subpixel line and edges detection**. In: K. J. Bowyer and P. J. Phillips (eds), Empirical Evaluation methods in Computer Vision, IEEE Computer Society Press, Los Alamitos, CA, pp 188-210, 1998.

STEGER, C. Subpixel – Precise Extraction of Lines and Edges. **ISPRS: International Society for Photogrammetry and Remote Sensing**, v. 33, Amsterdam, 2000.

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. **Fotogrametria Básica**. 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.

TRYTEN, D. A.; TUCEYRAN, M.. Segmentation and grouping of objects boundaries using energy minimization. In: IEEE – Conference on Computer Vision and Pattern Recognition, 1991. Maui, Hi, USA. **Proceedings CVPR**, v.91, 1991, p. 730-731.

VOSSelman, 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. **Proceedings...** 1999.

VOSSelman, G. Fusion of LASER scanning data, maps and aerial photographs for building reconstruction. In: **IGARSS 2002**, Toronto, Canadá, 2002, CD-ROM.

VALE, G. M.; DAL POZ, A. P. Processo de detecção de bordas de Canny. **Boletim de Ciências Geodésicas**, Curitiba, v. 8, n. 2, p. 67-78, 2002.

YANO, M. S.; DAL POZ, A. P.; MENDES, T. S. G. Extração e regularização automática de polígonos representando contornos de telhado a partir de um MDS normalizado. In: III Simpósio Brasileiro de Geomática, 2012, Presidente Prudente, São Paulo. **Anais...** 2012, p. 187 – 192.

WANG, H.; BRADY, M. Real-time corner detection algorithm for motion estimation. **Image and Vision Computing**, v.13, N. 9, p. 695-703, 1995.

WANG, W.; DONY, R. D. Evaluation of image corner detectors for hardware implementation. In: Canadian Conference on Electrical and Computer Engineering, 2004, Ontario, Canadá. **Proceedings...** 2004.

WOLF, P.; DEWITT, B. **Elements of photogrammetry – with applications in GIS**. 3. ed. United States of America: Mc Graw Hill, 2000.

ZANIN, R. B.; ISHIBASHI, R. DAL POZ, A. P. Detector de linha de Steger: Potencial na extração de rodovias. In: II Simpósio Brasileiro de Geomática e V Colóquio Brasileiro de Ciências Geodésicas, 2007, Presidente Prudente-SP. **Anais...**, 2007, CD-ROM.

ZIOU, D.; TABBONE, S. Edge detection techniques: an overview. **International Journal of Pattern Recognition and Image Analysis**, Canada, v.8, n.4, p. 537-559, 1998.

APÊNDICES

Apêndice A

Esse apêndice apresenta alguns conceitos e ferramentas que são secundárias para o desenvolvimento da pesquisa proposta ou que são de domínio comum nas Ciências Cartográficas. A Subseção A.1 versa sobre referenciais do espaço-imagem e do espaço-objeto. A Subseção A.2 apresenta em três partes o processo de transformação de um ponto no espaço-objeto para o espaço-imagem. A subseção A.3 versa sobre a propagação de variância-covariância. Na Subseção A.4 são apresentados, brevemente, os métodos de interpolação.

A.1 Referenciais do Espaço-imagem e do Espaço-objeto

A.1.1 Sistemas do espaço-imagem

O espaço-imagem compreende, fisicamente, a região interna da câmara, entre o centro perspectivo (CP), ponto fictício que representa o sistema de lentes da câmara, e o plano focal.

A seguir serão definidos o sistema central da imagem, o sistema fotogramétrico e o sistema de imagem.

A.1.1.1 Sistema Central da Imagem

O sistema central da imagem é definido como segue:

- A origem coincide com o centro da imagem (intersecção entre as diagonais da imagem);

- O eixo x tem a direção das linhas da imagem e o sentido que mais se aproxima do sentido de voo;
- O eixo y é ortogonal ao eixo x e seu sentido está definido a 90° anti-horário.

A.1.1.2 Sistema Fotogramétrico

O sistema fotogramétrico é um sistema de coordenadas tridimensionais, definido da seguinte maneira (Galo, 2008) (Figura 1):

- A origem coincide com o centro perspectivo (CP);
- Os eixos x e y são paralelos aos eixos x e y do sistema central da imagem;
- O eixo z é perpendicular ao plano do negativo e forma com os outros dois um sistema dextrogiro de coordenadas.




Figura 1 – Sistema fotográfico de coordenadas do diapositivo, ou sistema Fotogramétrico.
(Fonte: Adaptado de GALO, 2008)

Para o caso do negativo, a origem desse sistema coincide com o CP, os eixos x e y sofrem uma reflexão em relação ao sistema anterior e o eixo z , é tal que, torna o sistema dextrogiro (Figura 2).




Figura 2 – Sistema fotográfico de coordenadas do negativo.
(Fonte: GALO, 2008)

Vale ressaltar que, o ponto principal (pp) é definido como a projeção ortogonal do CP no plano do negativo ou positivo (Figuras 1 e 2).

A.1.1.3 Sistema de Imagem

Esse sistema está associado a uma imagem digital. A imagem digital constitui uma matriz bidimensional em um sistema de coordenadas linha e coluna, representados por L e C. Cada célula dessa matriz é chamada de pixel, que possui um atributo que indica os níveis de cinza (TOMMASELLI, 2004). Geralmente, a origem desse sistema coincide com o centro do pixel situado no canto superior esquerdo (Figura 3). O eixo L coincide com a primeira coluna da imagem e o eixo C com a primeira linha.




Figura 3 – Sistema de imagem.
(Fonte: Adaptada de GALO, 2008)

A.1.2 Sistemas do Espaço-objeto

O espaço-objeto é definido como o espaço que compreende o CP e a superfície fotografada. Os seguintes sistemas de coordenadas do espaço-objeto serão definidos a seguir: sistema de coordenadas geodésicas curvilíneas, sistema coordenadas geodésicas cartesianas, sistema de coordenadas UTM com altura geométrica e sistema de coordenadas cartesianas locais.

A.1.2.1 Sistema de Coordenadas Geodésicas Curvilíneas e o Sistema de Coordenadas Geodésicas Cartesianas

A origem do sistema geodésico cartesiano é o centro do elipsóide (modelo geométrico para a superfície terrestre). O eixo X coincide com a intersecção do meridiano de Greenwich com o equador geodésico, apontando para o meridiano de Greenwich, o eixo Z coincide com o eixo do elipsóide e aponta para o pólo norte geodésico e o eixo Y do sistema é determinado de modo que o sistema se torne dextrogiro (Figura 4).




Figura 4 – Sistema geodésico cartesiano.
(Fonte: Adaptada de LUGNANI, 1987)

As coordenadas de um ponto P qualquer da superfície do elipsóide podem ser expressas também por meio das coordenadas Geodésicas curvilíneas (φ, λ, h) . As coordenadas geodésicas podem ser definidas da seguinte forma:

- Latitude Geodésica (φ): é o ângulo entre a normal¹ no ponto considerado e o plano equatorial do elipsóide, contado no plano do meridiano geodésico. No hemisfério norte as latitudes são positivas e no hemisfério sul são negativas.
- Longitude Geodésica (λ): é o ângulo entre o meridiano geodésico do ponto considerado e o meridiano geodésico origem (Greenwich), contado no plano equatorial do elipsóide. A leste do meridiano de Greenwich a longitude é positiva e a oeste negativa.
- Altitude Geométrica (h): é a distância do ponto P ao elipsóide, contada sobre a normal.




Figura 5 – Sistema de coordenadas geodésicas.
(Fonte: Adaptada de LUGNANI, 1987)

¹ A normal ao elipsóide em um ponto P' (Figura 2.5) é uma reta que passa por P' e é normal ao plano tangente ao elipsóide em P'. A normal contém um ponto P pertencente à superfície física da Terra.

A.1.2.2 Sistema UTM – Universal Transverso de Mercator

O sistema de projeção UTM tem por princípio a projeção dos pontos do elipsóide de revolução sobre um cilindro secante e transversal ao elipsóide. Esse sistema foi desenvolvido a partir de modificações feitas na projeção TM (*Transversa de Mercator*), em que a superfície de projeção é tangente à esfera modelo em qualquer meridiano. O sistema UTM faz parte de uma categoria de projeções conformes, que tem por principal característica a preservação da forma de pequenas áreas.

A combinação UTM-h constitui um sistema caracterizado como híbrido, pelo motivo de que é composto por superfícies de referência de diferentes características. As coordenadas E e N são coordenadas cartesianas sobre o cilindro, que é desenvolvível no plano, e h é obtida a partir das distâncias dos pontos da superfície física a uma superfície não plana, nesse caso, a partir do elipsóide. Em alguns procedimentos essa combinação provoca erros sistemáticos, principalmente no caso de extensas áreas.

A.1.2.3 Sistema Cartesiano Local

Esse sistema é definido da seguinte maneira (LUGNANI, 1987):

- Origem: sobre a superfície do elipsóide ou em um ponto sobre a superfície física da Terra;
- Eixo Z_L : coincidente com a normal passante pelo ponto origem no sentido contrário ao centro geométrico do elipsóide;
- Eixo Y_L : tangente ao meridiano no ponto origem, apontando para o norte geodésico;
- Eixo X_L : orientado de tal modo que o sistema seja dextrogiro.




Figura 2.6 – Sistema Cartesiano local.
(Fonte: Adaptada de LUGNANI, 1987)

A.2 Transformação de um ponto no espaço-objeto para o espaço-imagem

As transformações de um ponto no espaço-objeto para o espaço-imagem podem ser divididas em três etapas principais:

- 1) Transformação do sistema UTM com altura geométrica para o sistema geodésico cartesiano;
- 2) Transformação do sistema geodésico cartesiano para o sistema geodésico cartesiano local;
- 3) Transformação do sistema geodésico cartesiano local para o sistema fotogramétrico;
- 4) Transformação do sistema fotogramétrico para o sistema de imagem. Essa última transformação ocorre em conjunto com a introdução de erros sistemáticos referentes ao sistema de lentes.

A.2.1 Transformação do sistema UTM com altura geométrica para o sistema geodésico cartesiano

Como foi dito, anteriormente, o sistema UTM é derivado da projeção TM (*Transversa de Mercator*). Desta forma, para a realização da transformação do sistema UTM com altura geométrica para o sistema cartesiano, o primeiro passo consiste em transformar as coordenadas (E, N) (em metros) no sistema UTM para coordenadas (x, y) no sistema Transverso de Mercator, a partir das seguintes equações:

$$y = (E - 500000)/0,9996 \quad (1)$$

- x para o hemisfério Norte

$$x = N/0,9996 \quad (2)$$

- x para o hemisfério Sul

$$x = (N - 10000000)/0,9996 \quad (3)$$

O próximo passo consiste em transformar as coordenadas do sistema TM para geodésicas. Essa transformação pode ser realizada da seguinte forma (BLACHUT et al., 1979):

$$\phi = \phi_1 + b_2 \cdot y^2 + b_4 \cdot y^4 + b_6 \cdot y^6 + \dots \quad (4)$$

$$\lambda = \lambda_0 + b_1 \cdot y + b_3 \cdot y^3 + b_5 \cdot y^5 + \dots \quad (5)$$

em que:

- ϕ_1 é a latitude corresponde ao arco de meridiano de comprimento x;
- λ_0 é a longitude do meridiano central; e
- b_i são coeficientes calculados em função de ϕ_1 e da segunda excentricidade do

elipsóide, obtidos por:

$$b_1 = \frac{1}{c} \left[\left(\frac{1}{\cos \phi_1} \right)^2 + e'^2 \right]^{\frac{1}{2}}, \quad (6)$$

$$b_2 = -\frac{1}{2} b_1^2 \sin \phi_1 \cos \phi_1 (1 + e'^2 \cos^2 \phi_1) \quad (7)$$

$$b_3 = -\frac{1}{6}b_1^3(2 - \cos^2 \phi_1 + e'^2 \cos^4 \phi_1) \quad (8)$$

$$b_4 = -\frac{1}{12}b_1^2b_2(3 + (2 - 9e'^2)\cos^2 \phi_1 + 10e'^2 \cos^4 \phi_1 - 4e'^4 \cos^6 \phi_1) \quad (9)$$

$$b_5 = \frac{1}{120}b_1^5(24 - 20\cos^2 \phi_1 + (1 + 8e'^2)\cos^4 \phi_1 - 2e'^2 \cos^6 \phi_1 + \dots) \quad (10)$$

$$b_6 = \frac{1}{360}b_1^4b_2(45 + 16\cos^4 \phi_1 + \dots) \quad (11)$$

O cálculo de ϕ_1 exige um processo iterativo, dado da seguinte forma (BLACHUT et al., 1979):

- Cálculo de $\phi_1^{(i)}$, com $i = 0$ (Equação 12). Com o valor de $\phi_1^{(i)}$ calcula-se o comprimento do arco de meridiano, a partir da Equação 13.

$$\phi_1^{(i=0)} = \frac{x}{A_0 \cdot c} \quad (12)$$

$$B_{\phi(i)} = A_0 \cdot c \cdot \phi - A_1 \cdot c \cdot \sin \phi \cdot \cos \phi \left(\begin{aligned} &1 + A_2 \sin^2 \phi + A_4 \sin^4 \phi \\ &+ A_6 \sin^6 \phi + A_8 \sin^8 \phi + \dots \end{aligned} \right) \quad (13)$$

em que:

- c : raio polar de curvatura $\left(c = \frac{a^2}{b} \right)$;
- a : semi-eixo maior do elipsóide;
- b : semi-eixo menor do elipsóide;
- e' : segunda excentricidade $\left(e'^2 = \frac{a^2 - b^2}{b^2} \right)$;

Os coeficientes $A_0, A_1, \dots, A_8$ podem ser obtidos por:

$$A_0 = 1 - \frac{3}{4}e'^2 \left\{ 1 - \frac{15}{16}e'^2 \left\{ 1 - \frac{35}{36}e'^2 \left\{ 1 - \frac{63}{64}e'^2 \left\{ 1 - \frac{99}{100}e'^2 \right\} \right\} \right\} \right\} \quad (14)$$

$$A_1 = \frac{3}{4}e'^2 \left\{ 1 - \frac{25}{16}e'^2 \left\{ 1 - \frac{77}{60}e'^2 \left\{ 1 - \frac{837}{704}e'^2 \left\{ 1 - \frac{2123}{1960}e'^2 \right\} \right\} \right\} \right\} \quad (15)$$

$$A_2 = \frac{5}{8} e'^2 \left\{ 1 - \frac{139}{144} e'^2 \left\{ 1 - \frac{1087}{1112} e'^2 \left\{ 1 - \frac{513427}{521760} e'^2 \right\} \right\} \right\} \quad (16)$$

$$A_4 = \frac{35}{72} e'^4 \left\{ 1 - \frac{125}{64} e'^2 \left\{ 1 - \frac{221069}{150000} e'^2 \right\} \right\} \quad (17)$$

$$A_6 = \frac{105}{256} e'^6 \left\{ 1 - \frac{1179}{400} e'^2 \right\} \quad (18)$$

$$A_8 = \frac{231}{640} e'^8 \quad (19)$$

- Após esses cálculos, um valor melhorado para a latitude pode ser obtido a partir da próxima aproximação, que pode ser calculada por:

$$\phi_1^{(i+1)} = \phi_1^{(i)} + \frac{x - B_{\phi_1}^{(i)}}{A_0 \cdot c} \quad (20)$$

Esse procedimento irá se repetir até que $(x - B_{\phi_1}^{(i)})$ seja menor que uma tolerância pré-estabelecida.

Após a obtenção das coordenadas geodésicas curvilíneas, o próximo passo consiste em transformá-las para o sistema geodésico cartesiano. Essa transformação pode ser obtida a partir dos seguintes modelos matemáticos.

$$X = (N + h) \cdot \cos(\phi) \cdot \cos(\lambda) \quad (21)$$

$$Y = (N + h) \cdot \cos(\phi) \cdot \sin(\lambda) \quad (22)$$

$$Z = [N \cdot (1 - e^2) + h] \cdot \sin(\phi) \quad (23)$$

em que:

- N: raio de curvatura da seção primeiro vertical, dado pela equação

$$N = \frac{a}{(1 - e^2 \sin^2 \phi)^{1/2}} ; \quad (24)$$

- a: semi-eixo maior do elipsóide de referência adotado;
- e^2 : é o quadrado da primeira excentricidade do elipsóide, dado por $e^2 = 2 \cdot f - f^2$;

- f é o valor do achatamento do elipsóide de referência adotado.

A.2.2 Transformação do sistema geodésico cartesiano para o sistema geodésico cartesiano local

Para serem obtidas as coordenadas no sistema geodésico cartesiano local é necessário realizar a transformação do sistema geodésico cartesiano para esse sistema. Nessa transformação, utiliza-se um modelo baseado em rotações e translações, dado pela equação

$$\begin{bmatrix} X_L \\ Y_L \\ Z_L \end{bmatrix} = R_1(\pi/2 - \phi_0) \cdot R_3(\pi/2 + \lambda_0) \cdot \begin{bmatrix} X - X_0 \\ Y - Y_0 \\ Z - Z_0 \end{bmatrix} \quad (25)$$

em que

- (X, Y, Z) são as coordenadas de um ponto P no referencial geodésico cartesiano;
- (X_L, Y_L, Z_L) são as coordenadas de um ponto no referencial cartesiano local;
- (ϕ_0, λ_0) são as coordenadas geodésicas da origem do sistema local;
- (X_0, Y_0, Z_0) são as coordenadas geodésicas cartesianas da origem do sistema local, calculadas para (ϕ_0, λ_0, h_0) ;
- R_1 e R_3 são matrizes de rotação dadas pelas equações:

$$R_1(\pi/2 - \phi_0) = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos(\pi/2 - \phi_0) & \sin(\pi/2 - \phi_0) \\ 0 & -\sin(\pi/2 - \phi_0) & \cos(\pi/2 - \phi_0) \end{bmatrix} \quad (26)$$

$$R_3(\pi/2 + \lambda_0) = \begin{bmatrix} \cos(\pi/2 + \lambda_0) & \sin(\pi/2 + \lambda_0) & 0 \\ -\sin(\pi/2 + \lambda_0) & \cos(\pi/2 + \lambda_0) & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (27)$$

A.2.3 Transformação do sistema cartesiano local para o sistema fotogramétrico

As relações matemáticas entre o espaço-imagem e o espaço-objeto podem ser estabelecidas com base em feições retas e pontuais. As feições retas são segmentos de reta no espaço-imagem ou no espaço-objeto. Embora vários modelos fotogramétricos baseados na correspondência entre feições retas tenham sido propostos (SOUZA, 1982; MULAWA e MIKHAIL, 1988; TOMMASELLI e TOZZI, 1996; HABIB et al., 2004), aplicações práticas continuam se baseando quase que exclusivamente na correspondência entre pontos no espaço-imagem ($p(x,y)$) e no espaço-objeto ($P(X,Y,Z)$).

No caso envolvendo pontos, o modelo comumente utilizado é das equações de colinearidade. Este modelo consiste basicamente em duas equações (Equação 28), as quais consideram que um ponto no espaço objeto $P(X, Y, Z)$, o seu correspondente no espaço imagem $p(x, y)$ e o centro perspectivo $CP(X_0, Y_0, Z_0)$ são colineares no instante da tomada da imagem (Figura 7). A Figura 7 mostra, além do referencial fotogramétrico tridimensional com origem no CP, também o referencial bidimensional com origem no pp. Ambos os referenciais permitem descrever um ponto da imagem de forma equivalente, pois:

- 1) O pp é uma projeção ortogonal do CP no plano do negativo (ou positivo);
- 2) Os eixos x e y de ambos os sistemas são paralelos; e
- 3) A coordenada z do referencial fotogramétrico tridimensional é igual a distância focal (f) para qualquer ponto da imagem (z igual a $-f$ para o caso do positivo fotogramétrico).




Figura 7 – Condição de colinearidade.

$$\begin{aligned}
 x &= -f \cdot \frac{r_{11} \cdot (X_L - X_0) + r_{12} \cdot (Y_L - Y_0) + r_{13} \cdot (Z_L - Z_0)}{r_{31} \cdot (X_L - X_0) + r_{32} \cdot (Y_L - Y_0) + r_{33} \cdot (Z_L - Z_0)} \\
 y &= -f \cdot \frac{r_{21} \cdot (X_L - X_0) + r_{22} \cdot (Y_L - Y_0) + r_{23} \cdot (Z_L - Z_0)}{r_{31} \cdot (X_L - X_0) + r_{32} \cdot (Y_L - Y_0) + r_{33} \cdot (Z_L - Z_0)}
 \end{aligned} \tag{28}$$

Na Equação 28 têm-se os seguintes elementos:

- x, y são as coordenadas de um ponto bidimensional no sistema fotogramétrico (ou (x, y, z) no sistema fotogramétrico tridimensional);
- (X, Y, Z) são as coordenadas de um ponto em um referencial cartesiano local;
- (X_0, Y_0, Z_0) são as coordenadas do centro perspectivo no referencial cartesiano local;
- f é a distância focal da câmara;
- Os elementos r_{ij} pertencem à matriz de rotação $(R(k, \varphi, \omega))$, utilizada para aplicar rotações no sistema fotogramétrico 3D com relação ao sistema de coordenadas locais, de modo que eles se tornem paralelos. A matriz de rotação é dada por:

$$R(k, \varphi, \omega) = R_3(k)R_2(\varphi)R_1(\omega) = \begin{pmatrix} r_{11} & r_{12} & r_{13} \\ r_{21} & r_{22} & r_{23} \\ r_{31} & r_{32} & r_{33} \end{pmatrix} \tag{29}$$

em que,

$$\begin{aligned}
 r_{11} &= \cos\varphi \cdot \cos\kappa \\
 r_{12} &= \cos\omega \cdot \text{Sen}\kappa + \text{sen}\omega \cdot \text{sen}\varphi \cdot \cos\kappa \\
 r_{13} &= \text{sen}\omega \cdot \text{Sen}\kappa + \cos\omega \cdot \text{sen}\varphi \cdot \cos\kappa \\
 r_{21} &= -\cos\varphi \cdot \text{sen}\kappa \\
 r_{22} &= \cos\omega \cdot \cos\kappa - \text{sen}\omega \cdot \text{sen}\varphi \cdot \text{sen}\kappa \\
 r_{23} &= \text{sen}\omega \cdot \cos\kappa + \cos\omega \cdot \text{sen}\varphi \cdot \text{sen}\kappa \\
 r_{31} &= \text{sen}\varphi \\
 r_{32} &= -\text{sen}\omega \cdot \cos\varphi \\
 r_{33} &= \cos\omega \cdot \cos\varphi;
 \end{aligned}$$

Os ângulos ω , φ e κ são rotações em torno, respectivamente, dos eixos x, y e z do sistema fotogramétrico.

A.2.4 Introdução de erros sistemáticos e transformação do sistema fotogramétrico para o sistema digital da imagem

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 lentes. Isso é necessário porque a imagem digital original, onde geralmente as operações de análise de imagem são realizadas, é afetada por tais distorções. Em se tratando de imagens capturadas por câmaras digitais, as distorções relevantes a considerar são as distorções das lentes. Essas distorções são classificadas em distorção radial simétrica e em distorção descentrada.

A distorção radial, que é um efeito provocado pela dificuldade em fabricar as superfícies de lentes como parabolóides de revolução, conforme Figura 8, provoca um desvio na trajetória do raio de luz emergente no ponto nodal posterior (N'), em relação ao raio incidente no ponto nodal anterior (N) (TOMMASELLI, 2004).




Figura 8 – Distorção Radial.
(Fonte: TOMMASELLI, 2004)

Segundo Tommaselli (2004), o raio proveniente de O , coincidente com o eixo óptico, não sofre desvio na trajetória. O raio proveniente de A e incidente no ponto nodal anterior N deveria emergir no ponto nodal posterior sem desvio, na linha tracejada $N'a'$. A distorção, entretanto, provoca um desvio na direção $N'a$. Isto faz com que o ponto imagem a seja desviado radialmente em relação à o . Quando o desvio ocorre em direção oposta ao que deveria ser o ponto ideal, essa distorção é considerada positiva ($a'a$) e, caso contrário, a distorção é considerada negativa ($b'b'$).

Essa distorção provoca um deslocamento radial e simétrico com relação ao ponto principal, por isso é denominada de distorção radial simétrica. Vale também salientar, que esse efeito deforma geometricamente as imagens.




Figura 9 – Efeitos da distorção radial simétrica. (a) quadrado sem distorções; (b) distorção em almofada; e (c) distorção barrilete.

(Fonte: TOMMASELLI, 2004)

Na Figura 9, (a) é um quadrado sem distorções, (b) possui distorção positiva chamada de distorção em almofada e em (c) a distorção é negativa, chamada de distorção em barrilete (TOMMASELLI, 2004).

Já a distorção descentrada é causada pela montagem imperfeita dos elementos das lentes (os eixos óticos das lentes não estão perfeitamente alinhados).

A distorção descentrada é o deslocamento de um ponto pertencente à imagem, normal à linha radial passante pelo ponto (ver Figura 10).




Figura 10 – Distorção descentrada.
(Fonte: TOMMASELLI, 2004)

Conforme a Figura 10, a imagem d está em sua posição correta tangencialmente. Já o ponto e foi deslocado no sentido horário de sua posição correta em e' , e o ponto f foi deslocado no sentido anti-horário de sua posição correta f' (TOMMASELLI, 2004). Como exemplo, se uma imagem de uma reta $e'f'$ passa por O (ponto principal), a distorção fará com que a reta seja uma linha curva, e isto só não ocorrerá quando a linha coincidir com a linha de distorção nula.

Na Figura 11, apresentam-se os efeitos causados por ambas as distorções (distorção radial simétrica e distorção descentrada).




Figura 11 – Efeitos das distorções radial simétrica e descentrada.
(Fonte: TOMMASELLI, 2004)

O modelo matemático que permite corrigir ambas as distorções é dado por (LUGNANI, 1987),

$$\begin{aligned} x &= x_c - (k_1 \cdot r^2 + k_2 \cdot r^4 + k_3 \cdot r^6) \cdot x_c - p_1 \cdot (r^2 + 2 \cdot x_c^2) + 2 \cdot p_2 \cdot x_c \cdot y_c \\ y &= y_c - (k_1 \cdot r^2 + k_2 \cdot r^4 + k_3 \cdot r^6) \cdot y_c - p_2 \cdot (r^2 + 2 \cdot y_c^2) + 2 \cdot p_1 \cdot x_c \cdot y_c \end{aligned} \quad (30)$$

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 28).

A Equação 30 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_c, y_c) . Como esta equação não admite a inversa analítica, é necessário utilizar alguma solução numérica para encontrar os valores de (x_c, y_c) que satisfaçam a Equação 30. 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 última etapa desse procedimento, basta observar que (Figura 7): 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,

$$\begin{aligned} C &= \frac{x_c}{DC} + \frac{DW - 1}{2} \\ L &= -\frac{y_c}{DL} + \frac{DH - 1}{2} \end{aligned} \quad (32)$$

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.

A.3 Propagação de variância-covariância

É muito comum, em várias áreas das ciências e engenharia em geral, as quantidades medidas serem utilizadas para estimar outras quantidades de interesse. Nesses casos, as quantidades obtidas estão relacionadas com as medidas, portanto, se as medidas apresentarem variâncias as quantidades calculadas também apresentarão. As variâncias nas quantidades calculadas e as eventuais correlações são calculadas a partir da lei de propagação de variância-covariância. A seguir, será apresentada a lei de propagação de variância - covariância tanto para funções lineares quanto para não lineares, assim como, sua aplicação nas equações que transformam um ponto no terreno (X, Y, Z) em coordenadas de imagem (C, L).

A.3.1 Propagação para funções lineares

Na demonstração da lei de propagação para funções lineares, consideram-se os vetores aleatórios X e Y, ligados por um modelo linear (GEMAEL, 1994):

$$Y = GX + C \quad (33)$$

em que:

${}_m Y_1$ - vetor das quantidades calculadas;

${}_m G_n$ - matriz dos coeficientes;

${}_n X_1$ - vetor das medidas (observações);

${}_m C_1$ - vetor das constantes.

Aplica-se a definição de variância na Equação 33 tendo em vista que variância e covariância são esperanças. Assim, obtém-se a MVC (Matriz Variância-Covariância) de Y (Σ_Y) (Equação 34):

$$\Sigma_Y = E\{(Y - U_Y)(Y - U_Y)^T\} \quad (34)$$

da Equação 2.62 tem-se que:

$$\begin{aligned} U_Y &= E\{Y\} = E\{GX + C\} \\ U_Y &= GE\{X\} + C \\ U_Y &= GU_X + C \end{aligned} \quad (35)$$

Substituindo as expressões (33) e (35) em (34):

$$\begin{aligned} \Sigma_Y &= E\{(GX + C - GU_X - C)(GX + C - GU_X - C)^T\} \\ \Sigma_Y &= E\{(G(X - U_X))(G(X - U_X))^T\} \\ \Sigma_Y &= E\{G(X - U_X)(X - U_X)^T G^T\} \\ \Sigma_Y &= GE\{(X - U_X)(X - U_X)^T\} G^T \\ \Sigma_Y &= G\Sigma_X G^T \end{aligned} \quad (36)$$

A Equação 36 é a expressão para a propagação de variância-covariância para funções lineares.

A.3.2 Propagação para funções não lineares

As funções lineares não são normalmente encontradas na prática. Na maioria das vezes são não lineares, o que implica na necessidade de serem linearizadas. A linearização é realizada a partir do desenvolvimento da série de Taylor.

Seja a função, considerando um caso geral, em forma matricial (GEMAEL, 1994):

$$Y = F(X) \quad (37)$$

O desenvolvimento em série de Taylor, conduz a:

$$Y \cong F(X_0) + \left. \frac{\partial F}{\partial X} \right|_{x_0} (X - X_0) + \frac{\partial^2 F}{2! \partial X^2} \bigg|_{x_0} (X - X_0)^2 + \dots \quad (38)$$

desprezando os termos de segunda ordem e superiores, tem-se:

$$Y \cong F(x_0) + \left. \frac{\partial F}{\partial X} \right|_{x_0} (X - X_0) \quad (39)$$

$$Y \cong F(X_0) + D\Delta X$$

$$Y \cong F(X_0) + D(X - X_0)$$

$$Y \cong F(X_0) + DX - DX_0$$

$$Y \cong DX + (F(X_0) - DX_0)$$

$$Y \cong DX + K \quad (40)$$

em que:

$$D = \frac{\partial F}{\partial X} \Big|_{x_0} = \begin{bmatrix} \frac{\partial y_1}{\partial x_1} & \frac{\partial y_1}{\partial x_2} & \cdots & \frac{\partial y_1}{\partial x_n} \\ \frac{\partial y_2}{\partial x_1} & \frac{\partial y_2}{\partial x_2} & \cdots & \frac{\partial y_2}{\partial x_n} \\ \cdots & \cdots & \cdots & \cdots \\ \frac{\partial y_m}{\partial x_1} & \frac{\partial y_m}{\partial x_2} & \cdots & \frac{\partial y_m}{\partial x_n} \end{bmatrix}_{x_0} \quad (41)$$

Procedimento igual ao anterior conduz a Equação 42, que é a fórmula para propagação de variância-covariância para funções não lineares.

$$\Sigma_Y = D \Sigma_X D^T \quad (42)$$

A.3.3 Propagação de variância-covariância aplicada às equações que transformam um ponto do terreno (X, Y, Z) em coordenadas imagem (C, L)

A propagação de variância-covariância aplicada às equações que transformam um ponto no terreno (X, Y, Z) em coordenadas de imagem (C, L) é dividida em dois passos. Inicialmente a propagação de variância-covariância é aplicada às equações de colinearidade (Equação 28) e, como nesse caso as funções são não lineares, utiliza-se a Equação (43).

$$\Sigma_{xy} = D \Sigma_X D^T \quad (43)$$

em que:

Σ_X : MVC dos parâmetros ($\omega, \varphi, \kappa, X_0, Y_0, Z_0, X_L, Y_L$ e Z_L).

A matriz D pode ser expressa da seguinte forma:

$${}_2D_9 = \begin{bmatrix} \frac{\partial x}{\partial \omega} & \frac{\partial x}{\partial \varphi} & \frac{\partial x}{\partial \kappa} & \frac{\partial x}{\partial X_0} & \frac{\partial x}{\partial Y_0} & \frac{\partial x}{\partial Z_0} & \frac{\partial x}{\partial X_L} & \frac{\partial x}{\partial Y_L} & \frac{\partial x}{\partial Z_L} \\ \frac{\partial y}{\partial \omega} & \frac{\partial y}{\partial \varphi} & \frac{\partial y}{\partial \kappa} & \frac{\partial y}{\partial X_0} & \frac{\partial y}{\partial Y_0} & \frac{\partial y}{\partial Z_0} & \frac{\partial y}{\partial X_L} & \frac{\partial y}{\partial Y_L} & \frac{\partial y}{\partial Z_L} \end{bmatrix} \quad (44)$$

Os elementos dessa matriz são as derivadas parciais das equações de colinearidade em relação aos parâmetros. As derivadas parciais são dadas no Apêndice B.

A MVC dos parâmetros (Σ_x) (Equação 47) é obtida a partir da MVC dos parâmetros de orientação da imagem (Σ_ϕ) (Equação 45) e da MVC das coordenadas do ponto P (Σ_P) no espaço-objeto (Equação 46). A MVC dos parâmetros de orientação da imagem vem da resseção espacial.

$$\Sigma_x = \begin{bmatrix} \sigma_\omega^2 & \sigma_{\omega\phi}^2 & \sigma_{\omega\kappa}^2 & \sigma_{\omega X_0}^2 & \sigma_{\omega Y_0}^2 & \sigma_{\omega Z_0}^2 \\ \sigma_{\phi\omega}^2 & \sigma_\phi^2 & \sigma_{\phi\kappa}^2 & \sigma_{\phi X_0}^2 & \sigma_{\phi Y_0}^2 & \sigma_{\phi Z_0}^2 \\ \sigma_{\kappa\omega}^2 & \sigma_{\kappa\phi}^2 & \sigma_\kappa^2 & \sigma_{\kappa X_0}^2 & \sigma_{\kappa Y_0}^2 & \sigma_{\kappa Z_0}^2 \\ \sigma_{X_0\omega}^2 & \sigma_{X_0\phi}^2 & \sigma_{X_0\kappa}^2 & \sigma_{X_0}^2 & \sigma_{X_0 Y_0}^2 & \sigma_{X_0 Z_0}^2 \\ \sigma_{Y_0\omega}^2 & \sigma_{Y_0\phi}^2 & \sigma_{Y_0\kappa}^2 & \sigma_{Y_0 X_0}^2 & \sigma_{Y_0}^2 & \sigma_{Y_0 Z_0}^2 \\ \sigma_{Z_0\omega}^2 & \sigma_{Z_0\phi}^2 & \sigma_{Z_0\kappa}^2 & \sigma_{Z_0 X_0}^2 & \sigma_{Z_0 Y_0}^2 & \sigma_{Z_0}^2 \end{bmatrix} \quad (45)$$

$$\Sigma_P = \begin{bmatrix} \sigma_{X_L}^2 & 0 & 0 \\ 0 & \sigma_{X_L}^2 & 0 \\ 0 & 0 & \sigma_{X_L}^2 \end{bmatrix} \quad (46)$$

$$\Sigma_x = \begin{bmatrix} \Sigma_x & \\ & \Sigma_P \end{bmatrix} \quad (47)$$

Como mostra a expressão 46, as coordenadas do ponto P são admitidas como estatisticamente independentes. A expressão 47 (notar que Σ_x é bloco-diagonal) mostra também que a mesma hipótese foi assumida entre as coordenadas do ponto P e os parâmetros de orientação exterior.

O resultado ao final das operações é a matriz (2x2) variância-covariância das coordenadas fotogramétricas (Σ_{xy}).

O próximo passo consiste em obter a MVC das coordenadas de um ponto imagem p (C, L) projeção do ponto objeto P, a partir da MVC das coordenadas

fotogramétricas (Σ_{xy}). Para tanto, a propagação é aplicada nas equações de transformação de coordenadas fotogramétricas (x, y) para coordenadas de imagem (C, L) (Equações 32). Nesse caso, as equações são lineares, podendo-se escrever a expressão de propagação para obter a MVC das coordenadas de um ponto p (L, C) no sistema de imagem na forma:

$$\Sigma_{CL} = G \Sigma_{xy} G^T \quad (48)$$

A G , matriz dos coeficientes, pode ser observada a seguir:

$$G = \begin{bmatrix} \frac{1}{DC} & 0 \\ 0 & -\frac{1}{DL} \end{bmatrix} \quad (49)$$

A.4 Métodos de Interpolação

A escolha da função de interpolação é de fundamental importância para se obter uma boa precisão do modelo. Uma função interpoladora deve possibilitar a reprodução de uma superfície contínua e um tempo computacional não restritivo, além de possuir propriedades matemáticas de interesse para uma dada aplicação.

Os processos de interpolação empregados são, geralmente, os locais, quando se considera uma vizinhança limitada, ou globais, quando a vizinhança é considerada ilimitada. Na literatura relacionada existe uma variedade de métodos de interpolação, entre eles, por exemplo, as splines, elementos finitos, mínimos quadrados, krigagem e vizinho mais próximo (EL-SHEIMY, 2005).

A seguir, serão descritos alguns métodos simples de interpolação local como, vizinho mais próximo, bilinear e média ponderada.

A.4.1 Interpolação por Vizinho mais Próximo

Esse método de interpolação atribui ao ponto interpolado o valor de elevação que está associado ao ponto de referência mais próximo. A Figura 12 ilustra o princípio desse método para pontos de referência regularmente distribuídos (EL-SHEIMY, 2005).




Figura 12 – Princípio da interpolação por vizinho mais próximo.
(Fonte: EL-SHEIMY, 2005)

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 descontinuas (EL-SHEIMY, 2005).

A.4.2 Interpolação Bilinear

O polinômio bilinear (Equação 50) pode ser definido por quatro pontos amostrados que inclui o ponto a ser interpolado.

$$Z(X, Y) = a_0 + a_1X + a_2Y + a_3XY \quad (50)$$

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.4.3 Interpolação por Média Ponderada

Como o próprio nome diz, essa técnica de interpolação 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 51 descreve matematicamente o processo.

$$Z(X,Y) = \sum_{i=1}^n \left[\frac{Z_i}{d_i^p} \right] / \sum_{i=1}^n \left[\frac{1}{d_i^p} \right] \quad (51)$$

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.

Apêndice B

A seguir, podem ser observadas as derivadas parciais das equações de colinearidade com relação aos parâmetros:

$$\frac{\partial x}{\partial \omega} = \frac{f \cdot (r \cdot (-r_{33} \cdot (Y_L - Y_0) + r_{32} \cdot (Z_L - Z_0)) - q \cdot (-r_{13} \cdot (Y_L - Y_0) + r_{12} \cdot (Z_L - Z_0)))}{q^2}$$

$$\frac{\partial y}{\partial \omega} = \frac{f \cdot (s \cdot (-r_{33} \cdot (Y_L - Y_0) + r_{32} \cdot (Z_L - Z_0)) - q \cdot (-r_{23} \cdot (Y_L - Y_0) + r_{22} \cdot (Z_L - Z_0)))}{q^2}$$

$$\begin{aligned} \frac{\partial x}{\partial \varphi} = & \frac{f \cdot (r \cdot (\cos \varphi \cdot (X_L - X_0) + \sin \omega \cdot \sin \varphi \cdot (Y_L - Y_0)) - \cos \omega \cdot \sin \varphi \cdot (Z_L - Z_0) - q \cdot (-\sin \varphi \cdot \cos \kappa \cdot (X_L - X_0) + \\ & + \frac{\sin \omega \cdot \cos \varphi \cdot \cos \kappa \cdot (Y_L - Y_0) - \cos \omega \cdot \cos \varphi \cdot \cos \kappa \cdot (Z_L - Z_0))}{q^2} \end{aligned}$$

$$\begin{aligned} \frac{\partial y}{\partial \varphi} = & \frac{f \cdot (s \cdot (\cos \varphi \cdot (X_L - X_0) + \sin \omega \cdot \sin \varphi \cdot (Y_L - Y_0)) - \cos \omega \cdot \sin \varphi \cdot (Z_L - Z_0) - q \cdot (\sin \varphi \cdot \sin \kappa \cdot (X_L - X_0) + \\ & - \frac{\sin \omega \cdot \cos \varphi \cdot \sin \kappa \cdot (Y_L - Y_0) + \cos \omega \cdot \cos \varphi \cdot \sin \kappa \cdot (Z_L - Z_0))}{q^2} \end{aligned}$$

$$\frac{\partial x}{\partial \kappa} = \frac{-f \cdot (r_{21} \cdot (X_L - X_0) + r_{22} \cdot (Y_L - Y_0) + r_{23} \cdot (Z_L - Z_0))}{q}$$

$$\frac{\partial y}{\partial \kappa} = \frac{f \cdot (r_{11} \cdot (X_L - X_0) + r_{12} \cdot (Y_L - Y_0) + r_{13} \cdot (Z_L - Z_0))}{q}$$

$$\frac{\partial x}{\partial X_0} = \frac{-f \cdot (r \cdot r_{31} - q \cdot r_{11})}{q^2}$$

$$\frac{\partial y}{\partial X_0} = \frac{-f \cdot (s \cdot r_{31} - q \cdot r_{21})}{q^2}$$

$$\frac{\partial x}{\partial Y_0} = \frac{-f \cdot (r \cdot r_{32} - q \cdot r_{12})}{q^2}$$

$$\frac{\partial y}{\partial Y_0} = \frac{-f \cdot (s \cdot r_{32} - q \cdot r_{22})}{q^2}$$

$$\frac{\partial x}{\partial Z_0} = \frac{-f \cdot (r \cdot r_{33} - q \cdot r_{13})}{q^2}$$

$$\frac{\partial y}{\partial Z_0} = \frac{-f \cdot (s \cdot r_{33} - q \cdot r_{23})}{q^2}$$

$$\frac{\partial x}{\partial X_L} = -\frac{\partial x}{\partial X_0}$$

$$\frac{\partial y}{\partial X_L} = -\frac{\partial y}{\partial X_0}$$

$$\frac{\partial x}{\partial Y_L} = -\frac{\partial x}{\partial Y_0}$$

$$\frac{\partial y}{\partial Y_L} = -\frac{\partial y}{\partial Y_0}$$

$$\frac{\partial x}{\partial Z_L} = -\frac{\partial x}{\partial Z_0}$$

$$\frac{\partial y}{\partial Z_L} = -\frac{\partial y}{\partial Z_0}$$

em que:

$$r = r_{11} \cdot (X_L - X_0) + r_{12} \cdot (Y_L - Y_0) + r_{13} \cdot (Z_L - Z_0)$$

$$s = r_{21} \cdot (X_L - X_0) + r_{22} \cdot (Y_L - Y_0) + r_{23} \cdot (Z_L - Z_0)$$

