

unesp  UNIVERSIDADE ESTADUAL PAULISTA

Faculdade de Ciências e Tecnologia

Programa de Pós-Graduação em Ciências Cartográficas

Tatiana Sussel Gonçalves Mendes



**EXTRAÇÃO SEMI-AUTOMÁTICA DE
RODOVIAS EM IMAGENS DIGITAIS USANDO
TÉCNICAS DE CORRELAÇÃO E O PRINCÍPIO
DE TESTE ATIVO**

**Presidente Prudente
2005**



UNIVERSIDADE ESTADUAL PAULISTA

Faculdade de Ciências e Tecnologia

Programa de Pós-Graduação em Ciências Cartográficas

Tatiana Sussel Gonçalves Mendes

**EXTRAÇÃO SEMI-AUTOMÁTICA DE RODOVIAS
EM IMAGENS DIGITAIS USANDO TÉCNICAS DE
CORRELAÇÃO E O PRINCÍPIO DE TESTE ATIVO**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Cartográficas da Faculdade de Ciências e Tecnologia – UNESP, como parte dos requisitos exigidos para a obtenção do título de Mestre em Ciências Cartográficas

Orientador:

Prof. Dr. Aluir Porfírio Dal Poz

Presidente Prudente
2005

Com muito carinho e afeto dedico este trabalho ao meu marido Bruno e ao nosso filho Bruninho. Também dedico aos meus pais, dos quais sempre recebi apoio.

AGRADECIMENTOS

A seguir estão todas as pessoas e entidades que de uma forma direta ou indireta colaboraram com esta pesquisa.

- Ao professor Dr. Aluir Porfírio Dal Poz, pela confiança depositada em mim, pelo seu constante incentivo e grande amizade;
- Ao CNPq, pela concessão de bolsa;
- À FAPESP (Fundação de Amparo à Pesquisa do Estado de São Paulo), pelos recursos e auxílio à pesquisa;
- À ESTEIO – Engenharia e Aerolevantamentos S.A., de Curitiba – PR, que colaborou nesta pesquisa através do fornecimento de imagens usadas nos experimentos;
- A todos os familiares pelo constante apoio e incentivo; em especial meu marido Bruno que sempre esteve ao meu lado, acreditando e me dando força para superar cada obstáculo;
- A todos os professores do Departamento de Cartografia, que contribuíram com a minha formação acadêmica; e
- A todos os amigos e os alunos do Programa de Pós-Graduação em Ciências Cartográficas, em especial Antônio Juliano Fazan que muito contribuiu para esta pesquisa.

*“Feliz aquele que transfere o que sabe e
aprende o que ensina.”*

Cora Coralina

RESUMO

É esperado que o operador humano permaneça, por um longo tempo, como parte integrante do sistema de extração de feições. Portanto, as pesquisas que caminham para o desenvolvimento de novos métodos semi-automáticos são ainda de grande importância. Nesta linha, esta pesquisa propõe um método semi-automático para a extração de rodovias em imagens digitais. A metodologia é uma combinação entre técnicas de correlação e estratégia de teste ativo. Para inicializar o processo de extração, o operador precisa fornecer dois pontos sementes próximos e mais um outro no fim do segmento de rodovia selecionado para ser extraído. Este último ponto marca a posição onde o processo de extração deve ser parado. O algoritmo desenvolvido prossegue em duas etapas básicas. A primeira é o cálculo do modelo da rodovia (denominado de perfil modelo), o qual é a média ponderada dos perfis de cinza extraídos perpendicularmente ao eixo da rodovia entre os dois pontos sementes próximos. Na segunda etapa, o perfil modelo é usado para iniciar o delineamento da rodovia até o ponto semente que indica o fim da extração. O processo de delineamento combina a estratégia de teste ativo e técnicas de correlação. Basicamente, a estratégia de teste ativo permite o cálculo da melhor direção da rodovia no último ponto extraído, procurando pela informação da rodovia nas direções anterior e adiante. O último ponto extraído é linearmente extrapolado usando a melhor direção da rodovia, resultando numa posição aproximada. Esta posição aproximada é corrigida através de funções de correlação, que comparam o perfil modelo e o perfil de cinza local extraído no último ponto extraído. Esta estratégia é então repetida permitindo que todo o eixo, previamente selecionado pelo operador, seja extraído. O processo de extração é interrompido se a porcentagem de falhas, corrigindo os pontos extrapolados no segmento de rodovia pré-definido, for maior que um limiar dado. Sempre que o método não pode prosseguir sozinho, o operador pode re-entrar com a informação necessária para reinicializar o processo de extração de rodovia. Os resultados experimentais obtidos da aplicação do método em imagens reais mostram que o método funciona corretamente, demonstrando que pode ser usado em esquemas de captura de dados.

Palavras-Chave: Extração de rodovia, Semi-automação, Correlação, Estratégia de Teste Ativo.

ABSTRACT

The human operator is still expected to remain as part of the feature extraction system for a relative long time. Therefore, researches for the development of new semi-automatic methods is still of great importance. Following this line, this research proposes a semi-automatic method for road extraction from digital images. It is based on a combination between correlation techniques and an active testing strategy. In order to initialize the extraction process, the operator needs to supply two close seed points plus another one at the end of road segment selected to be extracted. This last point marks the position where the extraction process must stop. The developed algorithm proceeds in two basic steps. The first one is the computation of a road model (referred to as model profile), which is a weighted mean profile among 1D gray level profiles extracted perpendicularly to the road axis along the two close seed points. In the second step, the model profile is used to start the delineation of the road as far as the seed point indicating the end of extraction. The delineation process combines the active testing strategy and correlation techniques. Basically, the active testing strategy allows the computation of best road direction at the last extracted point, searching for road information both in backward and forward directions. Using the best road direction, the last extracted point is linearly extrapolated, resulting in an approximate position. This approximate position is corrected by correlation-based techniques, which compare the model profile and local 1D gray level profile extracted at the last extracted point. This strategy is then repeated to allow the entire road axis, previously selected by the operator, to be extracted. The extraction process is stopped if the percentage of failures, in correcting the extrapolated points in a pre-defined road segment, is greater than a given threshold. Whenever the method cannot proceed itself, the operator may re-enter the needed information to restart the road extraction process. Experimental results obtained from the application of the method to real image data show that the method works properly, demonstrating that the developed method can be used in data capturing schemes.

Key-Words: Road Extraction, Semi-automation, Matching, Active Testing Strategy.

LISTA DE FIGURAS

Figura 1 – Interpolação por vizinho mais próximo.	22
Figura 2 – Interpolação bilinear.	23
Figura 3 – Interpolação bilinear através das distâncias.	25
Figura 4 – Convolução cúbica.	26
Figura 5 – Janela alvo e janela de pesquisa.	29
Figura 6 – Processo de correlação areal.	32
Figura 7 – Descrição estrutural de uma imagem.	37
Figura 8 – Inicialização do processo. (a) Segmento de reta formado pelos pontos iniciais P_1 e P_2 . (b) Seqüência de pontos e extração do perfil modelo.	58
Figura 9 – Processo de interpolação.	59
Figura 10 – Estabelecimento da janela de pesquisa perpendicular ao segmento de rodovia dado pelos últimos pontos extraídos.	65
Figura 11 – Exemplos de máscaras contendo modelos de rodovia.	66
Figura 12 – Parâmetros de construção de uma máscara.	68
Figura 13 – Correlação entre a máscara e a janela de pesquisa.	70
Figura 14 – Melhor correlação entre os perfis modelo e medido.	73
Figura 15 – Resultado da correlação usando funções de correlação.	74
Figura 16 – Esquema mostrando as rotinas principais e secundárias.	82
Figura 17 – Imagem real 1.	86
Figura 18 – Imagem real 2.	87
Figura 19 – Imagem real 3.	88
Figura 20 – Imagem real 4.	89
Figura 21 – Imagem real 5.	90
Figura 22 – Imagem real 6.	91
Figura 23 – Resultados obtidos com a imagem real 1.	95
Figura 24 – Resultados obtidos com a imagem real 2.	98
Figura 25 – Resultados obtidos com a imagem real 3.	100
Figura 26 – Resultados obtidos com a imagem real 4.	102
Figura 27 – Resultados obtidos com a imagem real 5.	104
Figura 28 – Resultados obtidos com a imagem real 6.	107

SUMÁRIO

1. INTRODUÇÃO	10
1.1 Objetivos	14
1.2 Estrutura do relatório	14
2. CONCEITOS TEÓRICOS FUNDAMENTAIS	15
2.1 Considerações Iniciais	15
2.2 Ajustamento pelo Método dos Mínimos Quadrados	17
2.3 Técnicas de Reamostragem de uma Imagem Digital	21
2.3.1 Vizinho Mais Próximo	22
2.3.2 Interpolação Bilinear	23
2.3.3 Convolução Cúbica	25
2.4 Correlação de Imagens	27
2.4.1 O problema de Correlação	27
2.4.1.1 Correlação Areal	31
2.4.1.2 Correlação por Entidades	32
2.4.1.3 <i>Matching</i> Relacional	36
2.4.2. Correlação Areal usando Funções de Correlação	38
2.4.2.1 Função Erro	39
2.4.2.2 Função Erro Quadrático	40
2.4.2.3 Função Covariância Cruzada	40
2.4.2.4 Função Correlação Cruzada	41
2.4.2.5 Função Coeficiente de Correlação	42
2.4.2.6 Função Quociente	42
2.4.3 Correlação Areal usando o Método dos Mínimos Quadrados	43
3. METODOLOGIA PARA EXTRAÇÃO DE RODOVIA	53
3.1 Considerações Iniciais	53
3.2 Noções Básicas sobre Modelagem e Extração de Rodovias	53
3.3 Extração Semi-Automática de Feições em Imagens Digitais usando Técnicas de Correlação e o Princípio de Teste Ativo	56
3.3.1 Inicialização	57
3.3.1.1 Interpolação de um Ponto Qualquer (Q_{i+1})	58
3.3.1.2 Extração de um Perfil em Q_{i+1}	60

3.3.1.3 Obtenção do Perfil Modelo e de uma Seqüência de Pontos	61
3.3.2 Delineamento da Rodovia	62
3.3.2.1 Modelagem da Trajetória da Rodovia através do Princípio de Teste Ativo	63
3.2.2.1.1 Definição de uma Janela de Pesquisa	64
3.2.2.1.2 Construção dos Modelos de Representação da Rodovia	66
3.2.2.1.3 Determinação da Melhor Direção Local da Rodovia	69
3.2.2.1.4 Extrapolação de um Ponto do Segmento da Rodovia	70
3.3.2.2 Extração de um perfil medido	71
3.3.2.3 Correlação entre o Perfil Modelo e o Perfil Medido	71
3.3.2.4 Validação do Ponto Extraído	73
3.3.2.5 Refinamento usando o MMQ	73
3.3.2.6 Atualização do Perfil Modelo	78
3.3.2.7 Generalização do Processo de Extração	78
4. EXPERIMENTOS E ANÁLISE	80
4.1 Considerações Iniciais	80
4.2 Metodologia	80
4.2.1 Aspectos Computacionais	80
4.2.2 Dados	85
4.2.3 Formas de Análise dos Resultados	91
4.3 Recursos Utilizados	92
4.4 Experimentos e Análise dos Resultados	93
4.4.1 Experimento com a Imagem Real 1	94
4.4.2 Experimento com a Imagem Real 2	96
4.4.3 Experimento com a Imagem Real 3	98
4.4.4 Experimento com a Imagem Real 4	100
4.4.5 Experimento com a Imagem Real 5	103
4.4.6 Experimento com a Imagem Real 6	106
5. CONCLUSÕES E RECOMENDAÇÕES	110
5.1 Conclusões	110
5.1 Recomendações	114
REFERÊNCIAS BIBLIOGRÁFICAS	116

1. INTRODUÇÃO

A extração automática de feições lineares através de imagens de sensoriamento remoto tem sido objetivo de diversas pesquisas nas últimas décadas. Estudos recentes mostram resultados promissores para a extração de feições para aplicações tais como atualização de Sistema de Informação Geográfica (SIG). Pesquisas nesta área têm sido estimuladas através do crescimento da disponibilidade de imagens nos últimos anos, devido ao lançamento de diversos sensores transportados por via aérea e satélite (QUACKENBUSCH, 2004).

Atualmente, a análise totalmente automatizada de imagens continua sendo uma tarefa difícil de ser implementada em computadores, sendo que o que há de fato disponível até o momento é um conjunto de técnicas de processamento de imagens que podem ser utilizadas para retirar algumas informações sobre os objetos presentes na cena.

A preferência pelas feições lineares tem seus motivos justificados, pois se apresentam em grande abundância em ambientes modificados pelo homem (construções prediais, rodovias etc.), possuem facilidade de detecção em imagens digitais, simplicidade no processo posterior de vetorização e menor probabilidade de erros grosseiros no estabelecimento de suas homólogas no espaço-objeto (em relação ao ponto de apoio) (TOMMASELLI e TOZZI, 1993).

A automação em Fotogrametria tem evoluído significativamente em alguns processos fotogramétricos, justamente naqueles que se caracterizam pelo caráter mais geométrico. Por exemplo, pode-se citar o caso da medida automática

de marcas fiduciais e da determinação automática da correspondência entre pontos homólogos (BAUMGARTNER et al., 1999). Este último avanço trouxe ganhos práticos consideráveis aos processos de orientação relativa, de geração de MDT (Modelos Digitais do Terreno) e de aerotriangulação.

Outro processo fotogramétrico de caráter geométrico relativamente bem resolvido é a geração automática de ortofoto. Já os processos de caráter semântico são muito mais difíceis de serem automatizados, pois necessitam da determinação do significado dos objetos cartográficos, além dos respectivos delineamentos geométricos. Dá-se a esse processo a denominação genérica de extração de feições, envolvendo duas tarefas básicas, isto é, a de reconhecimento e a de delineamento.

Especialmente a extração de malha viária em imagens digitais tem recebido considerável atenção de pesquisadores da área de Fotogrametria e, também, de outras áreas, como a de Visão Computacional. De fato, o problema de extração de rodovia vem sendo alvo de inúmeras pesquisas desde os trabalhos pioneiros de Bajcsy e Tavakoli (1976) e de Quam (1978).

O critério mais comum para a classificação dos métodos de extração está relacionado com o grau de intervenção do operador humano (DAL POZ e SILVA, 2002). Os métodos que necessitam da intervenção do operador são ditos métodos semi-automáticos, e os que não necessitam, automáticos.

Os métodos inteiramente automáticos para a extração tentam tirar completamente a intervenção humana na extração. Basicamente, estes métodos requerem uma integração da informação contextual e do conhecimento *a priori* na tarefa de extração de rodovia (DAL POZ e SILVA, 2002). Um exemplo bem sucedido é encontrado em Baumgartner et al. (1999). Outros estudos recentes podem ser

encontrados em Doucette; Agouris; Stefanidis (2004) e Priestnall et al. (2004). Em Quackenbush (2004), são descritos diversos métodos usados para extração de feições, considerando os resultados destes métodos com acurácia quantitativa e qualitativa.

O principal problema de métodos automáticos é que para muitas aplicações a qualidade dos resultados não é suficiente. Entretanto, os benefícios dos sistemas automáticos dependem não somente de algoritmos sofisticados, mas também de ferramentas adequadas para uma posterior edição (BAUMGARTNER; HINZ; WIEDEMANN, 2002).

Conforme Dal Poz e Silva (2002), nos métodos semi-automáticos um operador deve fornecer, por exemplo, um ponto inicial e um outro para dar a direção, além da largura da rodovia. Com esses parâmetros o algoritmo vai extraíndo seqüencialmente toda a rodovia. Por isso é que, conforme Baumgartner; Hinz; Wiedemann (2002), os métodos semi-automáticos possuem vantagens, pois a qualidade dos resultados é garantida pelo fato do operador controlar o processo de aquisição dos dados e prevenir os erros. Com certeza, os algoritmos para extração semi-automática não precisam possuir os mesmos requerimentos que os do sistema automático, necessitando apenas de uma eficiente interface e ferramentas.

As metodologias de extração que podem ser implementadas nos sistemas semi-automáticos são geralmente categorizadas em dois grupos. Num primeiro grupo estão os chamados delineadores seqüenciais, os quais se caracterizam principalmente pelo uso de informações locais para decidir seqüencialmente pela inclusão de um próximo ponto na lista de pontos extraídos até então. Estes delineadores são inicializados por dois pontos sementes próximos, geralmente locados pelo operador no início da rodovia selecionada para extração,

com intuito de fornecer a posição e a direção inicial para o algoritmo. Exemplos típicos destas metodologias são encontradas em McKeown e Denlinger (1988); Dal Poz e Silva (2003) e Mendes e Dal Poz (2004).

Num segundo grupo estão os delineadores baseados em algum processo de otimização global, como, por exemplo, programação dinâmica (MERLET e ZERUBIA, 1996; GRÜEN e LI, 1997 e VALE, 2003) e contorno ativo (KASS; WITKIN; TERZOPOULOS, 1987; AGOURIS; GYFTAKIS; STEFANIDIS, 2000).

Para a extração de segmentos de rodovia, uma série de modelos e estratégias está disponível (DAL POZ, 2001). No entanto, poucos são os trabalhos realizados no sentido de criar uma metodologia para detecção e extração de cruzamento de rodovia na literatura (BARSI; HEIPKE; WILLRICH, 2002; ZANIN, 2003), para assim conectar os segmentos e gerar a malha viária.

A principal motivação deste trabalho é a constatação de que, mesmo em estados mais desenvolvidos do país, existem grandes extensões de rodovias vicinais não mapeadas, geralmente ligando pequenas cidades, bairros, vilas e comunidade de agricultores. Os métodos semi-automáticos para extração de rodovias podem acelerar bastante o processo de captura ou atualização das malhas viárias vicinais em imagens aéreas e de satélite, uma vez que ao operador caberia apenas identificar as rodovias vicinais e fornecer poucos pontos sementes.

1.1 Objetivos

Os principais objetivos são:

- Desenvolver e implementar computacionalmente uma metodologia semi-automática para extração de rodovia usando técnicas de correlação e o princípio de teste ativo; e
- Avaliar experimentalmente o potencial da metodologia.

1.2 Estrutura do Trabalho

Este relatório está estruturado em 5 capítulos. No Capítulo 2 é apresentada uma revisão bibliográfica envolvendo os assuntos mais importantes para o desenvolvimento da pesquisa.

O Capítulo 3 descreve o modelo de extração de rodovia pela técnica de correlação e o princípio de teste ativo.

No Capítulo 4 são apresentados os resultados experimentais.

A conclusão é apresentada no Capítulo 5.

2. CONCEITOS TEÓRICOS FUNDAMENTAIS

2.1 Considerações Iniciais

A Fotogrametria Digital é caracterizada pelo uso de técnicas de processamento digital e análise de padrões, que são fundamentais para automatizar o trabalho de medição nas imagens. As investigações no domínio digital têm demonstrado grandes vantagens na aplicação de correlação para realizar trabalhos tais como elaboração automática de mapas, ortofotos e modelos digitais de terreno (STRAUCH, 1990).

Um dos processos mais fundamentais em Fotogrametria é a identificação e a medida de pontos homólogos em duas ou mais imagens com superposição. Nas fotogrametrias analógica e analítica a identificação dos pontos homólogos era executada pelo operador, enquanto que na fotogrametria digital, procura-se resolver o problema automaticamente através do processo conhecido como correlação digital de imagens (SCHENK, 1999).

Kreiling (1976 apud Schenk, 1999) foi um dos primeiros a desenvolver a correlação digital para a geração automática de Modelo Digital de Elevação com o propósito de produzir ortofotos. Makarovic (1980 apud SCHENK, 1999) apresentou uma visão geral dos algoritmos de correlação de imagens.

Conforme Heipke (1996 apud GALO e TOZZI, 1997) atualmente estão disponíveis no mercado sistemas automáticos, no que se refere à orientação interior, à orientação relativa e à aerotriangulação.

Portanto, na Fotogrametria a correlação entre as feições extraídas da imagem e os pontos de controle, ou seja, o relacionamento entre o espaço imagem e o espaço objeto, é o problema crucial da orientação absoluta automática. Neste sentido, técnicas de correlação de imagens são estudadas na tentativa de melhorar esse procedimento.

Outros problemas tais como, a orientação relativa, a geração de Modelos Digitais do Terreno (DTM) e a fototriangulação, podem ser automatizados através de técnicas de correlação de imagens, justificando assim a importância da correlação na Fotogrametria.

Além dos problemas tradicionais da fotogrametria (apresentados acima) a correlação é também aplicada em extração de rodovias, conforme Mendes e Dal Poz (2002, 2004).

O capítulo 2 apresenta os fundamentos teóricos necessários para o desenvolvimento da metodologia de extração, com destaque para o estudo das técnicas de correlação de imagens, com ênfase à correlação areal (seção 2.4). As seções 2.2 e 2.3 apresentam, respectivamente, o ajustamento pelo Método dos Mínimos Quadrados e as técnicas de reamostragem para uma imagem digital.

2.2 Ajustamento pelo Método dos Mínimos Quadrados

Segundo Gemael (1994), no método paramétrico, também conhecido como o método das equações de observações, cada observação proporciona uma equação.

Denota-se n como o número total de observações e u o número de parâmetros envolvidos. Tem-se então n observações e conseqüentemente n equações. Essas equações serão de tal forma que se pode explicitar cada observação em função dos parâmetros envolvidos (u).

No Método dos Mínimos Quadrados (MMQ), estimam-se as variáveis estocásticas X (parâmetros) e sua precisão Σ_X (matriz variância-covariância dos parâmetros), a partir de amostras L_b , observadas com precisão Σ_{L_b} (matriz variância-covariância das observações).

O modelo matemático do ajustamento pelo método paramétrico é dado pela equação 1.

$$L_a = F(X_a) \quad (1)$$

A equação 1 mostra que as observações são funções explícitas dos parâmetros, sendo que L_a é o vetor que contém as observações ajustadas, X_a é o vetor dos parâmetros ajustados.

O vetor dos parâmetros ajustados (equação 2) é obtido pela soma do vetor dos parâmetros aproximados (X_0) e do vetor X estimado no ajustamento, que representa o vetor das correções aos parâmetros aproximados.

$$\mathbf{X}_a = \mathbf{X}_0 + \mathbf{X} \quad (2)$$

$$\mathbf{L}_a = \mathbf{L}_b + \mathbf{V} \quad (3)$$

A equação 3 mostra que o vetor das observações ajustadas é obtido pela soma do vetor \mathbf{L}_b com o vetor \mathbf{V} estimado no ajustamento, que representa o vetor dos resíduos das observações.

Substituindo as equações (2) e (3) em (1), tem-se:

$$\mathbf{L}_b + \mathbf{V} = \mathbf{F}(\mathbf{X}_0 + \mathbf{X}) \quad (4)$$

O modelo matemático (equação 4) é não linear. A linearização é realizada através da série de Taylor, desprezando os termos de ordem igual e superior a segunda. A linearização é dada a seguir:

$$\mathbf{L}_b + \mathbf{V} = \mathbf{F}(\mathbf{X}_0) + \left. \frac{\partial \mathbf{F}}{\partial \mathbf{X}_a} \right|_{\mathbf{X}_0} \cdot (\mathbf{X}_a - \mathbf{X}_0)$$

Fazendo:

- $\mathbf{L}_0 = \mathbf{F}(\mathbf{X}_0)$;

- $\mathbf{A} = \left. \frac{\partial \mathbf{F}}{\partial \mathbf{X}_a} \right|_{\mathbf{X}_0}$;
- $\mathbf{X} = \mathbf{X}_a - \mathbf{X}_0$; e
- $\mathbf{L} = \mathbf{L}_0 - \mathbf{L}_b$.

Tem-se:

$$\mathbf{L}_b + \mathbf{V} = \mathbf{L}_0 + \mathbf{A} \cdot \mathbf{X} \quad \Rightarrow$$

$$\mathbf{V} = \mathbf{A} \cdot \mathbf{X} + (\mathbf{L}_0 - \mathbf{L}_b) \quad \Rightarrow$$

$$\mathbf{V} = \mathbf{A} \cdot \mathbf{X} + \mathbf{L} \quad (5)$$

A equação 5 representa o modelo matemático linearizado do método paramétrico de ajustamento, onde \mathbf{A} representa a matriz das derivadas parciais das equações de observação em relação aos parâmetros.

O critério do MMQ estabelece que a soma dos quadrados dos resíduos ponderados deve ser mínima, então:

$$\mathbf{V}^T \mathbf{P} \mathbf{V} = \min \quad (6)$$

Na equação 6, \mathbf{P} é a matriz dos pesos das observações. A matriz \mathbf{P} é dada por:

$$\mathbf{P} = \sigma_0^2 \sum_{L_b}^{-1} \quad (7)$$

Substituindo a equação 5 na equação 6, expandindo e derivando o resultado em relação às componentes do vetor \mathbf{X} , resulta em:

$$\mathbf{A}^T \mathbf{P} \mathbf{A} \mathbf{X} + \mathbf{A}^T \mathbf{P} \mathbf{L} = \mathbf{0} \quad (8)$$

Fazendo:

- $\mathbf{N} = \mathbf{A}^T \mathbf{P} \mathbf{A}$ e
- $\mathbf{U} = \mathbf{A}^T \mathbf{P} \mathbf{L}$, tem-se:

$$\mathbf{N} \mathbf{X} + \mathbf{U} = \mathbf{0} \quad \Rightarrow$$

$$\mathbf{X} = -\mathbf{N}^{-1} \cdot \mathbf{U} \quad (9)$$

Ao somar as componentes do vetor \mathbf{X} com os parâmetros aproximados tem-se finalmente o vetor dos parâmetros ajustados (eq. 10).

$$\mathbf{X}_a = \mathbf{X}_0 + \mathbf{X} \quad (10)$$

Onde \mathbf{X}_a é o vetor dos parâmetros ajustado, \mathbf{X}_0 é o vetor dos parâmetros aproximados e \mathbf{X} é vetor das correções aos parâmetros.

Sempre que o modelo 1 for não linear, é necessário realizar iterações até que \mathbf{X} atenda um limiar pré-definido.

No final, a matriz variância-covariância dos parâmetros ajustados \mathbf{X}_a é dada pela equação 11.

$$\sum X_a = \hat{\sigma}_0^2 \cdot N^{-1} \quad (11)$$

onde $\hat{\sigma}_0^2$ é denominado fator de variância *a posteriori* e é dado pela equação 12.

$$\hat{\sigma}_0^2 = \frac{V^T P V}{n - u} \quad (12)$$

2.3 Técnicas de Reamostragem de uma Imagem Digital

Uma imagem digital pode ser reduzida, ampliada ou até mesmo transformada para atender a vários propósitos. Por exemplo, a ampliação (ou superamostragem) gera pixels por interpolação de modo a ampliar a imagem além da informação originalmente disponível. Para interpolar os tons de cinza de uma imagem digital, normalmente se utilizam técnicas de reamostragem, tais como: interpolação bilinear e vizinho mais próximo (MACHADO E SILVA, 1988).

A seguir tem-se uma breve descrição das três técnicas de reamostragem mais conhecidas: vizinho mais próximo, interpolação bilinear e convolução cúbica.

2.3.1 Vizinho Mais Próximo

A interpolação de um ponto pelo método do vizinho mais próximo ocorre com a verificação da distância entre o ponto considerado (i', j') e seus quatro pixels vizinhos. Adota-se, então, o nível de cinza de $g(i', j')$ igual ao nível do pixel mais próximo na imagem digital, como ilustrado na figura 1. Nesse exemplo, verifica-se visualmente que o pixel (i', j') recebe o tom de cinza do pixel $(i+1, j+1)$.

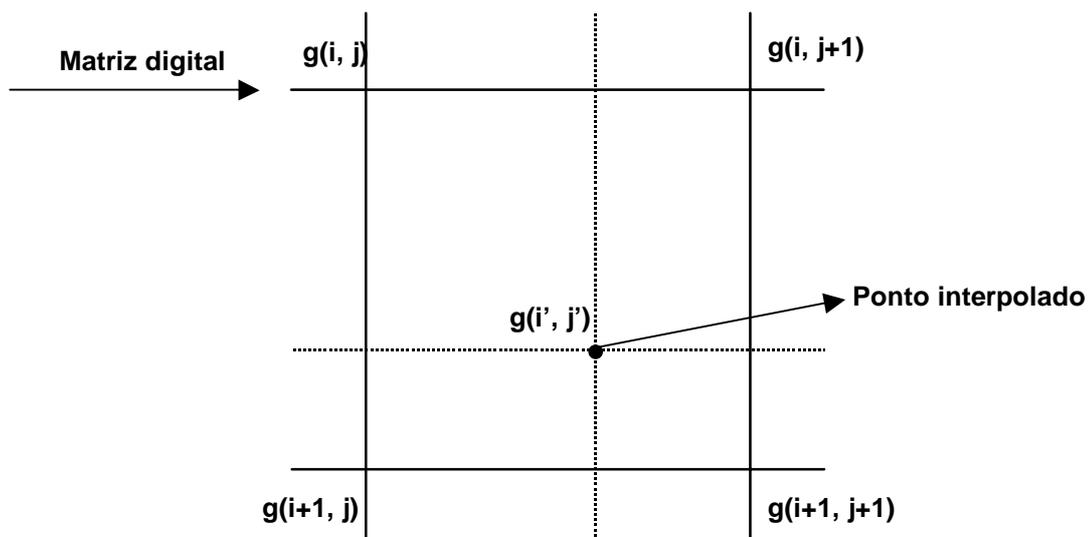


Figura 1 - Interpolação por vizinho mais próximo.

(Adaptado de Silva (2001))

2.3.2 Interpolação Bilinear

Na técnica de reamostragem por interpolação bilinear, para um ponto interpolado obtêm-se o seu nível de cinza através da interpolação dos valores de brilho dos quatro pixels mais próximos (vizinhos). A interpolação bilinear é um dos métodos de interpolação de tons de cinza mais utilizados devido aos bons resultados apresentados e relativamente pouco esforço computacional (figura 2).

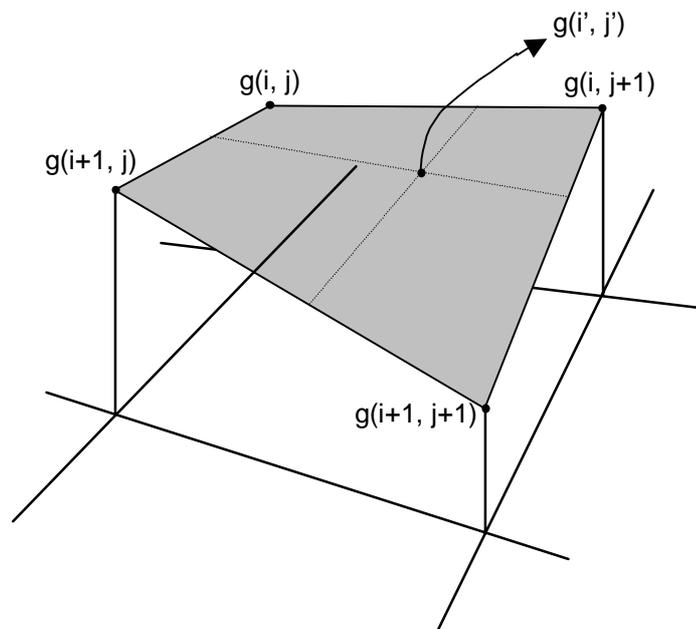


Figura 2: Interpolação bilinear.

(Adaptado de Jain; Kasturi; Schunck (2000))

A reamostragem por interpolação bilinear é realizada através de três interpolações sobre os quatro vizinhos mais próximos:

1. Encontra-se o tom de cinza do ponto (i, j') conhecendo-se os tons de cinza dos pixels (i, j) e $(i, j+1)$ através da seguinte equação:

$$g(i, j') = j' \cdot g(i, j+1) + (1 - j') \cdot g(i, j) \quad (13)$$

2. Obtém-se agora o tom de cinza do ponto $(i+1, j')$, conhecendo-se os tons de cinza dos pixels $(i+1, j)$ e $(i+1, j+1)$, realizando a seguinte interpolação:

$$g(i+1, j') = j' \cdot g(i+1, j+1) + (1 - j') \cdot g(i+1, j) \quad (14)$$

3. Através dos dois pontos encontrados na primeira e na segunda interpolação, obtém-se o ponto desejado (i', j') através da equação a seguir:

$$g(i', j') = (1 - i') \cdot \{ j' \cdot g(i, j+1) + (1 - j') \cdot g(i, j) \} + i' \cdot \{ j' \cdot g(i+1, j+1) + (1 - j') \cdot g(i+1, j) \} \quad (15)$$

Uma outra forma de se realizar a interpolação bilinear é baseada nos quatros pixels vizinhos e em suas distâncias para o ponto (i', j') (KONECNY, 1987). Como ilustrado na figura 3, este método faz com que o ponto interpolado tenha uma

maior influência do pixel vizinho mais próximo, ou seja, é atribuído maior peso para a menor distância em relação ao ponto.

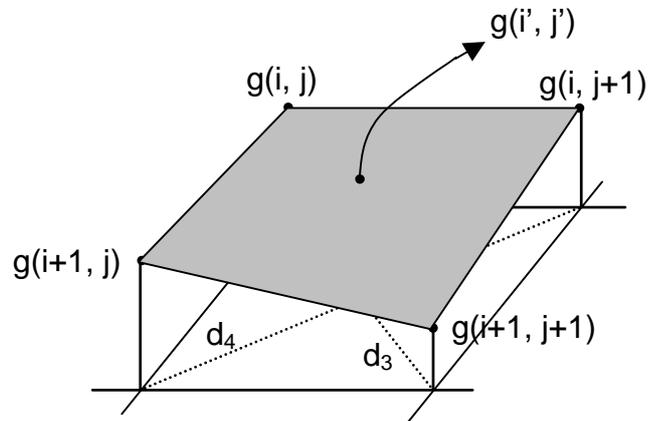


Figura 3 - Interpolação bilinear através das distâncias
(Adaptado de Silva (2001)).

O tom de cinza do pixel (i', j') é obtido como segue:

$$g(i', j') = \frac{\frac{1}{d_1} \cdot g(i, j) + \frac{1}{d_2} \cdot g(i, j+1) + \frac{1}{d_3} \cdot g(i+1, j+1) + \frac{1}{d_4} \cdot g(i+1, j)}{\frac{1}{d_1} + \frac{1}{d_2} + \frac{1}{d_3} + \frac{1}{d_4}} \quad (16)$$

2.3.3 Convolação Cúbica

O método de reamostragem por convolação cúbica produz uma reamostragem mais aperfeiçoada da imagem. Este processo trabalha com cinco

interpolações, com base em uma vizinhança de dezesseis pixels, e, portanto, exige um maior esforço computacional. A figura 4 mostra as interpolações por convolução cúbica.

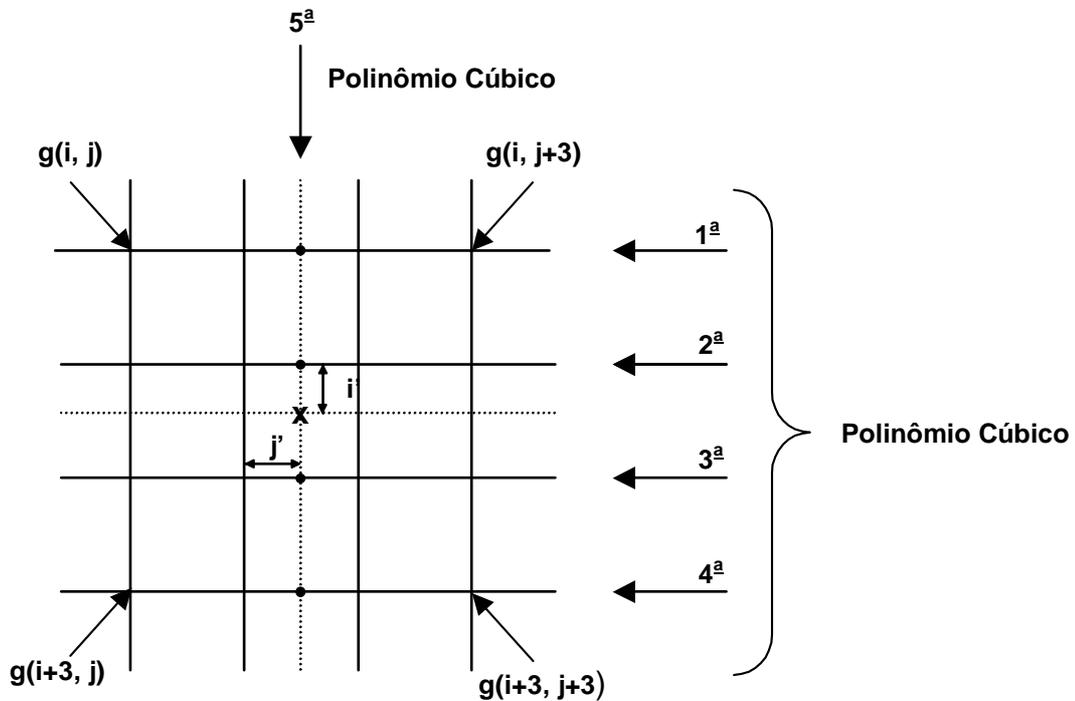


Figura 4 - Convolução Cúbica.

(Adaptado de Richards (1986))

A expressão 17 é calculada para cada uma das quatro linhas mostradas na figura 4, para produzir quatro interpolações: $g(i, j')$, $g(i+1, j')$, $g(i+2, j')$ e $g(i+3, j')$.

$$\begin{aligned}
 g(i, j') = & j' \{ j' (j' [g(i, j+3) - g(i, j+2) + g(i, j+1) - g(i, j)] + \\
 & [g(i, j+2) - g(i, j+3) - 2g(i, j+1) + 2g(i, j)])) \\
 & g(i, j+2) - g(i, j) \} + g(i, j+1)
 \end{aligned} \tag{17}$$

Então, para interpolar verticalmente o tom de cinza no ponto (i', j') , têm-se a expressão 18.

$$\begin{aligned}
 g(i', j') = & i' \{ i' (i' [g(i+3, j') - g(i+2, j') + g(i+1, j') - g(i, j')] + \\
 & [g(i+2, j') - g(i+3, j') - 2g(i+1, j') + 2g(i, j')]) + \\
 & [g(i+2, j') - g(i, j')] \} + g(i+1, j')
 \end{aligned} \tag{18}$$

A reamostragem por convolução cúbica resulta em uma ligeira suavização na imagem, maior do que a observada no método da interpolação bilinear. Devido à possibilidade dos novos valores de brilho interpolados serem um pouco diferentes do atual valor de radiância detectado pelo sensor de satélite, este método de reamostragem não é recomendável para a classificação (RICHARDS, 1986).

2.4 Correlação de Imagens

2.4.1 O Problema de Correlação

A correlação é um índice que descreve a dependência linear entre duas variáveis e serve como indicador do grau de similaridade entre este par de variáveis. Este princípio pode ser aplicado no processamento de imagem digitais para procurar determinados padrões em uma imagem ou pontos homólogos em

pares estereoscópicos, comparando uma matriz de amostra com as diferentes regiões da imagem. Os locais onde a matriz e a região da imagem forem similares serão caracterizados por um alto valor da correlação (STRAUCH, 1990).

De acordo com Heipke (1996 apud GALO e TOZZI, 1997) a correlação é definida como o procedimento para o estabelecimento de correspondência entre vários conjuntos de dados, que podem ser associados, como por exemplo, a imagens, mapas, modelos de objetos e dados de SIG.

Na implementação das técnicas de correlação digital é necessária a definição da janela alvo, ou janela de referência na primeira imagem, ou seja, o padrão bidimensional a ser procurado na segunda imagem. Uma outra janela, conhecida como a janela de pesquisa, é definida na segunda imagem, evitando assim que o algoritmo procure em toda a segunda imagem, evitando gastos computacionais desnecessários e outros problemas. A janela de pesquisa é definida em uma região onde se espera encontrar o alvo. A janela alvo deve ser de dimensão menor que a janela de pesquisa para possibilitar que ela se desloque dentro desta última. Ambas as janelas contêm valores digitais da imagem original. As janelas podem ser visualizadas na figura 5.

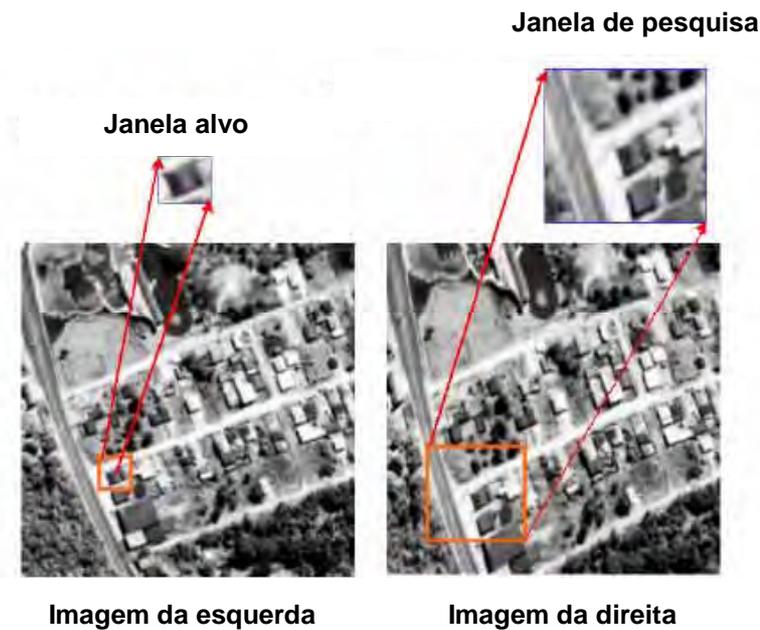


Figura 5 - Janela alvo e janela de pesquisa.
(Fonte: CENTENO; MACHADO; PEDRO, 2003)

Segundo Kraus (1993), no domínio da imagem, o algoritmo de correlação digital consiste basicamente em deslocar a janela alvo sobre a janela de pesquisa, calculando para cada posição, o valor da correlação entre os níveis de cinza das duas matrizes.

De uma forma geral, a correlação digital determina, sobre a janela de pesquisa, a melhor posição da janela alvo pré-definida na primeira imagem (DAL POZ e GALO, 1992). Assim, o pixel central da janela alvo e o mais similar da área de pesquisa são tomados como correspondentes (LEMMENS, 1988). Esse processo é geralmente melhor realizado através de duas etapas: a correlação aproximada e a correlação refinada. Na primeira etapa, através de funções de correlação, é realizada uma primeira aproximação para o problema. Já na segunda etapa, a matriz de tons de cinza formada pela janela alvo desliza sobre a janela de pesquisa,

procurando a melhor correlação pelo critério dos Mínimos Quadrados (DAL POZ e GALO, 1992).

A qualidade da correlação é determinada pelas características da imagem. Com o aumento da razão do sinal/ruído da imagem, a probabilidade de obter uma correlação correta aumenta. A precisão da correlação é determinada pelo conteúdo de frequência (a quantia de detalhes presentes) na imagem (FÖRSTNER, 1982 apud MIKHAIL; BETHEL; MCGLONE, 2001). A qualidade da correlação também é degradada pela presença de erros sistemáticos, tais como distorções das lentes ou refração atmosférica (MIKHAIL; BETHEL; MCGLONE, 2001).

Existem diversos métodos de correlação. Lemmens (1988) destaca três classes:

- Correlação areal;
- Correlação por entidades; e
- *Matching* Relacional.

A seguir, são dadas noções sobre estes métodos. A correlação areal, brevemente apresentada nos parágrafos acima, é apresentada com detalhes nas sub-seções 2.4.2 e 2.4.3.

2.4.1.1 Correlação Areal

Segundo Schenk (1999) a correlação areal é a mais popular em Fotogrametria e as entidades associadas são os níveis de cinza. A similaridade é indicada pela semelhança entre os níveis de cinza.

A idéia é comparar a distribuição de níveis de cinza de uma pequena sub-imagem, chamada de janela alvo com a uma outra imagem (janela de pesquisa). A janela alvo é uma porção da imagem, a qual normalmente permanece na posição fixada em uma das imagens. A janela de pesquisa refere-se ao espaço de pesquisa dentro da qual porções da imagem (janelas de correlação) são comparadas com a janela alvo (SCHENK, 1999).

A figura 6 mostra a janela alvo e a janela de pesquisa no processo de correlação, observando que a janela alvo desliza sobre a janela de pesquisa.

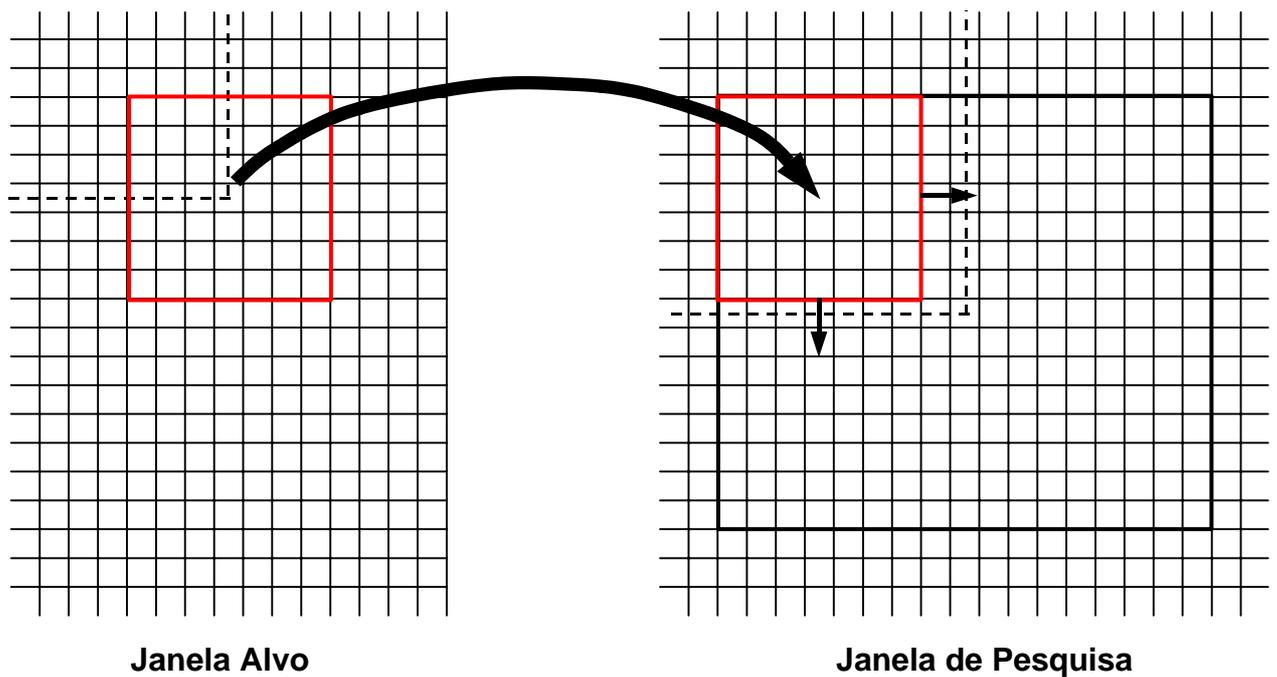


Figura 6 – Processo de correlação areal.

(Adaptado de LEMMENS, 1988)

A correlação areal pode ser melhorada (refinada) através do ajustamento por Mínimos Quadrados. Esta técnica permite um ajustamento ao nível do sub-pixel da posição obtida usando funções de correlação. Mais detalhes sobre a correlação por Mínimos Quadrados será dado na sub-seção 2.4.3

2.4.1.2 Correlação por Entidades

Devido às limitações da correlação areal, muitos sistemas estéreo usam correlação por feições, ou correlação por entidades. As feições podem ser pontos, linhas ou áreas (MIKHAIL; BETHEL; MCGLONE, 2001) sendo que em

fotogrametria digital, os pontos são mais utilizados (LEMMENS, 1988). Na correlação por entidades, ao contrário do método de correlação areal, as feições são detectadas em ambas as imagens (LEMMENS, 1988).

Segundo Schenk (s.d.) a correlação por entidades ganhou popularidade em visão computacional na década de 70 quando foi notado que a espantosa habilidade de visão estérea dos humanos é baseada em encontrar bordas homólogas. Os métodos de correlação por entidades são em geral mais robustos e requerem menos informações *a priori* (SCHENK, 1997).

Diversos detectores de pontos notáveis foram desenvolvidos, tais como os operadores de Marr-Hildreth, de Moravec e de Förstner. Para linhas e formas, os operadores básicos são os detectores de bordas combinados com métodos de vetorização (LEMMENS, 1988).

A seguir apresentam-se os princípios de correlação por entidades usando pontos notáveis, visto que o uso de pontos notáveis em correlação tem-se tornado bem mais comum em Fotogrametria.

A idéia básica de extração de pontos em uma imagem ou uma porção da imagem é identificar áreas com alta variância – áreas as quais são potencialmente aproveitáveis para correlação. Os operadores de pontos notáveis mais usados em Fotogrametria Digital são os operadores Moravec e Förstner (SCHENK, 1999).

O operador de Moravec é um operador simples para detectar pontos únicos em uma imagem e se baseia na medida de variância direcional, sendo desenvolvido originalmente para quatro direções. A resposta deste operador considera os valores dos quadrados das diferenças dos tons de cinza nas direções 0° , 45° , 90° e 135° (GALO e TOZZI, 2002). A variância em cada direção é calculada

como a soma das diferenças dos quadrados dos níveis de cinza entre os pixels vizinhos. Originalmente, para o cálculo das variâncias, é definida uma matriz de dimensão 5x5 (LEMMENS, 1988).

Förstner (1986 apud Lemmens, 1988) descreve um operador, o qual avalia a matriz de covariância do gradiente de imagem \mathbf{g}_x e \mathbf{g}_y em uma vizinhança. Diferentes feições podem ser detectadas, tais como pontos de canto e feições circulares (SCHENK, 1999).

Segundo Lemmens (1988) tem-se as seguintes etapas da correlação por entidades:

- 1) Detecção dos pontos característicos;

- 2) Verificação da similaridade entre possíveis pares de pontos homólogos de um estereopar de imagens, como, por exemplo, pares de pontos com alto coeficiente de correlação que podem ser homólogos. Este tipo de verificação normalmente conduz a ambigüidades.

- 3) Verificação de consistência através da busca por caminho de custo mínimo em grafo. Neste caso, os nós dos grafos são as possíveis correspondências determinadas no passo anterior e os arcos dos grafos são caracterizados pelo custo ou peso de cada correspondência. Por exemplo, quando se usa função de correlação, cujo valor ótimo é zero (caso da conhecida função erro), os pesos podem ser tomados como inversamente proporcionais aos valores retornados pela função de correlação.

Um exemplo de função custo bastante simples poderia ser definida como o somatório dos custos individuais de cada arco. Um exemplo de técnicas de otimização para encontrar o caminho ótimo (correspondências corretas) é a programação dinâmica.

Para melhorar a estratégia citada acima, normalmente se faz (LEMMENS, 1988):

- Uso de estratégia multiresolução: iniciando com imagem sub-amostrada, tem-se pouco ruído e apenas detalhes mais proeminentes. Assim, tem-se pouca ou nenhuma ambigüidade no topo da pirâmide. O resultado pode ser usado para uma primeira orientação das imagens;
- A confiabilidade da orientação pode ser melhorada com o uso de estratégia de detecção de erros grosseiros, como a estimativa robusta;
- Conhecidos os parâmetros de orientação exterior (primeira aproximação), pode-se gerar as linhas epipolares homólogas, as quais podem ser usadas na etapa 2 mencionada acima (verificação de similaridade entre pontos notáveis) para eliminar uma série de ambigüidades;
e
- O processo continua até atingir a imagem original na base, mas com forte injunção na geometria epipolar da imagem.

Tem-se no final:

- Resultados precisos;
- Confiabilidade (alta redundância); e
- Problema: para um par de imagens, os erros em \mathbf{x} são compensados em altura (\mathbf{h}).

2.4.1.3 Matching Relacional

O *matching* relacional, também denominado correlação estrutural, melhora a robustez da correlação por entidades considerando as relações entre estas. Uma correlação somente é aceita se as relações entre entidades de dois espaços (Por exemplo, duas imagens) são satisfeitas. O *matching* relacional para estereopares foi proposto primeiramente por Boyer e Kak (1988 apud Schenk, 1999) e introduzida na Fotogrametria por Vosselman (1992 apud Schenk, 1999), Cho (1996 apud Schenk, 1999) e Wang (1996 apud Schenk, 1999).

Conforme Wang (1998) a correlação estrutural estabelece uma correspondência entre duas descrições estruturais, (isto é, descrição de objetos por grafos). Uma descrição estrutural de uma imagem consiste de um conjunto de feições das imagens e a relação entre as feições como ilustrado na figura 7. As feições (pontos, linhas e regiões) são também referidas como primitivas. As primitivas e relações podem ser descritas por diversos atributos.

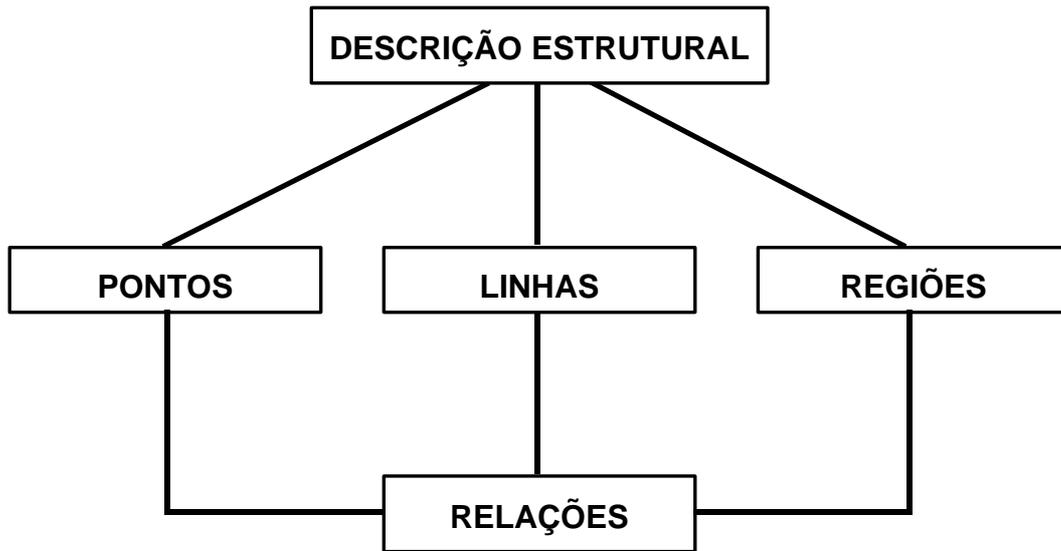


Figura 7 – Descrição estrutural de uma imagem

(Fonte: WANG, 1998).

O principal objetivo da correlação estrutural é encontrar uma melhor correlação entre as primitivas e relações de duas descrições estruturais. Em uma imagem as primitivas disponíveis e as relações entre elas podem ser milhares se duas imagens são parcialmente sobrepostas, então, uma correlação correta de duas descrições podem ser somente uma correspondência parcial de todas as primitivas e relações. Uma primitiva (ou relação) da primeira descrição pode ser correlacionada com uma, várias ou nenhuma primitiva (ou relação) da segunda descrição. No entanto, podem existir muitas correlações entre duas descrições estruturais (WANG, 1998).

2.4.2. Correlação Areal usando Funções de Correlação

Segundo Yanniris (1974) as funções de correlação são implementadas através de um eficiente algoritmo com as seguintes operações:

- Na imagem da esquerda seleciona-se uma região retangular contendo o alvo de interesse, a qual será denominado de janela alvo;
- Na imagem da direita seleciona-se uma área, onde possivelmente o alvo ou feição homóloga pode estar contido. Esta área é então denominada de janela de pesquisa, com dimensões maiores que a janela alvo; e
- Aplica-se uma função de correlação.

A função de correlação aplicada determina uma sub-matriz de dimensão igual ao da janela alvo na janela de pesquisa. Nesta sub-matriz, a função de níveis de cinza, dentro do critério estabelecido pela função de correlação aplicada, apresenta o comportamento mais semelhante à função de níveis de cinza da janela alvo. A sub-matriz obtida é então denominada de janela correlacionada (STRAUCH, 1990).

As funções de correlação são expressões matemáticas que determinam o grau de dependência linear entre duas funções de natureza igual, com a finalidade de comparar essas duas funções e verificar onde elas apresentam comportamento mais semelhante, ou seja, onde apresentam correlação (STRAUCH, 1990).

A seguir são apresentadas as funções de correlação onde:

- $g_r(i,j)$ é o valor do tom de cinza na posição (i,j) da janela alvo;
- $g_p(i,j)$ é o valor do tom de cinza na posição (i,j) da janela de pesquisa;
- r_x é o número de colunas da janela alvo;
- r_y é o número de linhas da janela alvo; e
- (a, b) é o deslocamento da janela alvo dentro da janela de pesquisa.

2.4.2.1 Função Erro

A função erro, também conhecida como função diferença, é apresentada da seguinte forma (YANNIRIS, 1974):

$$F_{\text{erro}}(\mathbf{a}, \mathbf{b}) = \frac{1}{r_x \cdot r_y} \cdot \sum_{i=0}^{r_y-1} \sum_{j=0}^{r_x-1} |g_r(i, j) - g_p(i + \mathbf{a}, j + \mathbf{b})| \quad (19)$$

Na equação 19 a posição de melhor correlação é encontrada quando o coeficiente $F_{\text{erro}}(\mathbf{a}, \mathbf{b})$ for mínimo.

2.4.2.2 Função Erro Quadrático

A função erro quadrático, também denominada como função diferença quadrada, pode ser expressa matematicamente por (YANNIRIS, 1974):

$$F_{e.\text{quad}}(\mathbf{a}, \mathbf{b}) = \frac{1}{r_x \cdot r_y} \cdot \sum_{i=0}^{r_y-1} \sum_{j=0}^{r_x-1} [g_r(i, j) - g_p(i + \mathbf{a}, j + \mathbf{b})]^2 \quad (20)$$

Analogamente à função erro, a posição de melhor correlação é encontrada quando o coeficiente $F_{e.\text{quad}}(\mathbf{a}, \mathbf{b})$ for mínimo.

A função erro quadrático, quando comparado à função erro, fornece a posição de melhor correlação com maior exatidão, pois é mais sensível às pequenas diferenças.

2.4.2.3 Função Covariância Cruzada

A função covariância cruzada é definida matematicamente por:

$$F_{\text{cov}}(\mathbf{a}, \mathbf{b}) = \frac{1}{r_x \cdot r_y} \cdot \sum_{i=0}^{r_y-1} \sum_{j=0}^{r_x-1} [g_r(i, j) - \bar{g}_r] [g_p(i + \mathbf{a}, j + \mathbf{b}) - \bar{g}_p] \quad (21)$$

Sendo que \bar{g}_r é a média dos tons de cinza da janela de referência dada pela equação 21.1 e \bar{g}_p é a média dos tons de cinza da janela de pesquisa no local onde a janela de referência convoluciona dada pela equação 21.2.

$$\bar{g}_r = \frac{1}{r_x \cdot r_y} \cdot \sum_{i=0}^{r_y-1} \sum_{j=0}^{r_x-1} g_r(i, j) \quad (21.1)$$

$$\bar{g}_{p(a,b)} = \frac{1}{r_x \cdot r_y} \cdot \sum_{i=0}^{r_y-1} \sum_{j=0}^{r_x-1} g_p(i + a, j + b) \quad (21.2)$$

Ao contrário das duas funções apresentadas anteriormente, a posição de melhor correlação é encontrada quando o coeficiente $F_{cov}(a,b)$ for máximo.

2.4.2.4 Função Correlação Cruzada

A função correlação cruzada é definida matematicamente por:

$$F_{cov_{mod}}(a,b) = \frac{1}{r_x \cdot r_y} \cdot \sum_{i=0}^{r_y-1} \sum_{j=0}^{r_x-1} [g_r(i, j)] [g_p(i + a, j + b)] \quad (22)$$

Esta função de correlação consiste no produto entre as janelas alvo e de pesquisa. A melhor correlação é encontrada quando o coeficiente $F_{\text{cov}_{\text{mod}}}(\mathbf{a}, \mathbf{b})$ for máximo.

2.4.2.5 Função Coeficiente de Correlação

A função coeficiente de correlação (equação 23) é uma variante da função covariância cruzada (sub-seção 2.4.2.3), sendo uma das mais utilizadas.

$$F_{\text{c.corr}}(\mathbf{a}, \mathbf{b}) = \frac{\sum_{i=0}^{r_y-1} \sum_{j=0}^{r_x-1} [g_r(i, j) - \bar{g}_r] [g_p(i + \mathbf{a}, j + \mathbf{b}) - \bar{g}_p]}{\sqrt{\sum (g_r(i, j) - \bar{g}_r)^2 \sum (g_p(i + \mathbf{a}, j + \mathbf{b}) - \bar{g}_p)^2}} \quad (23)$$

Esta função de correlação varia de -1 a 1 e o coeficiente de correlação mais próximo a 1 corresponde à melhor correlação.

2.4.2.6 Função Quociente

A função quociente é descrita da seguinte forma:

$$F_q(\mathbf{a}, \mathbf{b}) = \frac{1}{r_x \cdot r_y} \cdot \sum_{i=0}^{r_y-1} \sum_{j=0}^{r_x-1} \frac{g_p(\mathbf{i} + \mathbf{a}, \mathbf{j} + \mathbf{b})}{g_r(\mathbf{i}, \mathbf{j})} \quad (24)$$

Nesta função a posição de melhor correlação é encontrada quando o coeficiente $F_q(\mathbf{a}, \mathbf{b}) = 1$, com $g_r(\mathbf{i}, \mathbf{j}) \neq 0$.

2.4.3 Correlação usando o Método dos Mínimos Quadrados

Após o passo preliminar de detecção do alvo é então assumido que a localização do alvo é aproximadamente conhecida. Assim, a localização precisa da posição do alvo torna-se um processo local, confinado a uma sub-imagem com o alvo mais ou menos no centro. A principal vantagem do processo local é que os parâmetros e limiares podem ser determinados individualmente para toda essa sub-imagem. Com uma estratégia de controle inteligente é possível selecionar diferentes algoritmos para localizar o alvo com precisão e confiabilidade (SCHENK, 1997).

Conceitualmente, a correlação por Mínimos Quadrados é bem parecida com o método de correlação apresentado acima, com a vantagem de ser capaz de obter uma localização ao nível de sub-pixel (WOLF e DEWITT, 2000).

O método de correlação por Mínimos Quadrados é um processo iterativo, sendo que em cada iteração, equações de observação linearizadas são solucionadas pelo Método de Mínimos Quadrados para obter correções das aproximações (WOLF e DEWITT, 2000). Os valores estimados devem ser muito precisos, de modo que para muitas aplicações as aproximações sejam boas o

suficiente para o resultado final da correlação. Então, a correlação por Mínimos Quadrados é atualmente um método para refinar a correlação, levando-a para um alto nível de precisão (LEMMENS, 1988).

O método de correlação por Mínimos Quadrados será inicialmente introduzido através de uma suposição matemática bastante simples, facilitando a compreensão do método. Pode-se supor, então, que ambas as janelas envolvidas no processo de correlação se diferenciam apenas por duas translações (**a**, **b**):

$$\mathbf{x}_p = \mathbf{x}_a + \mathbf{a}; \quad (25)$$

$$\mathbf{y}_p = \mathbf{y}_a + \mathbf{b}. \quad (26)$$

Com:

- $\mathbf{g}_a = \mathbf{g}_a(\mathbf{x}_a, \mathbf{y}_a)$ é a função de nível de cinza da janela alvo; e
- $\mathbf{g}_p = \mathbf{g}_p(\mathbf{x}_p, \mathbf{y}_p)$ é a função de nível de cinza da janela de pesquisa.

Assumindo agora um ruído aditivo, pode-se escrever:

$$\mathbf{g}_a(\mathbf{x}_a, \mathbf{y}_a) + \mathbf{n}_a(\mathbf{x}_a, \mathbf{y}_a) = \mathbf{g}_p(\mathbf{x}_a + \mathbf{a}, \mathbf{y}_a + \mathbf{b}) + \mathbf{n}_p(\mathbf{x}_a + \mathbf{a}, \mathbf{y}_a + \mathbf{b}) \quad (27)$$

Considerando que:

$$\mathbf{n}(\mathbf{x}_a, \mathbf{y}_a) = \mathbf{n}_a(\mathbf{x}_a, \mathbf{y}_a) - \mathbf{n}_p(\mathbf{x}_a + \mathbf{a}, \mathbf{y}_a + \mathbf{b}) \quad (28)$$

Então, a equação mencionada acima (equação 27) torna-se:

$$\mathbf{g}_a(\mathbf{x}_a, \mathbf{y}_a) + \mathbf{n}(\mathbf{x}_a, \mathbf{y}_a) = \mathbf{g}_p(\mathbf{x}_a + \mathbf{a}, \mathbf{y}_a + \mathbf{b}) \quad (29)$$

A equação 29 é não linear. Para resolvê-la para (\mathbf{a}, \mathbf{b}) são necessários valores aproximados $(\mathbf{a}_0, \mathbf{b}_0)$ como mostrado nas equações 30 e 31:

$$\mathbf{a}_0 = \mathbf{a} - \mathbf{d}\mathbf{a}; \quad (30)$$

$$\mathbf{b}_0 = \mathbf{b} - \mathbf{d}\mathbf{b}. \quad (31)$$

Linearizando o segundo membro da equação 29 em torno de $(\mathbf{a}_0, \mathbf{b}_0)$:

$$\mathbf{g}_a(\mathbf{x}_a, \mathbf{y}_a) + \mathbf{n}(\mathbf{x}_a, \mathbf{y}_a) = \mathbf{g}_p(\mathbf{x}_a + \mathbf{a}_0, \mathbf{y}_a + \mathbf{b}_0) + \left[\frac{\partial \mathbf{g}_p}{\partial \mathbf{x}_p} \cdot \frac{\partial \mathbf{x}_p}{\partial \mathbf{a}} \quad \frac{\partial \mathbf{g}_p}{\partial \mathbf{y}_p} \cdot \frac{\partial \mathbf{y}_p}{\partial \mathbf{b}} \right] \cdot \begin{bmatrix} \mathbf{d}\mathbf{a} \\ \mathbf{d}\mathbf{b} \end{bmatrix} \quad (32)$$

Assim,

$$\mathbf{g}_a(\mathbf{x}_a, \mathbf{y}_a) - \mathbf{g}_p(\mathbf{x}_a + \mathbf{a}_0, \mathbf{y}_a + \mathbf{b}_0) + \mathbf{n}(\mathbf{x}_a, \mathbf{y}_a) = \begin{bmatrix} \frac{\partial \mathbf{g}_p}{\partial \mathbf{x}_p} \cdot \frac{\partial \mathbf{x}_p}{\partial \mathbf{a}} & \frac{\partial \mathbf{g}_p}{\partial \mathbf{y}_p} \cdot \frac{\partial \mathbf{y}_p}{\partial \mathbf{b}} \end{bmatrix} \cdot \begin{bmatrix} \mathbf{d}\mathbf{a} \\ \mathbf{d}\mathbf{b} \end{bmatrix} \quad (33)$$

Fazendo $\Delta \mathbf{g} = \mathbf{g}_a(\mathbf{x}_a, \mathbf{y}_a) - \mathbf{g}_p(\mathbf{x}_a + \mathbf{a}_0, \mathbf{y}_a + \mathbf{b}_0)$ e observando que

$$\frac{\partial \mathbf{x}_p}{\partial \mathbf{a}} = \frac{\partial \mathbf{y}_p}{\partial \mathbf{b}} = \mathbf{1}, \text{ tem-se:}$$

$$\Delta \mathbf{g} + \mathbf{n}(\mathbf{x}_a, \mathbf{y}_a) = \begin{bmatrix} \frac{\partial \mathbf{g}_p}{\partial \mathbf{x}_p} & \frac{\partial \mathbf{g}_p}{\partial \mathbf{y}_p} \end{bmatrix} \cdot \begin{bmatrix} \mathbf{d}\mathbf{a} \\ \mathbf{d}\mathbf{b} \end{bmatrix} \quad (34)$$

Com:

- $\Delta \mathbf{g} \rightarrow$ igual à diferença entre os valores de cinza em pontos das janelas alvo e de pesquisa;
- $\begin{bmatrix} \frac{\partial \mathbf{g}_p}{\partial \mathbf{x}_p} & \frac{\partial \mathbf{g}_p}{\partial \mathbf{y}_p} \end{bmatrix} = [\mathbf{g}\mathbf{x} \quad \mathbf{g}\mathbf{y}] \rightarrow$ gradiente da imagem calculado em pontos da janela de pesquisa; e
- $[\mathbf{d}\mathbf{a} \quad \mathbf{d}\mathbf{b}]^T \rightarrow$ vetor correção.

Supondo uma janela alvo com \mathbf{k} elementos, a aplicação da equação

34 permite obter as seguintes matrizes:

$$\mathbf{A}_{k \times 2} = \begin{bmatrix} \mathbf{g}x_1 & \mathbf{g}y_1 \\ \mathbf{g}x_2 & \mathbf{g}y_2 \\ \vdots & \vdots \\ \mathbf{g}x_k & \mathbf{g}y_k \end{bmatrix} \quad (35)$$

$$\mathbf{Lb}_{k \times 1}^T = [\Delta \mathbf{g}_1 \quad \Lambda \quad \Delta \mathbf{g}_k] \quad (36)$$

$$\mathbf{P} = \mathbf{I}_{k \times k} \quad (37)$$

A equação 37 significa que as observações são admitidas como estatisticamente independentes e com a mesma qualidade.

A solução através do ajustamento por Mínimos Quadrados é mostrada na equação 38:

$$\begin{bmatrix} \mathbf{d}a \\ \mathbf{d}b \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^k \mathbf{g}x_i^2 & \sum_{i=1}^k \mathbf{g}x_i \mathbf{g}y_i \\ \sum_{i=1}^k \mathbf{g}x_i \mathbf{g}y_i & \sum_{i=1}^k \mathbf{g}y_i^2 \end{bmatrix}^{-1} \cdot \begin{bmatrix} \sum_{i=1}^k \mathbf{g}x_i \cdot \Delta \mathbf{g}_i \\ \sum_{i=1}^k \mathbf{g}y_i \cdot \Delta \mathbf{g}_i \end{bmatrix} \quad (38)$$

$\underbrace{\hspace{10em}}_{\mathbf{A}^T \mathbf{A}} \qquad \underbrace{\hspace{10em}}_{\mathbf{A}^T \mathbf{L}b}$

Devido à linearização, iterações são necessárias até que $\mathbf{d}a = \mathbf{d}b \rightarrow \mathbf{0}$. No início, pode-se adotar $\mathbf{a}_0 = \mathbf{b}_0 = \mathbf{0}$, implicando na não necessidade de se reamostrar pontos na janela correlacionada. A partir da 1ª iteração tem-se $\mathbf{a}_0 \neq \mathbf{0}$ e $\mathbf{b}_0 \neq \mathbf{0}$, implicando que $\mathbf{x}_a + \mathbf{a}_0$ e $\mathbf{y}_a + \mathbf{b}_0$ não coincidem mais com pixels

da janela correlacionada. Assim, os tons de cinza de pontos desta janela têm que ser reamostrado para possibilitar o cálculo de Δg_i e (g_{x_i}, g_{y_i}) .

Além dos deslocamentos, outras diferenças geométricas e radiométricas entre as áreas alvo e de pesquisa podem ser introduzidas. Normalmente usa-se uma transformação afim:

$$\begin{cases} x_p = a_0 + a_1 x_a + a_2 y_a \\ y_p = b_0 + b_1 x_a + b_2 y_a \end{cases} \quad (39)$$

As diferenças radiométricas são freqüentemente assumidas como lineares:

$$g_a = k_0 + k_1 g_p \quad (40)$$

Soluções encontradas em Fotogrametria freqüentemente fazem uso das equações 39 e 40. Nesse caso, têm-se 8 parâmetros ($a_0, a_1, a_2, b_0, b_1, b_2, k_0, K_1$) a serem estimados contra dois da solução aproximada apresentada acima.

Uma vez que os parâmetros da transformação são calculados, um ponto representativo na área alvo tem que ser selecionado e transferido para a área de pesquisa. As coordenadas do centro do pixel central da janela alvo pode ser apropriado. Conforme Pertl (1985 apud LEMMENS, 1988) pode-se tomar o centro de gravidade, o qual tem o peso dos quadrados dos gradientes (equações 41 e 42).

$$\bar{x}_a = \frac{\sum_i x_{a,i} g_{x,i}^2}{\sum_i g_{x,i}^2} \quad (41)$$

$$\bar{y}_a = \frac{\sum_i y_{a,i} g_{y,i}^2}{\sum_i g_{y,i}^2} \quad (42)$$

A precisão da correlação depende de:

- $\sigma_0^2 \rightarrow$ variância do ruído na imagem;
- $n \rightarrow$ número de pixels envolvidos;
- $\sigma_{gx}^2, \sigma_{gy}^2, \sigma_{gx,gy}^2 \rightarrow$ as variâncias e covariâncias dos gradientes nas direções x e y :

Uma estimativa ($\hat{\sigma}_0^2$) de σ_0^2 pode ser obtida através dos resíduos v_i , calculados após a convergência do processo de ajustamento envolvido na correlação por Mínimos Quadrados:

$$\hat{\sigma}_0^2 = \sum_i \frac{v_i^2}{r} \quad (43)$$

sendo r a redundância no ajustamento.

Para as variâncias σ_x e σ_y , a precisão da posição é dada por (LEMMENS, 1988):

$$\sigma_x^2 = \frac{1}{n} \cdot \frac{\sigma_0^2}{\sigma_{gx}^2} \quad (44)$$

$$\sigma_y^2 = \frac{1}{n} \cdot \frac{\sigma_0^2}{\sigma_{gy}^2} \quad (45)$$

No caso, a razão do sinal/ruído (RSR) é conhecida como:

$$RSR = \frac{\sigma_g}{\sigma_0} \quad (46)$$

com σ_g sendo a variância do sinal.

As equações dadas acima (equações 44 e 45) podem ser substituídas por:

$$\sigma_x^2 = \frac{1}{nRSR^2} \cdot \frac{\sigma_g^2}{\sigma_{gx}^2}; \quad (47)$$

$$\sigma_y^2 = \frac{1}{nRSR^2} \cdot \frac{\sigma_g^2}{\sigma_{gy}^2}. \quad (48)$$

Nas áreas onde os níveis de cinza são mais homogêneos, isto é, baixa textura e poucas bordas, ambos σ_{gx}^2 e σ_{gy}^2 serão pequenos e conseqüentemente σ_x^2 e σ_y^2 serão grandes, o que está de acordo com a intuição. As equações 47 e 48 mostram que em áreas homogêneas não é possível realizar a correlação. Também, como esperado, quanto maior a razão sinal/ruído (**RSR**), maior a precisão da correlação.

A correlação por Mínimos Quadrados é muito acurada, mas pode ser sujeita aos mesmos problemas de outros algoritmos de correlação, tais como áreas de difícil correlação sem variação ou textura suficiente. No entanto, a maior vantagem da correlação por Mínimos Quadrados é que a qualidade dos resultados pode ser avaliada usando técnicas estatísticas bem estabelecidas. A precisão dos parâmetros de transformação estimados indica como a correlação foi realizada. Se a precisão é baixa, alguns dos parâmetros podem ser removidos da solução (mudando para um modelo geométrico simples, por exemplo) e a correlação é refeita. O sucesso da correlação por Mínimos Quadrados é dependente de se ter boas aproximações iniciais para os parâmetros de correlação (MIKHAIL; BETHEL; MCGLONE, 2001).

Uma vez que duas porções das imagens são associadas por meio de uma porção comum da superfície através da projeção central, deve-se usar um modelo de projeção central. As janelas de correlação e a porção da correspondente superfície são normalmente pequenas, podendo esta última ser aproximada por um plano. Com esta simplificação, as porções das imagens e a porção da superfície são relacionadas através de uma transformação projetiva (transformação de oito parâmetros). Quando a superfície não apresentar bruscas variações, pode-se

simplificar o problema através da aproximação da transformação projetiva pela transformação afim (SCHENK, 1999).

A transformação geométrica entre as porções das imagens, tais como, relação polinomial e transformações afim ou projetiva, é incluída na solução para considerar a diferença dos pontos de vistas entre as duas imagens. A solução da correlação então tenta minimizar as diferenças radiométricas entre as porções das imagens enquanto calculam-se os parâmetros geométricos e radiométricos. A geometria epipolar entre as imagens pode também ser usada para injuncionar a correlação (MIKHAIL; BETHEL; MCGLONE, 2001).

3. METODOLOGIA PARA EXTRAÇÃO DE RODOVIA

3.1 Considerações Iniciais

O Capítulo 3 está dividido em 3 principais seções, sendo que a seção 3.2 trata de noções básicas de modelagem e extração de rodovias. A seção 3.3 apresenta uma descrição do modelo de extração proposto e utilizado neste trabalho.

3.2 Noções Básicas sobre Modelagem e Extração de Rodovias

Conforme mostrado em Dal Poz (2000), uma malha viária pode ser modelada através de dois modelos: o modelo intrínseco, que abrange os aspectos geométricos, radiométricos e topológicos, e o modelo contextual.

O aspecto geométrico trata de propriedades geométricas da entidade rodovia, tais como, largura, anti-paralelismo dos lados, curvatura etc.. O aspecto radiométrico refere-se à homogeneidade dos tons de cinza dos pixels das rodovias. O aspecto ligado à topologia descreve a malha viária composta de arcos (rodovias) e nós (intersecções). Em relação ao modelo contextual, este descreve as relações entre a rodovia e outros objetos.

Os aspectos topológicos e contextuais relacionam-se com tarefas mais complexas de reconhecimento e, portanto, na presente pesquisa, são deixadas a cargo do operador. As propriedades geométricas e radiométricas mais importantes da rodovia serão tratadas a seguir (LI, 1997; GRÜEN e LI, 1997; DAL POZ e AGOURIS, 2000a).

A primeira propriedade estabelece que os pixels de uma rodovia são mais claros que os de fundo, considerando a rodovia como uma faixa contínua, estreita e de alta intensidade de brilho, margeada por um fundo de baixa intensidade. A segunda propriedade considera que o material de rolagem (asfalto, concreto) não varia muito em distâncias curtas, implicando em respostas espectrais semelhantes em curtos segmentos. Ambas as propriedades citadas acima são radiométricas. Uma terceira propriedade é uma generalização das duas primeiras propriedades. A quarta propriedade é geométrica e se trata da suavidade da rodovia que normalmente é composta por segmentos de retas e curvas suaves. A quinta propriedade estabelece que a curvatura local de uma rodovia possui um limite máximo e finalizando, tem-se o fato da largura da rodovia ser normalmente constante, gerando assim a sexta propriedade.

As propriedades citadas acima, geralmente, são usadas implícita ou explicitamente em todos os modelos de extração de rodovia. Um exemplo, em Dal Poz et al. (2000b), todas as propriedades são usadas explicitamente para formular um modelo matemático de rodovia, o qual é resolvido através de um algoritmo de otimização global de programação dinâmica. Este também é o caso da solução proposta em Li (1997) envolvendo a curva *snakes*. Em se tratando da presente pesquisa, todas as propriedades são assumidas na formulação do modelo de extração.

Na literatura das áreas de fotogrametria digital e visão computacional existem diversas técnicas de extração de rodovias, mas geralmente podem ser identificadas 5 etapas distintas (DAL POZ, 2000): realce da rodovia, detecção e extração de pontos sementes, extração de segmentos de rodovia, ligação dos segmentos da rodovia e geração da malha viária.

Na primeira etapa, para facilitar o processamento nas etapas futuras, é aplicado em toda a imagem algum operador de gradiente (ex: Sobel, Nevatia e Babu) realçando a estrutura da rodovia. Nesta etapa, geralmente, em cada pixel da imagem são calculadas a magnitude e a direção.

A partir da imagem realçada, a segunda etapa detecta os pontos sementes que são indícios do local onde está a rodovia. No caso de métodos automáticos, a detecção desses pontos geralmente se baseia em informações de bordas. Já no método semi-automático, o operador deve intervir e identificar os pontos sementes.

No momento da extração da rodovia, geralmente o processo é interrompido por problemas ocasionados por ruídos na imagem, sombras provocadas por outras feições e obstruções na rodovia. Uma forma de resolver esses problemas é extrair, propositalmente, os segmentos de rodovia nesta etapa.

A próxima etapa, então, é a conexão dos segmentos de rodovia.

A última etapa é a geração da malha viária através da reconstrução dos cruzamentos de rodovia, possibilitando a extração de uma malha correta, inclusive do ponto de vista topológico.

Vale ressaltar que nem todos os métodos possuem todas as etapas acima. Por exemplo, a segunda etapa só está presente em métodos semi-automáticos.

3.3 Extração Semi-Automática de Feições em Imagens Digitais usando Técnicas de Correlação e o Princípio de Teste Ativo

O traçador de rodovia proposto por Quam (1978) baseia-se numa estratégia de correlação unidimensional envolvendo perfis de tons de cinza extraídos transversalmente ao longo do eixo da rodovia. De uma forma geral, compara-se um perfil modelo, calculado no início do processo de extração e atualizado continuamente ao longo do processo, com perfis extraídos durante o delineamento do eixo central da rodovia. Cada novo perfil é extraído tendo por base uma posição extrapolada utilizando uma modelagem da direção da rodovia, por meio de um processo baseado na estratégia de teste ativo. O processo de comparação entre os perfis é realizado pela técnica de correlação híbrida, utilizando uma função de correlação e o ajustamento pelo Método dos Mínimos Quadrados, cujo objetivo é refinar a posição extrapolada.

O princípio proposto por Quam (1978) é utilizado nesta pesquisa para a implementação de um sistema semi-automático para a extração de rodovias em imagens digitais de média e alta resolução (MENDES, 2002; MENDES e DAL POZ, 2002). A idéia básica dos extratores semi-automáticos é a de que tarefas mais complexas, tais como o reconhecimento e a identificação do objeto rodovia, fiquem a cargo do operador humano, enquanto as tarefas demoradas e cansativas de medida sejam realizadas através do algoritmo computacional. A intervenção do operador é requerida em dois momentos. Num primeiro, no início do processo de extração, fornecendo alguns dados de entrada (posição e direção num ponto, largura média da rodovia). O outro momento é quando o algoritmo não pode prosseguir sozinho,

devido às irregularidades presentes no leito da rodovia, necessitando novamente de informações externas para reinicializar (i.e., posição e direção num ponto), ou até mesmo, finalizar o processo de extração (MENDES, 2002).

A seguir será descrito como são realizadas as etapas de inicialização e de delineamento seqüencial do eixo da rodovia.

3.3.1 Inicialização

A inicialização é efetuada pelo operador através do mouse, que indica dois pontos sementes (P_1 e P_2) em uma região aproximadamente reta da rodovia (figura 8). O primeiro ponto indica o início da rodovia e o segundo a sua direção. Neste momento, é necessário também que o operador forneça visualmente a largura (em pixels) aproximada da rodovia (w).

As coordenadas linha e coluna dos pontos sementes são coletadas com a utilização de algum *software* comercial para processamento de imagens. Os dois primeiros pontos sementes de um conjunto devem ser fornecidos numa porção aproximadamente reta da rodovia. Um outro ponto deve ser fornecido indicando o ponto de parada, onde a extração do segmento é encerrada.

Entre os dois pontos sementes (P_1 e P_2), uma seqüência de pontos é obtida através de um processo sucessivo de interpolação linear (figura 8). Em cada ponto da seqüência obtida é extraído um perfil de tons de cinza transversal ao eixo da rodovia, por meio de algum método de interpolação de tons de cinza. Através da

média desses perfis de tons de cinza é obtido o perfil modelo de tons de cinza, que será utilizado posteriormente na etapa de delineamento da rodovia.

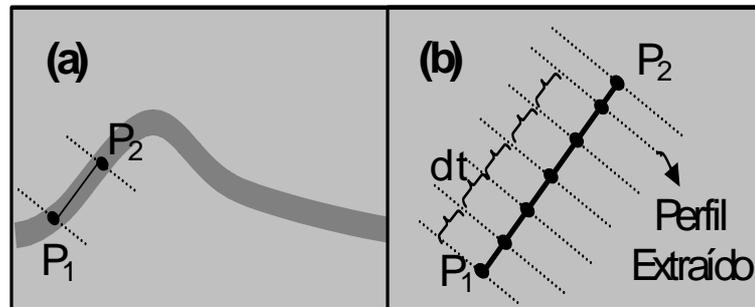


Figura 8 - Inicialização do processo. (a) Segmento de reta formado pelos pontos iniciais P_1 e P_2 . (b) Seqüência de pontos e extração do perfil modelo.

3.3.1.1 Interpolação de um Ponto Qualquer (Q_{i+1})

Sejam $P_1(L_{P1}, C_{P1})$ e $P_2(L_{P2}, C_{P2})$ os pontos sementes fornecidos pelo operador (figura 9). O ponto a ser interpolado a uma distância dt a partir do ponto $Q_i (L_{Qi}, C_{Qi})$ é representado por $Q_{i+1} (L_{Qi+1}, C_{Qi+1})$.

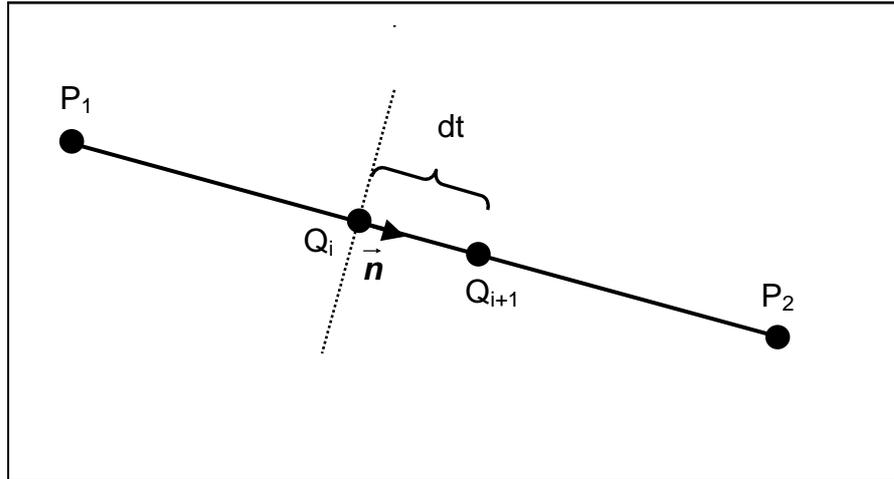


Figura 9 - Processo de interpolação.

A equação para interpolar Q_{i+1} a partir de Q_i , é dada por:

$$\begin{bmatrix} L_{Q_{i+1}} \\ C_{Q_{i+1}} \end{bmatrix} = dt \cdot \vec{n} + \begin{bmatrix} L_{Q_i} \\ C_{Q_i} \end{bmatrix} \quad (49)$$

onde $|\vec{n}| = 1$ (vetor unitário correspondente à direção definida pelos pontos P_1 e P_2);

$$\vec{n} = \left(\frac{L_{P_2} - L_{P_1}}{d}, \frac{C_{P_2} - C_{P_1}}{d} \right) = (\alpha, \beta) ;$$

(50)

$$d = \sqrt{(L_{P_2} - L_{P_1})^2 + (C_{P_2} - C_{P_1})^2}$$

3.3.1.2 Extração de um Perfil em Q_{i+1}

Na posição interpolada (Q_{i+1}), uma seção perpendicular à rodovia é tomada, e nesta é estabelecida uma janela 1D através da amostragem de tons de cinza de pontos espaçados regularmente. As posições dos pontos na janela são calculadas através da seguinte equação:

$$\begin{bmatrix} \mathbf{L} \\ \mathbf{C} \end{bmatrix}_J = \mathbf{K} \cdot \mathbf{r} \cdot \begin{bmatrix} -\beta \\ \alpha \end{bmatrix} + \begin{bmatrix} \mathbf{L}_{Q_{i+1}} \\ \mathbf{C}_{Q_{i+1}} \end{bmatrix} \quad (51)$$

Sendo que:

- $(\mathbf{L}, \mathbf{C})_J$: são as coordenadas de pontos amostrados na janela;
- $(\mathbf{L}_{Q_{i+1}}, \mathbf{C}_{Q_{i+1}})$: coordenadas de um ponto interpolado do eixo da rodovia, sendo este o centro da janela (ou perfil);
- \mathbf{K} : varia de $1, \dots, \mathbf{n}_{\text{mod}}$ num lado do eixo da rodovia e de $-1, \dots, -\mathbf{n}_{\text{mod}}$ noutro lado do eixo da rodovia;
- $\vec{\mathbf{n}}_0 = (-\beta \ \alpha)$: é um vetor unitário perpendicular ao eixo da rodovia, sendo, portanto normal ao vetor $\vec{\mathbf{n}} = (\alpha \ \beta)$, já definido anteriormente na equação 50;
- \mathbf{r} : é a resolução da janela (ou perfil). A fim de possibilitar uma precisão sub-*pixel*, o valor de \mathbf{r} deve ser menor que 1 *pixel*; e
- \mathbf{n}_{mod} : é o número de pontos reamostrados em cada lado do eixo da rodovia, sendo calculado da seguinte forma:

$$n = \text{int}(0,55 \cdot w) + 1 \quad (52)$$

Para definir o parâmetro n_{mod} (equação 52), primeiramente é adotada a largura da janela de busca (em pixel) como sendo igual à largura da rodovia (w) com uma tolerância de 10%, ou seja, $1,1w$. Com essa tolerância, toma-se uma janela de busca um pouco maior que largura da rodovia, possibilitando, numa próxima etapa, realizar a correlação. Finalmente, calculam-se os tons de cinza para as posições da janela definida acima através de um processo de reamostragem ou interpolação de tons de cinza. Para tal, geralmente, são utilizados os métodos de interpolação bilinear, interpolação pelo vizinho mais próximo e convolução cúbica (RICHARDS, 1986).

3.3.1.3 Obtenção do Perfil Modelo e de uma Seqüência de Pontos

Como mostra a figura 8(b), uma lista de pontos é amostrada ao longo do segmento de inicialização. Esses pontos são obtidos através do emprego da equação 49 a passo (dt) constante. Se d for a distância entre os pontos sementes P_1 e P_2 , então o número de pontos a serem amostrados é $\lambda = \text{int}(d/dt)$. Como ambos os pontos sementes devem ser incluídos na lista de inicialização, então a lista final é $\{P_1, Q_1, \Lambda, Q_\lambda, P_2\}$.

O perfil modelo, a ser usado para continuar a extração da rodovia na próxima etapa, é obtido através de uma média aritmética dos elementos (tons de

cinza) correspondentes dos perfis de tons de cinza extraídos nos pontos da lista de inicialização.

3.3.2 Delineamento da Rodovia

No delineamento da rodovia, o método proposto por Quam (1978) e implementado por Mendes e Dal Poz (2002), é modificado usando um processo de extrapolação baseado no princípio de teste ativo, que possibilita a análise das informações situadas adiante do último ponto extraído, tornando assim, o método mais robusto no tratamento de irregularidades presentes nas rodovias e nas adjacências.

Esta etapa é baseada no mesmo princípio usado na inicialização (etapa anterior). Mas existem algumas diferenças fundamentais.

Na inicialização, o segmento da rodovia selecionado era reto. Já nesta etapa, a rodovia apresenta forma desconhecida e não se realiza uma interpolação para definir o outro ponto a ser extraído, e sim uma extrapolação baseada no princípio de teste ativo. Uma outra diferença é em relação à posição extrapolada, que nesta etapa necessita ser refinada através do processo de correlação, estudada no Capítulo 2.

Para realizar a extrapolação e extração de um único ponto são necessários os seguintes passos: modelagem da trajetória da rodovia através do princípio de teste ativo; extração de um perfil medido; correlação entre o perfil medido e o perfil modelo; validação do novo ponto, refinamento do novo ponto

usando correlação pelo MMQ, atualização do perfil modelo e generalização do processo de extração. Todos os passos são descritos a seguir:

3.3.2.1 Modelagem da Trajetória da Rodovia através do Princípio de Teste Ativo

O teste ativo é uma estratégia bastante utilizada para extrair feições lineares e outras entidades em imagens digitais. Esta estratégia está relacionada com uma outra, ainda mais ampla, denominada visão ativa (DAL POZ e SILVA, 2002).

As técnicas de visão ativa procuram simular a visão humana (MARCHAND e CHAUMETTE, 1999). É muito importante, quando se trata de visão natural, considerar a adaptação do processo perspectivo às mudanças de posição de cabeça, aos rápidos movimentos dos olhos para visar diferentes regiões da cena e às variações de iluminação da cena. Assim, os sistemas computacionais de visão ativa devem apresentar como característica fundamental uma adaptação contínua envolvendo o sistema sensor-cena.

Neste sentido, o principal objetivo dos sistemas computacionais de visão ativa é geralmente o de adaptar ou determinar continuamente os parâmetros do sensor, como por exemplo, posição, atitude, velocidade, distância focal etc., auxiliando assim as tarefas de reconhecimento.

Os sistemas computacionais de teste ativo procuram identificar e extrair objetos usando basicamente os dados de imagem, ou seja, estes sistemas

não exploram a adaptação contínua dos parâmetros do sensor para a obtenção de novas informações sobre a cena que auxiliam nas tarefas de reconhecimento.

De acordo com Geman e Jedynak (1996), a estratégia de teste ativo pode ser definida como um processo em que uma imagem é explorada seqüencialmente para extrair informações que possibilitem a identificação de um ou mais objetos presentes na cena, cujos modelos encontram-se armazenados em uma biblioteca (rodovias, estradas, rios, divisa de culturas, viadutos, edificações etc.).

Neste sentido, a estratégia de teste ativo torna-se adequada para a modelagem da trajetória local de rodovias, uma vez que utiliza informações situadas adiante do último ponto extraído e possibilita um melhor tratamento das irregularidades presentes no leito da rodovia e adjacências.

3.2.2.1.1 Definição de uma Janela de Pesquisa

No início do processo de extração, a rodovia apresenta uma direção local definida pelos pontos sementes e o modelo de rodovia é dado pelo conjunto de pontos extraídos na inicialização. Nesta etapa, a rodovia apresenta forma e direção desconhecidas. A estratégia de teste ativo é utilizada para a modelagem e determinação da melhor direção local da rodovia. A figura 10 mostra o princípio do processo de extrapolação usando a estratégia de teste ativo. No último ponto extraído atualmente (P_2), é definida uma janela de pesquisa bidimensional, perpendicular à direção dada, respectivamente pelo último e pelo penúltimo ponto extraído (P_2 e P_1). As dimensões da janela de pesquisa dependem de parâmetros

(altura e profundidade) e da largura média da rodovia, fornecidos no início do processo de extração. Esses parâmetros devem ser tais que possibilitem a definição de uma janela maior que a largura da rodovia, que permitirá a obtenção de informação acerca da rodovia e das adjacências.

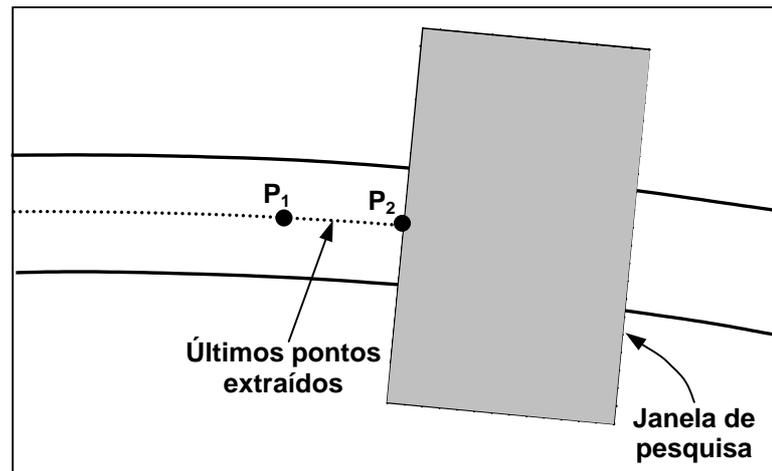


Figura 10 - Estabelecimento da janela de pesquisa perpendicular ao segmento de rodovia dado pelos últimos pontos extraídos.

A resolução da janela de pesquisa é a mesma da imagem original, sendo que esta é representada por uma matriz de tons de cinza, calculados em função de um conjunto de pontos amostrados na região da imagem que está sendo explorada. Esses tons de cinza são obtidos por algum método de interpolação. No presente trabalho, utiliza-se o método de interpolação bilinear.

A execução do teste ativo é feita através de uma estratégia de correlação bidimensional utilizando a função de correlação erro quadrático (Capítulo 2), envolvendo a janela de pesquisa e máscaras, representando modelos de rodovia (figura 11).

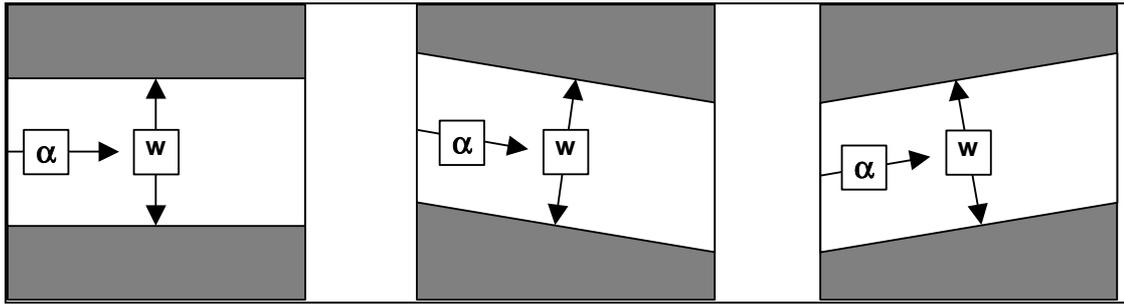


Figura 11 - Exemplos de máscaras contendo modelos de rodovia.

3.2.2.1.2 Construção dos Modelos de Representação da Rodovia

Como pode ser visto pela figura 11, as máscaras são criadas para armazenar modelos associados às possíveis direções locais de um segmento de rodovia. Para a construção das máscaras são utilizados os seguintes parâmetros ilustrados na figura 12:

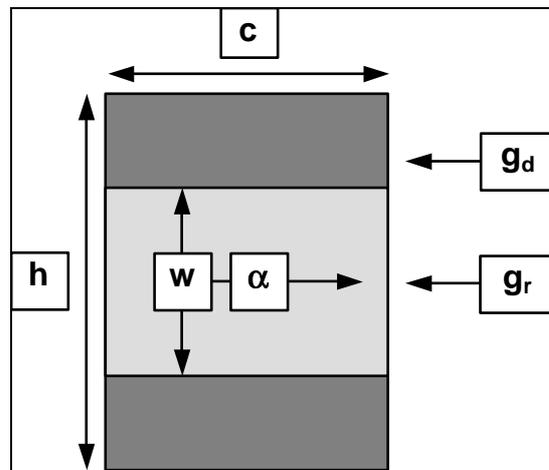


Figura 12 - Parâmetros de construção de uma máscara.

- Largura da máscara (c): é um valor inteiro calculado em função da largura da rodovia. A largura de uma máscara deve ser idêntica à largura da janela de pesquisa;
- Altura da máscara (h): é um valor inteiro calculado em função da largura da rodovia. Deve ser menor que a altura da janela de pesquisa e maior que a largura da rodovia;
- Tom de cinza representando a rodovia (g_r): é assumido como o valor central do perfil modelo extraído na inicialização. É usado para preencher os elementos da máscara correspondente ao segmento de rodovia modelado;
- Tom de cinza de fundo (g_d): é calculado pela média aritmética dos elementos extremos do perfil modelo extraído na inicialização. É usado para preencher os elementos da máscara correspondente às adjacências ao segmento de rodovia modelado;
- Passo de direção (p_{dir}): é usado para calcular a direção (α) do segmento de rodovia modelado pela máscara. Sua escolha depende da precisão desejada para a direção e das dimensões da máscara a ser criada. Como exemplo, pode-se usar um passo de 1° ;
- Variação de direção global (v_{dir}): representa a magnitude da variação de direção do segmento de rodovia a ser extraído. Considerando-se que os segmentos de rodovia são

geometricamente suaves, esse valor é pequeno, da ordem de 3° a 5°.

A variação de direção de um segmento de rodovia a ser extraído corresponde à direção α associada à máscara k , cujo valor é obtido pela seguinte expressão:

$$\alpha_k = k \cdot p_{dir} - v_{dir} \quad (53)$$

O número total de máscaras a construir (t_m), é calculado pela equação seguinte, dada em função dos parâmetros v_{dir} e p_{dir} .

$$t_m = \text{int}(2 \cdot v_{dir} / p_{dir}) + 1 \quad (54)$$

Na equação 53, o identificador k varia no intervalo $[0, K, t_m - 1]$. Para construir uma máscara de direção α_k , as colunas e linhas são preenchidas com os valores dos tons de cinza que representam a rodovia (g_r) e as adjacências (g_d). Para tanto, é calculada a posição da linha central da máscara correspondente a uma coluna j através da equação:

$$L = \text{int}((h/2) + (c/2 - j) \cdot \tan(\alpha_k)) \quad (55)$$

O valor obtido pela equação anterior é então comparado à posição da linha atual. Se estiver contido no intervalo $[L - w/2, K, L + w/2]$, então a posição dada pela linha e coluna atuais assume o valor do tom de cinza que representa os valores de brilho da rodovia, caso contrário a posição atual dentro da máscara recebe o tom de cinza que representa o valor de brilho das adjacências. O intervalo $[L - w/2, K, L + w/2]$ dentro da máscara corresponde ao leito do segmento de rodovia.

3.2.2.1.3 Determinação da Melhor Direção Local da Rodovia

Para encontrar a melhor direção local da rodovia, as máscaras deslizam, uma a uma, no sentido indicado na figura 13, sobre a janela de pesquisa, procurando pelo menor coeficiente de correlação. A máscara que melhor se correlacionar com a janela de pesquisa, ou seja, que possuir o menor coeficiente de correlação, é a máscara correspondente à melhor variação local de direção da rodovia. A melhor direção local do segmento de rodovia onde será realizada a extrapolação de um ponto é calculada em função da direção dada pelos últimos pontos extraídos e da variação de direção dada pela máscara.

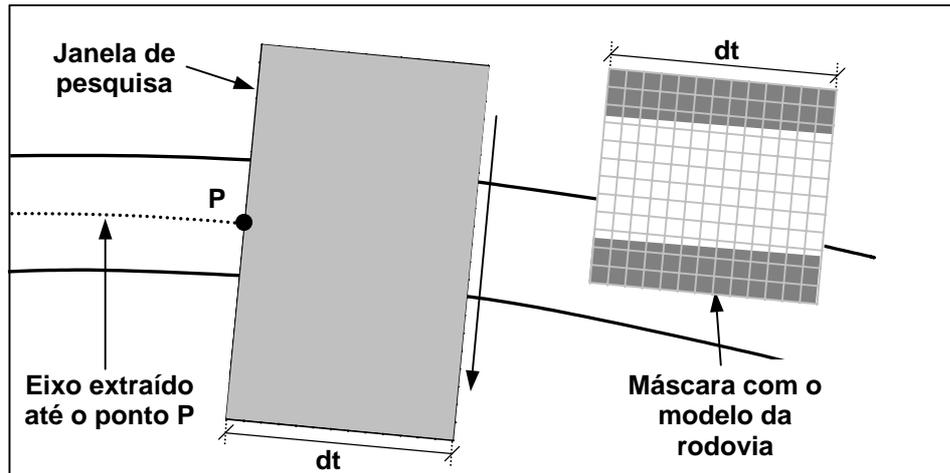


Figura 13 - Correlação entre a máscara e a janela de pesquisa.

3.2.2.1.4 Extrapolação de um Ponto do Segmento da Rodovia

O passo de extrapolação fornecido na inicialização pelo operador é combinado com a melhor direção local determinada pelo teste ativo para extrapolar linearmente um ponto do eixo da rodovia. O processo de extração da rodovia é realizado nesse ponto. Esse processo consiste na extração de um perfil de tons de cinza (perfil medido), correlação entre o perfil medido e o perfil modelo, atualização do perfil modelo e validação do ponto extraído (MENDES, 2002).

3.3.2.2 Extração de um Perfil Medido

Procedimento análogo ao da subseção 3.3.1.2, com uma diferença em relação à largura da janela de busca (n_{med}), que nesse caso, é adotada como sendo igual à largura da rodovia (w) com uma tolerância de 20%, ou seja, $n_{med} = \text{int}(0,6 * w/r) + 1$. A tolerância é maior, para que o perfil medido seja maior que perfil modelo, possibilitando assim realizar a correlação, tendo como resultado a posição relativa de maior similaridade entre os perfis modelo e medido. O perfil medido é estabelecido no ponto previamente extrapolado pelo modelo de trajetória.

3.3.2.3 Correlação entre o Perfil Modelo e o Perfil Medido

Trata-se de um procedimento de correlação unidimensional usando uma função de correlação. Neste trabalho utilizou-se a função erro quadrático, que tem como característica desejável o fornecimento da posição de melhor correlação com maior exatidão, sendo expressa matematicamente por (YANNIRIS, 1974):

$$S(j) = \frac{1}{2 \cdot n_{mod} + 1} \sum_{i=1}^{i=2n_{mod}+1} (A(i) - B(i + j))^2 \quad (56)$$

Onde:

- **A** é um vetor com $2 \cdot n_{\text{mod}} + 1$ elementos representando o perfil modelo;
- **B** é um vetor com $2 \cdot n_{\text{med}} + 1$ elementos representando o perfil medido;
- $0 \leq j \leq 2 \cdot (n_{\text{med}} - n_{\text{mod}})$: é um contador que permite a realização das $2 \cdot (n_{\text{med}} - n_{\text{mod}}) + 1$ possíveis comparações entre ambos os perfis.

A posição de melhor correlação entre ambos os perfis é encontrada quando o coeficiente de correlação **S(j)** for mínimo. O ponto corrigido do eixo da rodovia corresponde à posição do elemento do perfil medido relacionado com o ponto central do perfil modelo (figura 14).

A figura 14 mostra a posição de melhor correlação entre dois perfis ideais de rodovia representando os perfis modelo e extraído. Como uma rodovia em imagens de média e alta resolução (pixel < 2 m) é geralmente uma faixa alongada de alta intensidade de brilho, com grande contraste em relação às adjacências, as formas características de ambos os perfis se aproximam da forma ideal mostrada na figura 14. No caso de imagens de baixa resolução (como por exemplo, imagens SPOT de 10 m de resolução) o perfil teria a forma de um corte de uma cumeira. De um modo geral, a forma do perfil não é um fator crítico, desde que o mesmo se mantenha adequadamente estável por pelo menos um curto segmento de rodovia.

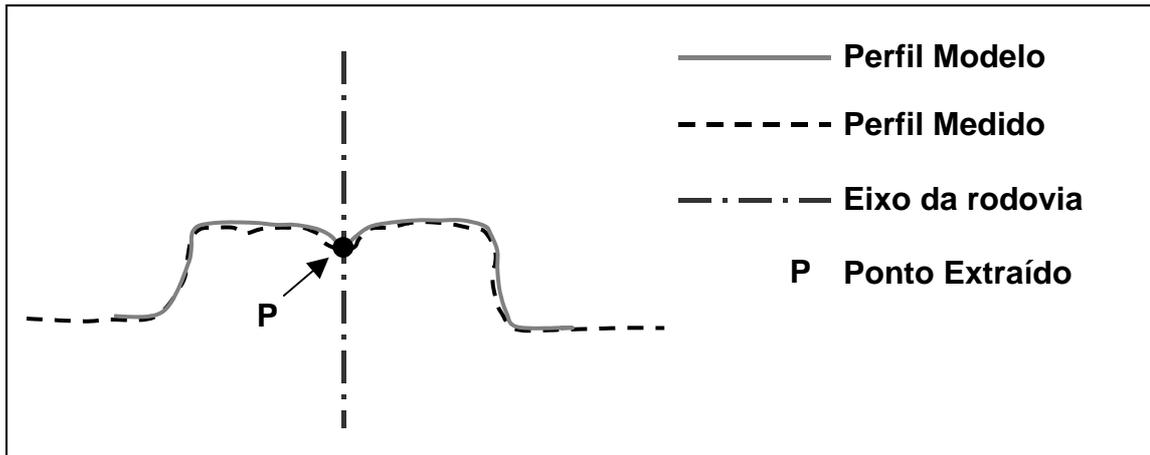


Figura 14 - Melhor correlação entre os perfis modelo e medido.

3.3.2.4 Validação do Ponto Extraído

Se o coeficiente de correlação não for pobre (ou seja, se for menor que um limiar pré-definido), o ponto é aceito se não provocar uma mudança abrupta de direção da rodovia. Caso seja aceito, a lista de coordenadas do eixo da rodovia e a lista dos últimos pontos extraídos são atualizadas, eliminando o ponto mais antigo desta última lista.

3.3.2.5 Refinamento usando o MMQ

A posição do eixo obtida no passo da seção 3.3.2.3 pode ser refinada usando a conhecida estratégia de correlação pelo MMQ (SCHENK, 1999).

A figura 15 mostra como seria o resultado da estratégia de correlação baseada em funções de correlação.

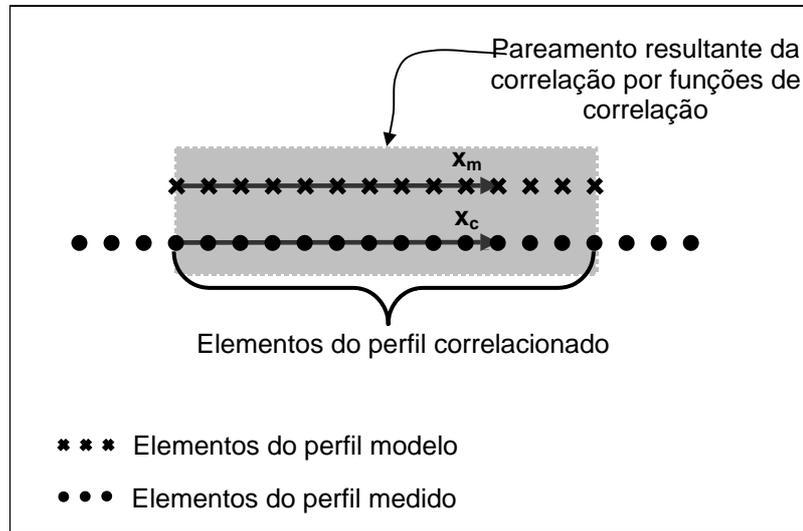


Figura 15 - Resultado da correlação usando funções de correlação.

Como mostra a figura 15, a correlação usando funções de correlação gera um pareamento entre o perfil modelo e um segmento do perfil medido. Para evitar ambigüidades, este último será denominado daqui a diante de perfil correlacionado. Notar que em ambos os perfis são definidos dois referenciais 1D (x_m e x_c), cujas origens são os pontos iniciais à esquerda de ambos.

O seguinte modelo matemático é utilizado para relacionar os tons de cinza de ambos os perfis:

$$\mathbf{g}_m(\mathbf{x}_m) + \mathbf{n}(\mathbf{x}_m) = \mathbf{r} + \mathbf{r}'\mathbf{g}_c(\mathbf{x}_c = \mathbf{a}\mathbf{x}_m + \mathbf{b}) \quad (57)$$

Onde:

- \mathbf{g}_m e \mathbf{g}_c são os tons de cinza dos perfis modelo e correlacionado, respectivamente;
- \mathbf{n} é o ruído da imagem;
- \mathbf{r} e \mathbf{r}' são os parâmetros necessários para modelar linearmente as diferenças radiométricas entre ambos os perfis, os quais são necessários porque estes perfis não correspondem às mesmas regiões da imagem; e
- \mathbf{a} e \mathbf{b} são parâmetros geométricos designados para modelar possíveis diferenças em translação e escala de ambos os perfis, cujas razões são parecidas com as apresentadas no item anterior.

Após linearizar o membro da direita da equação 57 em torno dos parâmetros aproximados (\mathbf{a}_0 \mathbf{b}_0 \mathbf{r}_0 \mathbf{r}'_0), obtém-se por reagrupamento de termos a equação de observação linearizada para um par de pontos correspondentes i :

$$\Delta \mathbf{g}_i + \mathbf{n}_i = \begin{bmatrix} \Delta \mathbf{g}_c^i \mathbf{a}_0 & \Delta \mathbf{g}_c^i & 1 & \mathbf{g}_c(\mathbf{x}_c^i) \end{bmatrix} \cdot \begin{bmatrix} d\mathbf{a} \\ d\mathbf{b} \\ d\mathbf{r} \\ d\mathbf{r}' \end{bmatrix} \quad (58)$$

Onde:

- $\Delta \mathbf{g}_i = \mathbf{g}_m(\mathbf{x}_m^i) - \mathbf{g}_c(\mathbf{x}_c^i)$ é a observação na equação 57;
- $\Delta \mathbf{g}_c^i = \mathbf{g}_c(\mathbf{x}_c^i) - \mathbf{g}_c(\mathbf{x}_c^{i-1})$; e

- $\mathbf{X}^T = [\mathbf{da} \ \mathbf{db} \ \mathbf{dr} \ \mathbf{dr}']$ é o vetor das correções aos parâmetros aproximados $\mathbf{X}_0^T = [\mathbf{a}_0 \ \mathbf{b}_0 \ \mathbf{r}_0 \ \mathbf{r}'_0]$.

Sendo n o número de elementos no perfil modelo $(\mathbf{g}_m(\mathbf{x}_c^0), \Delta, \mathbf{g}_m(\mathbf{x}_c^{n-1}))$ e no perfil correlacionado $(\mathbf{g}_c(\mathbf{x}_c^0), \Delta, \mathbf{g}_c(\mathbf{x}_c^{n-1}))$, pode-se escrever a partir da equação 58 o seguinte sistema de equações de observações:

$$\begin{bmatrix} \Delta \mathbf{g}_1 \\ \vdots \\ \Delta \mathbf{g}_n \end{bmatrix}_{(n-1) \times 1} + \begin{bmatrix} \mathbf{n}_0 \\ \vdots \\ \mathbf{n}_{n-1} \end{bmatrix}_{(n-1) \times 1} = \begin{bmatrix} \Delta \mathbf{g}_c^1 \mathbf{a}_0 & \Delta \mathbf{g}_c^1 & 1 & \mathbf{g}_c(\mathbf{x}_c^1) \\ \vdots & \vdots & \vdots & \vdots \\ \Delta \mathbf{g}_c^{n-1} \mathbf{a}_0 & \Delta \mathbf{g}_c^{n-1} & 1 & \mathbf{g}_c(\mathbf{x}_c^{n-1}) \end{bmatrix}_{(n-1) \times 4} \cdot \begin{bmatrix} \mathbf{da} \\ \mathbf{db} \\ \mathbf{dr} \\ \mathbf{dr}' \end{bmatrix}_{4 \times 1} \quad (59)$$

onde se pode facilmente identificar, conforme terminologia usual de Ajustamento de Observações, o vetor das observações (\mathbf{L}_b) e a matriz “design” \mathbf{A} . Considerando as observações como estatisticamente independentes e de mesma qualidade, e considerando também a variância de unidade peso *a priori* igual a variância das observações, a solução desejada é da forma:

$$\mathbf{X}_a = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{L}_b + \mathbf{X}_0 \quad (60)$$

$$\Sigma \mathbf{X}_a = \hat{\sigma}_0^2 (\mathbf{A}^T \mathbf{A})^{-1} \quad (61)$$

onde \mathbf{X}_a e $\Sigma \mathbf{X}_a$ são respectivamente o vetor dos parâmetros ajustados e a matriz variância-covariância dos parâmetros ajustados, e $\hat{\sigma}_0^2$ é a variância da unidade peso *a posteriori*.

É importante ressaltar que a solução dada pela equação 60 é iterativa. No início, é conveniente adotar $\mathbf{X}_0^T = [1 \ 0 \ 0 \ 1]$, implicando em cálculos apenas com os elementos originais dos perfis modelo e correlacionado. Após a realização do primeiro ciclo de cálculo, os elementos iniciais de \mathbf{X}_0 variarão, sendo assim necessária a reamostragem de todos os elementos (isto é, tons de cinza) do perfil correlacionado. As iterações prosseguem com a necessidade de reamostragem do perfil correlacionado em cada uma delas, parando quando as correções aos parâmetros aproximados forem desprezíveis.

Após a convergência do processo de correlação é necessário ainda calcular a posição corrigida do eixo de rodovia. O primeiro passo consiste em calcular a posição do elemento central do perfil modelo ($\mathbf{x}_m^{\text{central}}$) no perfil correlacionado:

$$\mathbf{x}_c^{\text{central}} = \mathbf{a}^{\text{aj}} \mathbf{x}_m^{\text{central}} + \mathbf{b}^{\text{aj}} \quad (62)$$

onde, $\mathbf{x}_c^{\text{central}}$ é a posição do eixo de rodovia no referencial do perfil correlacionado e \mathbf{a}^{aj} e \mathbf{b}^{aj} são os parâmetros geométricos ajustados, obtidos através da equação 60.

Como mostra a figura 15, a posição do primeiro elemento do perfil correlacionado ($\mathbf{x}_c=0$) é conhecida *a priori* no referencial da imagem. Sendo as coordenadas deste ponto dadas por $(\mathbf{L}_0, \mathbf{C}_0)$, obtém-se:

$$\begin{bmatrix} \mathbf{L}_c \\ \mathbf{C}_c \end{bmatrix} = \mathbf{x}_c^{\text{central}} \begin{bmatrix} -\beta \\ \alpha \end{bmatrix} + \begin{bmatrix} \mathbf{L}_0 \\ \mathbf{C}_0 \end{bmatrix} \quad (63)$$

onde $\mathbf{h}_0 = [-\beta \ \alpha]$ já foi definido anteriormente e (L_c, C_c) são as coordenadas refinadas de um ponto do eixo da rodovia.

3.3.2.6 Atualização do Perfil Modelo

O perfil modelo é atualizado através de uma média ponderada entre o perfil modelo atual e o segmento correspondente do último perfil medido (figura 14), adotando-se um peso maior para o perfil modelo, evitando assim uma mudança abrupta do perfil modelo. No presente trabalho, foi adotado peso 1 para o perfil medido e 4 para o perfil modelo.

3.3.2.7 Generalização do Processo de Extração

O processo descrito anteriormente é executado até encontrar um novo conjunto de pontos sementes que define um novo segmento de rodovia a ser extraído. Nessa etapa, o processo de extração é reinicializado.

O processo de extração continua até encontrar um conjunto de pontos sementes, correspondente ao último segmento a ser extraído. Após o processamento desses pontos sementes, o processo é finalizado.

O ideal é que o processo de extração prossiga até encontrar o último ponto semente, correspondente ao último segmento a ser extraído, finalizando o

processo. Mas obstruções (por exemplo, árvores e sombras) e outras irregularidades podem provocar a parada do processo. Em ambos os casos, o critério de parada é verificar se as falhas sucessivas excedem uma tolerância pré-definida. No caso de ocorrer a parada automática do processo de extração, o operador pode intervir para reiniciar o processo ou, até mesmo, finalizá-lo.

4. EXPERIMENTOS E ANÁLISE

4.1 Considerações Iniciais

O Capítulo 4 mostra os resultados obtidos e as respectivas análises dos experimentos realizados, incluindo os detalhes e recursos computacionais envolvidos. A seção 4.2 apresenta a metodologia para a execução da pesquisa em si, apresentando os aspectos computacionais mais importantes, os dados utilizados nos experimentos e a forma de análise dos resultados. Na seção 4.3, têm-se os recursos utilizados. Finalmente, a seção 4.4 apresenta os experimentos e análises dos resultados.

4.2 Metodologia

4.2.1 Aspectos Computacionais

O algoritmo descrito no capítulo 3 foi implementado em linguagem C padrão ANSI para o ambiente Windows PC. O programa de computador desenvolvido baseia-se na metodologia descrita em detalhes no capítulo 3. O aplicativo executa um processamento completo, incluindo leitura de arquivos

contendo parâmetros necessários, como a largura média da rodovia, coordenadas dos pontos sementes, bem como da imagem a ser processada no formato RAW. Os resultados gerados são um arquivo contendo os pontos extraídos do eixo da rodovia e a imagem de saída no formato RAW contendo a projeção dos vetores de rodovia extraídos.

O programa computacional está estruturado de forma que as tarefas mais simples foram identificadas e transformadas em rotinas primárias e, a partir destas, construiu-se as rotinas mais complexas. A seguir encontra-se um esquema ilustrando o programa principal, as três rotinas principais com suas rotinas primárias.

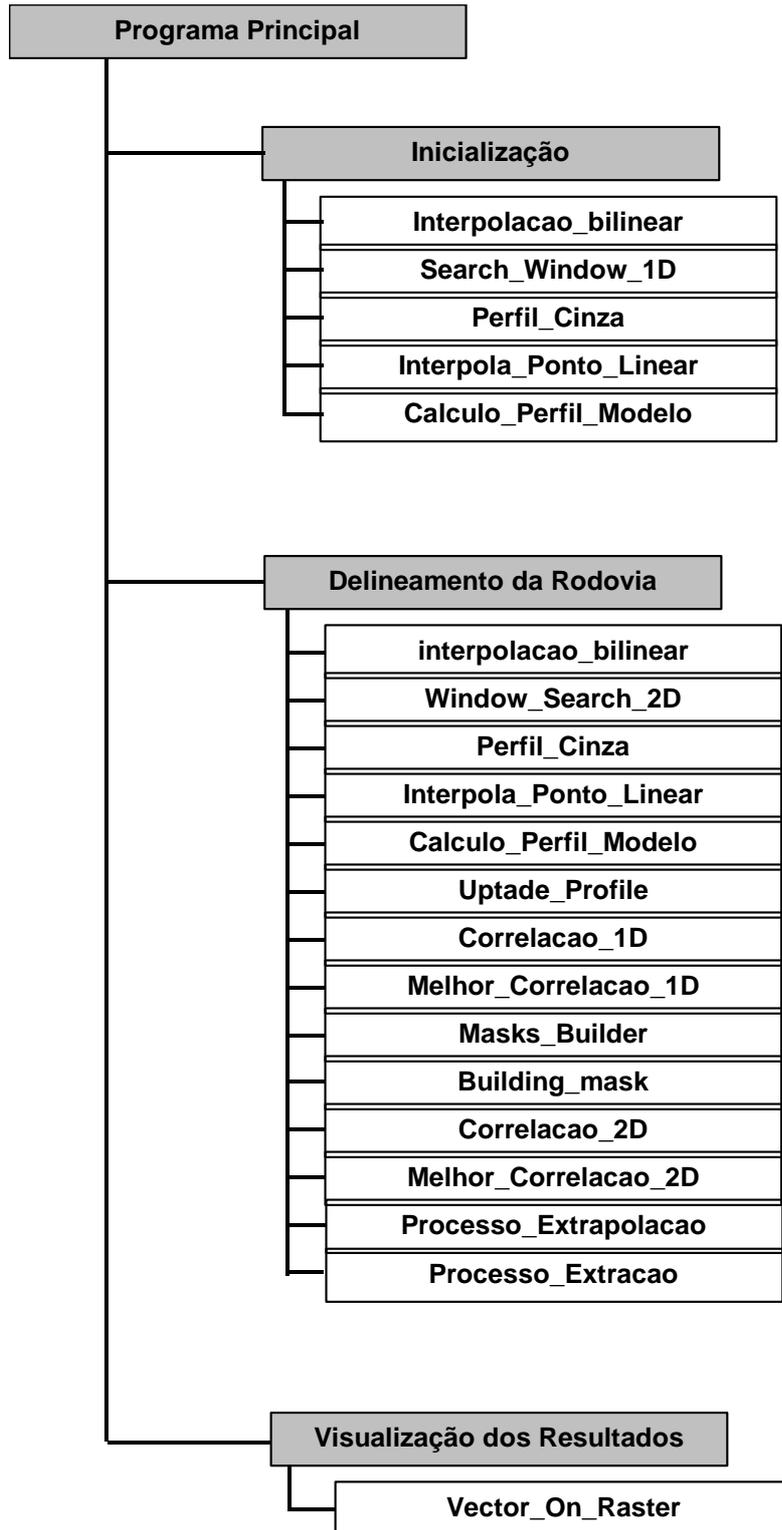


Figura 16 – Esquema mostrando as rotinas principais e secundárias.

Dentro de cada uma das rotinas principais, têm-se as rotinas secundárias, cada qual com os seus objetivos, que são brevemente descritos a seguir:

- **Rotina: interpolacao_bilinear**
Esta rotina tem a função de interpolar os tons de cinza através de interpolação bilinear.
- **Rotina: Search_Window_1D**
Esta rotina amostra uma janela de busca unidimensional (1D), perpendicular ao eixo da rodovia em um ponto dado.
- **Rotina: Window_Search_2D**
Esta rotina cria uma janela de busca bidimensional numa região da imagem compreendendo a rodovia numa direção dada.
- **Rotina: Perfil_Cinza**
Esta rotina extrai o perfil de cinza usando as posições calculadas pela rotina Search_Window_1D.
- **Rotina: Interpola_Ponto_Linear**
Esta rotina realiza a interpolação linear de um ponto.
- **Rotina: Calculo_Perfil_Modelo**
Esta rotina calcula o perfil modelo que será usado para realizar a extração da rodovia.
- **Rotina: Update Profile**
Esta rotina atualiza o perfil modelo através de uma média ponderada entre o perfil modelo atual e o segmento correspondente do último perfil extraído.

- **Rotina: Correlacao_1D**
Esta rotina calcula o coeficiente de correlação utilizando a função erro quadrático.
- **Rotina: Melhor_Correlacao_1D**
Esta rotina encontra a melhor correlação entre o perfil modelo e perfil medido usando o MMQ.
- **Rotina: Masks_Builder**
Esta rotina constrói máscaras contendo diferentes modelos de rodovia, utilizando a máscara gerada pela rotina Building_mask.
- **Rotina: Building_mask**
Esta rotina constrói a máscara para ser utilizada na rotina Masks_Builder.
- **Rotina: Correlacao_2D**
Esta rotina calcula o coeficiente de correlação, utilizando a função erro quadrático, entre a janela de pesquisa e as máscaras contendo diferentes modelos de rodovia.
- **Rotina: Melhor_Correlacao_2D**
Esta rotina encontra a máscara que melhor se correlaciona com a janela de pesquisa, ou seja, encontra a máscara correspondente à melhor variação local de direção da rodovia.
- **Rotina: extrapolation**
Esta rotina realiza a extrapolação de um ponto, num intervalo pré-definido, em pixels, um passo adiante.

- **Rotina: Processo_Extrapolacao**
Esta rotina extrapola os pontos da rodovia em um passo adiante, analisando a melhor direção local da rodovia determinada pela estratégia do teste ativo.
- **Rotina: Processo_Extracao**
Esta rotina realiza o processo de extração da rodovia num determinado ponto.
- **Rotina: Vector_On_Raster**
Esta rotina sobrepõe as rodovias extraídas sobre a imagem de entrada.

4.2.2 Dados

Os experimentos realizados para avaliação da metodologia desenvolvida utilizaram imagens reais de baixa e média resolução. As duas primeiras imagens reais (fig. 17 e 18) foram obtidas através da *home page* do Sistema BADGER (<http://badger.parl.com/>) que, via internet, distribui mapas e imagens da Baía de São Francisco, Califórnia, EUA. As imagens seguintes apresentadas nas figuras 19 e 20 foram obtidas através da digitalização de fotos aéreas da região de Botucatu – SP, disponíveis no Laboratório de Fotogrametria da FCT – Unesp de Presidente Prudente. E as duas últimas imagens, apresentadas nas figuras 21 e 22, da cidade de Curitiba, foram adquiridas junto à empresa ESTEIO – Engenharia e Aerolevantamentos S.A., de Curitiba – PR.

A seguir é feita uma descrição das principais características de cada uma das imagens utilizadas. Para facilitar esta descrição, em imagens que

apresentam mais de uma rodovia, é necessário separar as rodovias principais e as rodovias secundárias, numerando cada uma delas. As rodovias principais são aquelas que se destacam melhor na imagem, enquanto que as rodovias secundárias são aquelas que aparecem com larguras mais estreitas e com uma maior dificuldade de definição.

As larguras das rodovias são dadas em pixels, sendo que cada pixel representa aproximadamente 2 m no terreno.

A imagem real 1 (figura 17) de dimensão de 500x500 pixels possui um alto contraste e apresenta uma rodovia aproximadamente reta, mas com uma largura, de aproximadamente 7 pixels, mal definida devido à areia da praia que obstrui as bordas da rodovia.



Figura 17 – Imagem real 1.

A imagem real 2 (figura 18) de dimensão 764x808 pixels, como a imagem anterior, também apresenta alto contraste e contém uma rodovia principal com curvas suaves, cruzando a imagem na diagonal. Esta rodovia sofre variações

na largura, que é em média de 7 pixels e também, em alguns trechos, há presença de obstruções nas bordas provocadas por árvores.

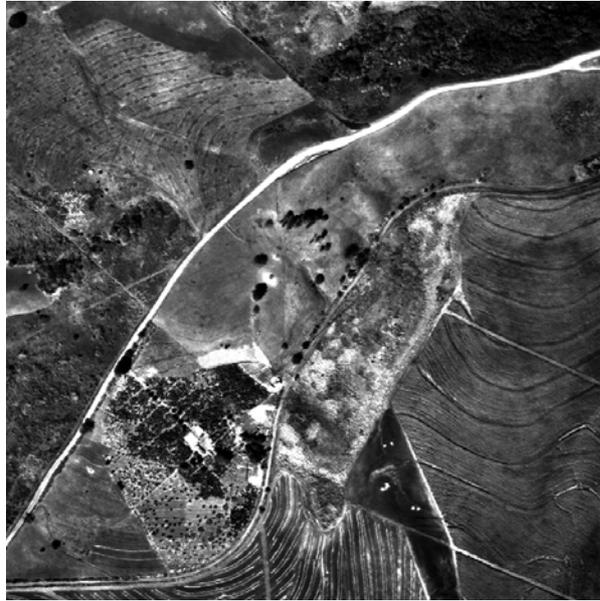


Figura 18 – Imagem real 2.

A imagem real 3 (figura 19) de dimensão 553x585 pixels possui baixo contraste e baixa resolução, apresentando uma rodovia principal 1 de características lineares, com curvas suaves e aproximadamente 4 pixels de largura. Além disso, observa-se padrão diferenciado ao longo da mesma. Na parte inferior da imagem observa-se uma rodovia secundária 2 com características idênticas e aproximadamente 2 pixels de largura.



Figura 19 – Imagem real 3.

A imagem real 4 (figura 20) de dimensão 567x567 pixels possui um contraste mediano, apresentando uma rodovia principal 1 com aproximadamente 5 pixels de largura relativamente bem destacada em relação às suas adjacências. Esta rodovia se apresenta de forma aproximadamente reta, mas com uma mudança de direção brusca. De um modo geral, as bordas apresentam-se bem definidas, apesar de obstruções provocadas por algumas árvores. Outras rodovias (2, 3, 4, 5, 6, 7, 8 e 9), chamadas de secundárias, podem ser observadas na imagem, sendo que todas se apresentam de forma reta, com largura de 3 pixels e sem obstruções em suas bordas. Na verdade, estas rodovias correm entre talhões de agricultura, por onde transitam as máquinas e caminhões. Além das rodovias, pode-se observar na imagem uma ferrovia quase que paralela à rodovia 1, mas esta ferrovia é difícil de ser visualizada devido ao baixo contraste da imagem.

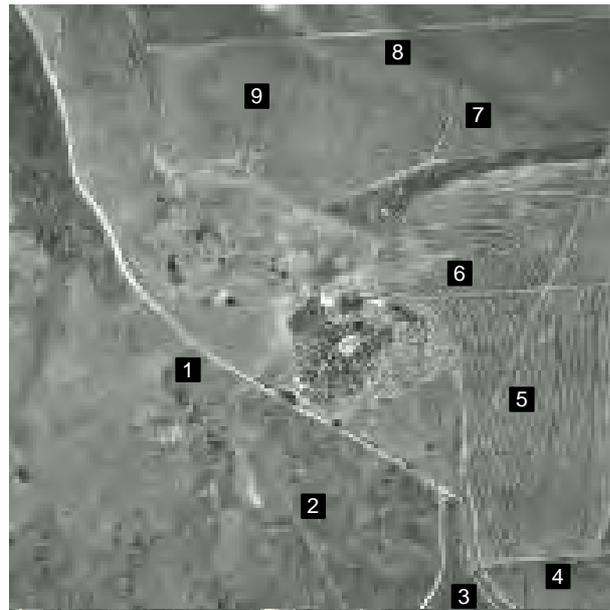


Figura 20 – Imagem real 4.

A imagem real 5 (figura 21) de dimensão 718x836 pixels apresenta alto contraste, verificando três rodovias principais bem definidas. A rodovia principal 1 apresenta uma largura de 4 pixels, curvas suaves e bordas bem destacadas, mas com obstruções, o que ocasiona uma largura um pouco irregular. Observa-se também uma variação de padrão ao longo da mesma. Já a rodovia principal 2, com largura de 7 pixels, é uma rodovia dupla, com um canteiro central, que se apresenta aproximadamente reta e com bordas bem definidas, sem obstruções, exceto quando esta cruza com a rodovia principal 3 formando um entroncamento entre elas. A rodovia principal 3, com largura de aproximadamente 5 pixels, também se apresenta reta e sem obstruções. Em relação às rodovias secundárias (4, 5, 6, 7, 8 e 9), estas se apresentam bem destacadas devido ao alto contraste da imagem e com uma largura média de aproximadamente 3 pixels. De uma forma geral estas rodovias apresentam pequenas obstruções nas bordas e grande variação ao longo da mesma.

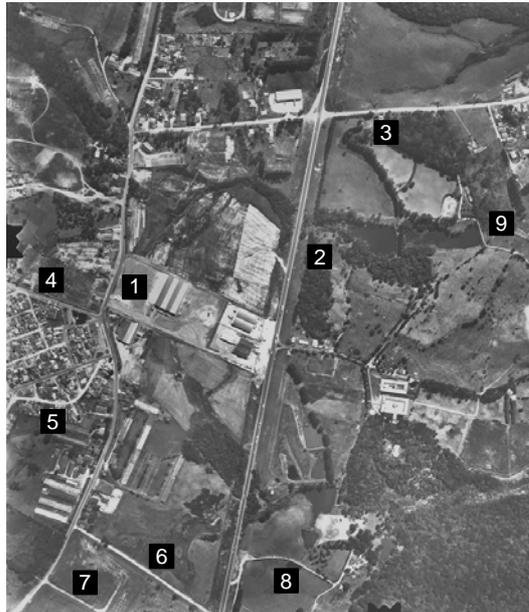


Figura 21 – Imagem real 5.

A imagem real 6 (figura 22) de dimensão 668x697 pixels apresenta rodovias bem destacadas devido ao seu alto contraste. A rodovia principal 1 corta a imagem na diagonal e apresenta uma largura de aproximadamente 6 pixels, mas muito irregular devido às grandes obstruções nas bordas e entroncamentos causados pelo cruzamento com as outras rodovias. Já as rodovias 2, 3, 4, e 5 são secundárias. A rodovia 2, com aproximadamente 4 pixels de largura, apresenta-se com curvas suaves e algumas obstruções nas bordas. A rodovia 3, com largura de 3 pixels, apresenta-se reta e sem obstruções nas bordas. A rodovia 4, com largura de aproximadamente 3 pixels, possui curvatura suave e também não apresenta obstruções nas bordas. Finalmente, a rodovia 5 é um pequeno segmento de rodovia com largura de 8 pixels. Observando a imagem (figura 22), de uma forma geral, tem-se uma alta variação de padrão ao longo das mesmas.



Figura 22 – Imagem real 6.

4.2.3 Formas de Análise dos Resultados

Por ser bastante eficiente, a análise visual dos resultados obtidos por métodos de extração de rodovia é muito comum na literatura especializada, sendo a forma comumente usada. A partir dos vetores superpostos sobre a imagem de entrada, pode-se verificar o desempenho do método e a acurácia da extração realizada. Além dessa forma de análise, existe a análise numérica, como encontrado em DAL POZ (2000), que possibilita obter maior confiabilidade e melhorar a avaliação do método de extração, podendo aplicar alguns critérios como, completeza, correção, qualidade, desvio médio e erro médio quadrático (DAL POZ, 2000).

Para a análise numérica dos resultados encontrados neste trabalho, é utilizado o critério do erro médio quadrático, que dá a media global do afastamento (distância **d**) do eixo extraído em relação ao eixo central da rodovia extraído visualmente.

$$e^2 = \frac{1}{n} \sum_{i=1}^n d_i^2 \quad (63)$$

4.3 Recursos Utilizados

Todos os recursos citados a seguir estão disponíveis no Laboratório de Fotogrametria da FCT/UNESP, os quais foram adquiridos com o apoio da Fundação de Amparo à Pesquisa do Estado de São Paulo – FAPESP. Os principais recursos são:

- Microcomputador;
- Sistema operacional Windows NT Workstation 2000;
- Aplicativos do Microsoft Office 2000;
- Programa Adobe Photoshop 6.0: Aplicativo de processamento digital de imagens, utilizado para visualização das imagens de entrada e de saída no formato RAW, bem como para coleta de pontos sementes e outros parâmetros necessários ao método;
- Programa Borland C++ Builder 4.0 Standard;

- Código fonte do programa computacional de extração de rodovias desenvolvido; e
- Imagens reais.

4.4 Experimentos e Análise dos Resultados

Nesta seção são apresentados os experimentos realizados e a análise dos resultados obtidos pelo método de extração de rodovias implementado, com as imagens reais mostradas na seção 4.2.2.

Sobre cada imagem de entrada pode-se visualizar os eixos extraídos de rodovia superpostos. Além disso, são ainda superpostos os pontos sementes de cada rodovia extraída. Os dois pontos sementes próximos usados no processo de inicialização são representados por círculos vazios na imagem e o último ponto semente, ou seja, o último ponto a ser extraído do segmento de rodovia, é representado por um círculo preenchido.

Essa flexibilidade de posicionar os pontos sementes permite que o operador humano delimite o segmento a ser extraído, fragmentando propositalmente a rodovia em segmentos, evitando assim, que o processo seja interrompido por problemas ocasionados por anomalias, como sombras e obstruções na rodovia. Estes segmentos, como citado na seção 3.2 podem posteriormente, através de algum algoritmo, serem conectados.

4.4.1 Experimentos com a Imagem Real 1

Na figura 23 são apresentados os resultados obtidos com a imagem real 1. Os dois pontos sementes usados no processo de inicialização são colocados no início da rodovia na parte superior da imagem, pois nessa região pode-se observar que a rodovia apresenta-se sem obstruções e bem nítida, formando assim um perfil modelo inicial de boa qualidade. O último ponto semente é colocado logo ao fim dessa rodovia na imagem, de forma a controlar que a extração chegue e pare neste ponto.

Esta imagem apresenta uma rodovia aproximadamente reta, mas com uma largura mal definida devido à areia da praia que obstrui suas bordas.



Figura 23 - Resultados obtidos com a imagem real 1.

A análise visual dos resultados revela que o método funciona satisfatoriamente, verificando que as regiões bastante problemáticas são onde as bordas são obstruídas pela areia, mudando o padrão ao longo da mesma. Mesmo com esta variação de padrão, pode-se observar que o método tem a capacidade de se adaptar a essa mudança, continuando a extração até o último ponto semente. Nessa região da rodovia verifica-se que o eixo extraído pelo método se desloca em relação ao correto, mas sem chegar a sair fora da mesma. Isso pode ser confirmado

através da análise numérica que apresenta um deslocamento médio de 1,9 pixels. Este deslocamento médio de quase 2 pixels é considerado pequeno quando comparado com a largura da rodovia que é de 7 pixels, comprovando que o método apresenta um eficiente desempenho.

4.4.2 Experimentos com a Imagem Real 2

A figura 24 ilustra os resultados obtidos pelo método com a imagem real 2. Neste caso, os pontos sementes usados no processo de inicialização já não são colocados em uma área sem anomalias, pois no segmento formado entre eles, observa-se que há um entroncamento com uma outra rodovia, eliminando parte da borda. Mesmo assim, através da análise visual pode-se concluir que o método apresenta um ótimo desempenho extraíndo o eixo da rodovia com acurácia comparável ao que seria obtido usando a visão natural.

Nas regiões onde existem obstruções, como árvores, o eixo extraído apresenta algumas irregularidades, sofrendo um deslocamento em relação ao eixo central. Entretanto, vale observar que, mesmo com obstruções, o método extrai o eixo da rodovia em apenas um segmento, não necessitando interromper o processo e inicializar novamente.

O bom desempenho do método ao passar por esses obstáculos se justifica pela sua tolerância às falhas, percebendo que o perfil extraído na obstrução é muito diferente do perfil modelo.

Assim, em vez de atualizar o perfil modelo, o método dá uma certa quantidade de passos (estabelecida como limiar) sucessivos na mesma direção do último ponto extraído, analisando os perfis até encontrar um perfil extraído compatível com o perfil modelo. Caso seja alcançado esse limiar, o processo de extração do eixo de rodovia é interrompido. Daí, para se extrair o restante da rodovia, é necessário reinicializar o processo.

Uma outra vantagem do método é a capacidade de adaptação às regiões mais curvas e também às regiões com mudança de largura, como pode ser visualizado na parte superior da imagem. Além disso, é possível observar na imagem que a variação de padrão ao longo da mesma não desfavorece o método.

Na análise numérica, o eixo da rodovia extraído pelo método apresenta um deslocamento médio de 0,5 pixel quando comparado ao eixo extraído visualmente. Esse pequeno deslocamento, quando comparado com a largura de 7 pixels da rodovia, torna-se quase irrisório, o que confirma o bom desempenho do método e a qualidade da extração.



Figura 24 - Resultados obtidos com a imagem real 2.

4.4.3 Experimentos com a Imagem Real 3

Na figura 25 têm-se os resultados obtidos com a imagem real 3. Esta imagem não apresenta um conteúdo muito favorável, pois apesar da rodovia 1

apresentar curvatura relativamente suave e largura uniforme, observam-se obstruções que recobrem parcialmente as bordas da rodovia, baixo contraste e também uma variação de padrão ao longo da mesma, desfavorecendo o desempenho do método. Mais uma vez o método prova que possui capacidade de adaptação do perfil modelo, vencendo todas essas dificuldades. Nesta rodovia os pontos sementes usados no processo de inicialização são distribuídos em uma parte da rodovia onde não há irregularidades. E o último ponto semente a ser extraído é colocado no fim da rodovia na imagem. Este procedimento visa permitir ao método extrair o eixo da rodovia em apenas um segmento.

Já na rodovia 2, que apresenta uma curvatura mais brusca, não foi possível extrair o eixo da rodovia em um só segmento. Para tal, os dois pontos sementes da inicialização são colocados no início da rodovia na imagem e o último ponto a ser extraído é colocado bem próximo à curva, extraíndo assim um segmento. O método então é reinicializado com os próximos dois pontos sementes, permitindo a extração do restante do eixo da rodovia até o último ponto semente.

Vale ainda observar a capacidade do método em tratar rodovias com larguras diferentes em um mesmo processamento. Isso, graças à flexibilidade do método em permitir a entrada de parâmetros diferentes para cada rodovia.

Através da análise numérica tem-se que o eixo da rodovia extraído pelo método apresenta, quando comparado com o eixo extraído visualmente, um deslocamento médio de 0,5 pixel para a rodovia 1 e um deslocamento médio de 0,3 pixel para a rodovia 2. Lembrando que a rodovia 1 e 2 apresentam respectivamente largura de 4 e 2 pixels, o deslocamento apresentado por ambas é muito pequeno, comprovando a eficácia do método.



Figura 25 - Resultados obtidos com a imagem real 3.

4.4.4 Experimentos com a Imagem Real 4

A figura 26 apresenta os resultados obtidos com a imagem real 4.

De modo a facilitar o desempenho do método a extração da rodovia principal 1 é dividida em 2 segmentos. O primeiro segmento tem início na parte superior da imagem, onde são colocados dois pontos sementes sobre esta rodovia e

o último ponto a ser extraído é colocado de forma estratégica ao longo da curva mais acentuada. Em seguida inicia-se novamente o processo de extração com os dois pontos sementes. Dessa forma, garante-se o sucesso da aplicação do método.

As rodovias secundárias (2, 3, 4, 5, 6, 7, 8 e 9), que se apresentam retas e sem obstruções nas bordas, também têm seus eixos extraídos pelo método. Para cada rodovia, é necessário colocar os pontos sementes indicando para o método o início e o fim da extração.

De uma forma geral, através da análise visual dos resultados, pode-se concluir que o método geralmente apresenta um bom desempenho, extraíndo a rodovia principal e todas as rodovias secundárias. Esta extração só é possível devido à flexibilidade do método que permite extrair segmentos de rodovias, inicializando o método a cada segmento previamente selecionado.

Além disso, pode-se verificar que o método tem capacidade para extrair rodovias com larguras variadas (5 pixels para a rodovia principal e 3 pixels para as rodovias secundárias) e se adaptar a padrões diferenciados nas adjacências das rodovias.

Cabe ressaltar que, ao analisar visualmente o eixo da rodovia principal 1 extraído, verifica-se que o método consegue extrair o eixo central da rodovia, mas de forma deslocada. Entretanto, o eixo extraído não é muito diferente em relação ao que seria obtido usando a visão natural.

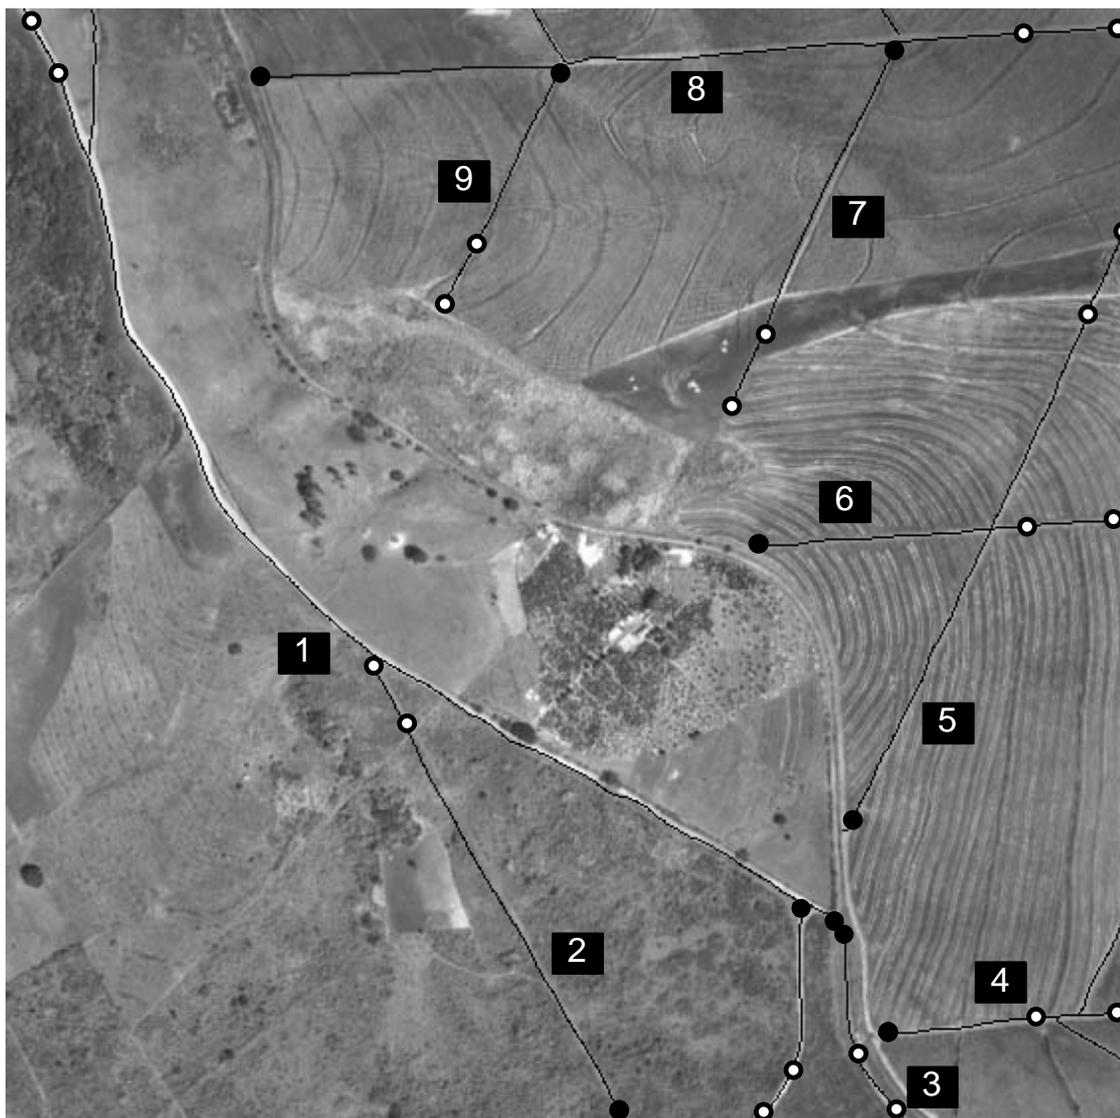


Figura 26 - Resultados obtidos com a imagem real 4.

Analisando numericamente os resultados obtidos, verifica-se que o eixo da rodovia principal extraído pelo método apresenta um deslocamento médio de 1,3 pixels quando comparado ao eixo real extraído visualmente. Levando em consideração que esta rodovia apresenta uma largura de 5 pixels, pode-se concluir que neste caso o método não tem um desempenho totalmente favorável, extraíndo o eixo central da rodovia com deslocamento para uma das bordas.

Já em relação às rodovias secundárias, o eixo das rodovias apresenta um deslocamento médio de 0,6 pixel, considerado pequeno quando comparado com a largura média das rodovias que é de 3 pixels.

4.4.5 Experimentos com a Imagem Real 5

Na figura 27 têm-se os resultados obtidos com a imagem real 5. Ao observar a rodovia principal 1, verifica-se que esta se apresenta com bastante obstruções e padrões muito variados. Todas essas características dificultam o desempenho do método. Mesmo com esses obstáculos, o método consegue extrair o eixo da rodovia. Para tal, é necessário realizar a extração da rodovia em dois segmentos, parando e reiniciando o processo no ponto mais crítico, a curva mais acentuada. Embora a extração desta rodovia tenha sido possível, nota-se que o eixo extraído geralmente não coincide com o eixo que seria extraído manualmente.

Já as rodovias principais 2 e 3, apesar de apresentarem padrões variados ao longo das mesmas, são rodovias retas e quase sem obstruções, o que facilita o desempenho do método. Mesmo no entroncamento, onde sempre há ausência de bordas, o método mostra ser eficiente, não precisando interromper o processo de extração. Isso só é possível devido à capacidade de tolerância às falhas, que como já foi explicado na seção 4.4.2, o método segue em passos sucessivos até encontrar novamente um perfil extraído compatível com o perfil modelo. De uma forma geral, nota-se um desempenho satisfatório do método para as rodovias principais 2 e 3, verificando-se apenas pequenos desvios em áreas mais críticas, como o entroncamento entre ambas as rodovias.

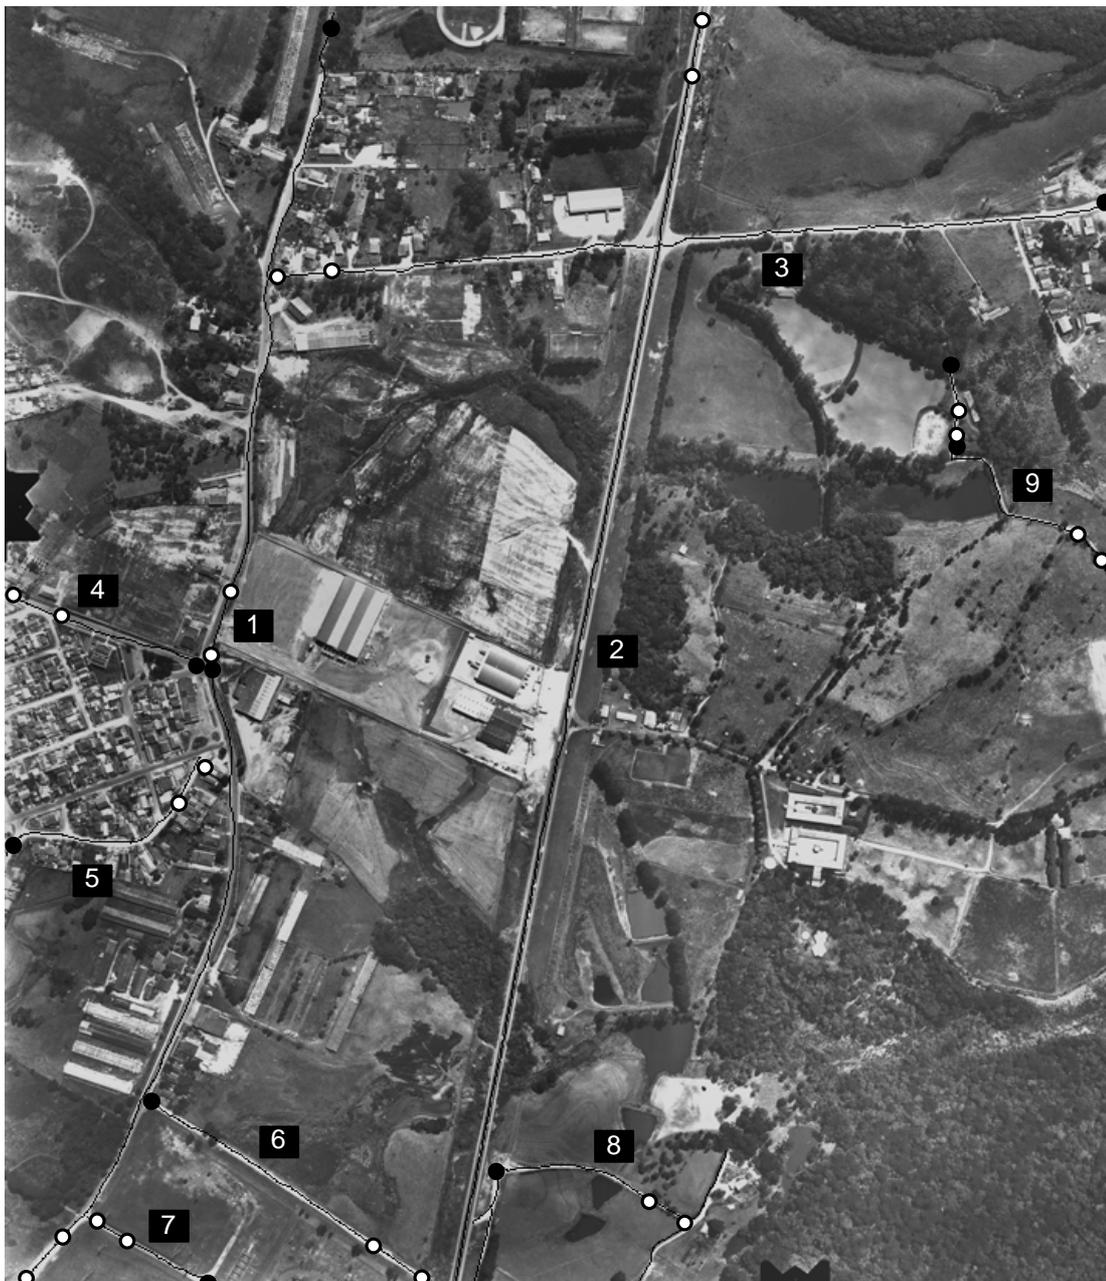


Figura 27 - Resultados obtidos com a imagem real 5.

As rodovias secundárias (4, 5, 6, 7, 8 e 9) também são extraídas pelo método. Estas apresentam muitas obstruções nas bordas e padrões variados ao longo das mesmas. Mesmo assim, o método mostra ser eficiente, extraíndo todas as rodovias, sendo que somente a rodovia 9, que por apresentar curvas bruscas, foi

extraída em dois pequenos segmentos. Portanto, a maioria das rodovias é extraída num único processamento, o que é possível porque o método permite adotar parâmetros diferenciados, como por exemplo, a largura, para cada rodovia. Entretanto, o fator mais importante é a adaptação dinâmica do modelo de rodovia aos diferentes padrões encontrados ao longo da rodovia selecionada para extração.

A análise numérica mostra que o eixo extraído da rodovia principal 1 apresenta um deslocamento médio de 1,6 pixels quando comparado ao eixo extraído visualmente. Esse deslocamento é considerado grande quando comparado com a largura da rodovia que é 4 pixels, confirmando um resultado não muito satisfatório. Entretanto, o eixo extraído da rodovia principal 2 apresenta deslocamento desprezível quando comparado com o eixo extraído manualmente. O padrão bastante regular beneficia o excelente desempenho do método. Já o eixo extraído da rodovia principal 3 que cruza a rodovia citada anteriormente, apresenta um deslocamento médio de 0,5 pixel, quando comparado com o eixo extraído manualmente. Como essa rodovia apresenta uma largura de 5 pixels, esse deslocamento pode ser considerado muito pequeno. Nota-se, entretanto, certa irregularidade do eixo extraído em razão das obstruções parciais encontradas ao longo da rodovia principal 3.

As rodovias secundárias, de uma forma geral, apresentam um deslocamento médio de 0,9 pixel quando comparado com o eixo extraído manualmente. Este deslocamento pode ser considerado relativamente grande quando comparado com a média da largura de 3 pixels, mas deve-se levar em consideração a complexidade das características dessas rodovias.

4.4.6 Experimentos com a Imagem Real 6

Na figura 28 têm-se os resultados obtidos com a imagem real 6. Cada segmento extraído pode ser identificado através dos pontos sementes que são colocados de forma estratégica para se obter um bom desempenho do método.

As rodovias 1 e 2, por se apresentarem com obstruções e curvas bruscas, são extraídas em dois segmentos. Assim, o método precisa ser interrompido pelo último ponto semente e reinicializado novamente. Na rodovia 1, a extração precisa ser interrompida com o último ponto semente em um trecho complicado, onde árvores obstruem as bordas das rodovias. Mas a reinicialização logo após o último ponto semente da extração não pode ser feita, isto porque o trecho local de rodovia não é apropriado para coleta de perfil modelo. Assim, os pontos sementes de inicialização são coletados no outro extremo da rodovia e o ponto semente de parada é posicionado na mesma região onde o primeiro segmento é interrompido. Procedimento semelhante é necessário em relação à rodovia 2. Nesse caso, o método é interrompido em um trecho com uma curva bastante acentuada.

Já as rodovias 3, 4 e 5 são extraídas em apenas um segmento, como pode ser observado na figura 28.

Logo, o algoritmo apresenta a vantagem do operador humano poder decidir onde quer colocar os pontos sementes iniciais, escolhendo o segmento utilizado na inicialização para formar um perfil modelo de boa qualidade e também, controlar até onde a extração deve seguir, posicionado o último ponto semente.

Uma outra grande vantagem do método é a capacidade de extrair rodovias com variação de padrões ao longo da mesma. Isso só é possível devido ao

método ir atualizando o seu perfil modelo à medida que realiza a extração. Além disso, graças à flexibilidade em adotar parâmetros diferentes para cada rodovia, em um único processamento, o método é capaz de extrair 5 rodovias com larguras distintas.



Figura 28 – Resultados obtidos com a imagem real 6.

A análise visual dos resultados obtidos mostra que o método extrai com sucesso o eixo da rodovia 1, mesmo com a presença de obstruções provocadas por árvores e também com a presença de entroncamentos entre as rodovias 2, 3, 4 e 5, os quais provocam localmente a ausência de uma ou ambas bordas da rodovia 1. Conseqüentemente, pequenos deslocamentos podem ser visualizados nestes trechos de entroncamento.

A rodovia 2, também apresenta obstruções, mesmo assim, o método também extrai com sucesso, observando alguns pequenos deslocamentos do eixo ao longo da rodovia.

Já as rodovias 3, 4 e 5 são extraídas pelo método de forma bastante satisfatória, confirmando o bom desempenho do método.

Pela análise visual dos resultados apresentada acima, pode-se concluir que o método geralmente apresenta um resultado satisfatório, extraindo todas as rodovias selecionadas, mas observa-se que em vários locais críticos, devido às anomalias na rodovia já descritas, o eixo extraído apresenta pequenos deslocamentos em relação ao eixo central que seria obtido manualmente.

Da análise numérica, tem-se que o eixo extraído da rodovia 1 apresenta um deslocamento médio de 1,8 pixels quando comparado com o eixo extraído visualmente. Esse deslocamento pode ser considerado satisfatório levando em consideração que esta rodovia apresenta uma largura de 6 pixels.

Já a rodovia 2 apresenta um resultado não muito satisfatório, já que o eixo extraído apresenta um deslocamento médio de 1,5 pixels e a sua largura é de 4 pixels.

Entretanto, as rodovias 3 e 4, com larguras de 3 pixels, apresentam resultados melhores, com um deslocamento médio de 0,5 pixel. E finalmente a

rodovia 5, foi a que apresentou um maior deslocamento relativo, sendo este de 4 pixels para uma largura média de 8 pixels.

5. CONCLUSÕES E RECOMENDAÇÕES

5.1 Conclusões

Para a presente pesquisa foram propostos dois objetivos principais. O primeiro objetivo tratou do desenvolvimento e da implementação computacional do traçador semi-automático de rodovias. O segundo objetivo foi a avaliação experimental do método usando imagens reais com diferentes graus de dificuldades.

Do primeiro objetivo, dada à forma que o método foi concebido, pode-se concluir que tem capacidade de extrair rodovias, com robustez e eficácia. A combinação das técnicas de correlação e o princípio de teste ativo conferiram flexibilidade ao método, possibilitando a extração de segmentos isolados que posteriormente podem ser conectados por algoritmos específicos, gerando assim a malha viária.

Outro ponto importante é em relação à capacidade que o método possui de extrair regiões com obstruções na rodovia. Isso só é possível devido a duas propriedades importantes do método. A primeira é o fato de que o perfil modelo vai sendo atualizado conforme o método extrai a rodovia e a segunda é devido ao método tolerar um limiar de falhas sucessivas quando encontra obstruções, não atualizando o perfil modelo até encontrar um perfil extraído compatível.

Para o segundo objetivo, foram realizadas análises visual e numérica (utilizando a medida do erro médio quadrático) dos resultados obtidos através da aplicação do método em imagens reais.

Com base nas análises realizadas no capítulo 4, pode-se concluir que:

- Na imagem real 1, o método de extração de segmentos de rodovia funcionou satisfatoriamente, verificando que a região bastante problemática é onde as bordas são obstruídas pela areia da praia. A análise numérica mostrou um pequeno deslocamento do eixo extraído de 1,9 pixels, levando em consideração os 7 pixels de largura da rodovia;
- Na imagem real 2, o método apresentou um ótimo desempenho, extraíndo o eixo da rodovia com acurácia comparável ao uso da visão natural, mesmo em regiões onde existem obstruções. A análise numérica confirmou o bom desempenho, com o eixo extraído apresentando um pequeno deslocamento médio de 0,5 pixel em uma rodovia com 7 pixels de largura;
- Na imagem real 3, a aplicação do método apresentou um ótimo resultado, comprovando a sua capacidade de adaptação do perfil modelo, vencendo todas as obstruções. Através da análise numérica verificou-se a eficácia do método, com pequeno deslocamento do eixo extraído de 0,5 e 0,3 pixel, respectivamente, para as rodovias 1 e 2. A rodovia 1 possui uma largura de 4 pixels e a rodovia 2 de 2 pixels;

- Na imagem real 4, pode-se concluir que o método geralmente apresentou desempenho satisfatório, extraíndo a rodovia principal e todas as secundárias. Isso graças à flexibilidade do método que permite extrair segmentos de rodovia, inicializando o método em cada segmento. Através da análise numérica, o eixo da rodovia principal 1 extraído apresentou um deslocamento relativamente grande de 1,3 pixels, quando comparado com a largura de 5 pixels. Já os eixos das rodovias secundárias apresentaram um pequeno deslocamento médio de 0,6 pixel quando comparado com rodovias com largura média de 3 pixels.
- Na imagem real 5, apesar de apresentar dificuldades como curvas bruscas, obstruções e padrões diferenciados ao longo das rodovias, pode-se concluir, que de uma forma geral, o método apresentou um desempenho satisfatório. A análise numérica da rodovia 1 mostrou um deslocamento grande do eixo extraído de 1,6 pixels em uma rodovia de com 4 pixels de largura. Já a rodovia 2 não apresentou deslocamento significativo. A rodovia 3 apresentou um pequeno deslocamento de eixo extraído de 0,5 pixel numa rodovia com 5 pixels de largura. As rodovias secundárias apresentaram um deslocamento pequeno de 0,9 pixel, quando comparado com a largura média de 3 pixels dessas rodovias.
- Na imagem real 6, o método geralmente apresentou resultado satisfatório, já que todas as rodovias foram extraídas, mesmo

as com obstruções. Mas, devido a essas obstruções e eixo extraído apresentou pequenos deslocamentos em relação ao eixo central extraído manualmente. Embora o método tenha então demonstrado robustez nesse experimento, a acurácia não foi, em geral, muito boa. O eixo extraído da rodovia 1 apresentou um resultado não muito satisfatório, com um deslocamento de 1,8 pixels numa largura de rodovia com 6 pixels. A rodovia 2 também apresentou um resultado não muito satisfatório, já que o eixo extraído apresentou um deslocamento médio de 1,5 pixels e a sua largura é de 4 pixels. As rodovias 3 e 4, com larguras de 3 pixels, apresentaram resultados melhores, com um deslocamento médio de 0,5 pixel. E a rodovia 5, apresentou deslocamento de 4 pixels, deslocamento considerado grande quanto comparado com a sua largura de 8 pixels.

Através dos resultados obtidos pela aplicação do método desenvolvido, pode-se verificar a viabilidade do método para extração de rodovias a partir de imagens digitais.

Todas as imagens usadas nos experimentos apresentaram algum tipo de irregularidade associada às bordas (por exemplo, ausência ou definição ruim), à variação de largura e às obstruções provocadas principalmente por árvores e sombras. Mesmo nestas situações desfavoráveis, a estratégia de extração provou ser geralmente robusta e acurada o suficiente, permitindo concluir que o desempenho é comparável ao obtido através da visão natural.

Logo, pode-se concluir que o método tem potencial para ser usado como um assistente de extração da malha viária. Neste esquema, as decisões de alto nível (por exemplo, a identificação de rodovias) são deixadas a cargo do operador, enquanto que as operações que exigem precisão e são mais cansativas são realizadas por um algoritmo computacional.

5.2 Recomendações

A metodologia apresentada pode ser generalizada para realizar a extração de outras entidades cartográficas, além de rodovia.

Como o método empregado é baseado na análise de consistência de perfis da superfície intensidade, extraídos transversalmente ao eixo da entidade rodovia, em imagens de alta e média resolução, para realizar esse generalização seria necessário adaptar o método para outros tipos de perfis.

São três os tipos possíveis de perfis: 1. Seção transversal de rodovias em imagens de média e alta resolução; 2. Linhas (por exemplo: rodovias em imagens de baixa resolução, como uma imagem HRV-SPOT; curvas de nível de um mapa digitalizado em formato matricial etc.) e 3. Bordas (fronteiras de áreas homogêneas, como culturas, florestas etc.).

Portanto, a aplicação do método não implicaria em mudanças importantes na metodologia descrita.

Uma outra importante recomendação é realizar a interface gráfica do algoritmo, facilitando assim a interação do operador humano e agilizando o processo de extração.

REFERÊNCIAS BIBLIOGRÁFICAS

AGOURIS, P.; GYFTAKIS, S.; STEFANIDIS, A. **Uncertainty in image-based change detection**. In: Accuracy 2000, Proceedings... Amsterdam, 2000, p. 1-8.

BAJCSY, R.; TAVAKOLI, M. **Computer recognition of roads from satellite pictures**. IEEE Transaction on System, Man and Cybernetics, v. 6, n. 9, 1976, p. 623-637.

BARSI, A.; HEIPKE, C.; WILLRICH F. **Junction extraction by artificial neural network system – JEANS**. In: ISPRS – Commission III Symposium on Photogrammetric Computer Vision, Graz, Áustria, Proceedings, 2002.

BAUMGARTNER, A.; HINZ, S.; WIEDEMANN, C. **Efficient methods and interfaces for road tracking**. In: ISPRS – Commission III Symposium on Photogrammetric Computer Vision, Graz, Áustria, Proceedings, 2002, p.1383.

BAUMGARTNER, A.; STEGER, C.; MAYER, H.; ECKSTEIN, W.; EBNER, H. **Automatic road extraction in rural areas**. In: International Archives Photogrammetry and Remote Sensing, v. 32, Part 3-2W5, 1999, p. 107-112.

BAUMGARTNER, A.; HINZ, S.; WIEDEMANN, C. **Efficient methods and interfaces for road tracking**. In: ISPRS – Commission III Symposium on Photogrammetric Computer Vision, Graz, Áustria, Proceedings, 2002, p.1383.

CENTENO, J. A. S.; MACHADO A. M.; PEDRO, P. C. **O efeito da compressão de imagens nos processos automáticos de extração de informações**. In: Anais do III Colóquio Brasileiro de Ciências Geodésicas, 2003.

DAL POZ, A. P. **Processo automático para reconhecer e extrair rodovias georeferenciadas de uma fotografia aérea digitalizada**. Relatório de Pós-Doutorado FAPESP, Universidade de Maine, EUA, 2000, 225 p..

DAL POZ, A. P. **Semi-automatic road extraction based on edge and correlation analyses**. In: ASPRS 2001 Annual Conference, Saint Louis, EUA, 2001.

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

DAL POZ, A. P.; AGOURIS, P. **Georeferenced road extraction and formulation of hypotheses for new road segments.** In: SPIE's 12th Annual International Symposium on Aerospace/Defense Sensing, Simulation, and Control - Conference Automated Geo-Spatial Image and Data Exploitation, Orlando - FL, USA, Proceedings, 2000a, v. 4054, p. 56-65.

DAL POZ, A. P.; GYFTAKIS, S.; AGOURIS, P. **Semi-automatic road extraction: Comparison of methodologies and experiments.** In: DC 2000 ASPRS Annual Conference, Washington, DC, USA, May 2000b, CD-ROM.

DAL POZ, A. P.; GALO, M. **A utilização do conceito de geometria epipolar em correlação de imagens digitais.** Revista Pesquisas, Porto Alegre - RS, v.19, n.2, 1992, p.137-142.

DAL POZ, A. P.; SILVA, M. A. O. **Road testing and edge analysis for road centerline extraction.** In: ISPRS – Commission III Symposium on Photogrammetric Computer Vision, Graz, Áustria, Proceedings, 2002.

DAL POZ, A. P.; SILVA, M. A. O. **Road segment delineation using active testing principle and an edge-based post-processing strategy.** Journal of Geomatica, Canadá, v. 57, n. 4, 2003. p. 399-410.

DOUCETTE, P. ; AGOURIS, P.; STEFANIDIS, A. **Automated road extraction from high resolution multispectral imagery.** Journal of the American Society for Photogrammetry and Remote Sensing, Maryland, v. 70, n. 12, 2004, p.1405-1416.

GALO, M.; TOZZI, C. L. **A Fotogrametria Digital e a Automação dos Processos Fotogramétricos.** In: Seminário: Impacto das novas Tecnologias na Engenharia Cartográfica, Presidente Prudente-SP. 1997. p. 70-75.

GALO, M.; TOZZI, C. L. **Combining Operators to Sub-Pixel Corner Estimation.** Pesquisa em Ciências Geodésicas. Curitiba, 2002.

GEMAEL, C. **Introdução ao Ajustamento de Observações: Aplicações Geodésicas,** Editora UFPR, Curitiba, 1994, p. 319.

GEMAN, D.; JEDYNAK, B. **An active testing model for tracking roads in satellite images.** IEEE Transaction on Pattern Analysis and Machine Intelligence 18(1), 1996, p. 1-14.

GRÜEN, A.; LI, H. **Semi-automatic linear feature extraction by dynamic programming and LSB-snakes.** Photogrammetric Engineering and Remote Sensing, v. 63, n. 8, 1997, p. 985-995.

JAIN, R.; KASTURI, R.; SCHUNCK, B. G. **Machine vision**. MIT press and McGraw-Hill, Inc., New York, 2000. 549 p..

KASS, M.; WITKIN, A.; TERZOPOULOS, D. **Snakes: Active contour models**. International Conference on Computer Vision, 1., London, Proceedings... London, 1987, p. 259-268.

KONECNY, G. **Geometric Evaluation of Spot Imagery**, 1987. In: Seminar on Photogrammetric Mapping from SPOT imagery, Hannover, September 21-23, 1987.

KRAUS, K. **Photogrammetry: Fundamental and Standard Processes**. V.1 Bonn, Dümmler, 1993, 397p..

LEMMENS, M. J. P. M. **A survey on stereo matching techniques**. In.: International Archives for Photogrammetry and Remote Sensing, Kyoto. Japão, Comm. V, p. 11-23, 1988.

LI, H. **Semi-automatic road extraction from satellite and aerial images**. PhD thesis, Report No. 61, Institute of Geodesy and Photogrammetry, ETH-Zurich, Switzerland, 1997,161p..

MACHADO E SILVA, A. J. F. **Modelos de Correção Geométrica para Imagens HRV – SPOT**. Dissertação de Mestrado, Programa de Pós-Graduação em Computação Aplicada, INPE, São José dos Campos, 1988, p. 219.

MARCHAND, E.; CHAUMETTE, F. **An autonomous active vision system for complete and accurate 3D scene reconstruction**. International Journal of Computer Vision, v. 32, n. 3, 1999, p.171-194.

MCKEOWN, D. M.; DENLINGER, J. L. **Cooperative methods for road tracking in aerial imagery**. In: Workshop of Computer Vision and Pattern Recognition, 1988, p. 662-672.

MENDES, T. S. G. **Extração semi-automática de rodovias através da análise de consistência da superfície intensidade**. Relatório Final de Iniciação Científica – PIBIC/CNPq. Presidente Prudente, 2002.

MENDES, T. S. G.; DAL POZ, A. P. **Extração semi-automática de rodovias combinando um modelo de trajetória com uma estratégia de correlação**. In: IV Simpósio Brasileiro de Geoinformática - GeoInfo 2002, 2002, p. 83-90.

MENDES, T. S. G.; FAZAN, A. J.; DAL POZ, A. P. **Delineamento de estradas vicinais usando técnicas de correlação de imagens**. Boletim de Ciências Geodésicas, v.10, n.12, 2004, p. 159-176.

MERLET, N.; ZERUBIA, J. **New prospects in line detection by dynamic programming.** IEEE Transaction on Pattern Analysis and Machine Intelligence, v. 18, n. 4, 1996. p. 426-431.

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

PRIESTNALL, G. ; HATCHER, M. J.; MORTON, R. D.; WALLACE, S. J.; LEY, R. G. **A framework for automated extraction and classification of linear networks.** Journal of the American Society for Photogrammetry and Remote Sensing, Maryland, v. 70, n. 12, 2004, p.1373-1382.

QUACKENBUSH, L. J. **A review of techniques for extracting linear features from imagery.** Journal of the American Society for Photogrammetry and Remote Sensing, Maryland, v. 70, n. 12, 2004, p.1383-1392.

QUAM, A. **Road tracking and anomaly detection in aerial imagery.** Proceedings of the DARPA Image Understanding Workshop, 1978, p. 51-55.

RICHARDS, J. A. **Remote Sensing Digital Image Analysis: An Introduction,** Springer -Verlag Berlim Heidelberg, 1986, p.281.

SCHENK, T. **The Role of Feature in Digital Photogrammetry,** s. l, s.d.

SCHENK, T. **Towards automatic aerial triangulation.** 1997. p. 110-121.

SCHENK, T. **Digital Photogrammetry.** TerraScience, 1999.

STRAUCH, J. C. M. **Correlação aplicada à Fotogrametria.** Seminário apresentado ao curso de pós-graduação em Ciências Geodésicas na Universidade Federal do Paraná. Curitiba, 1990.

SILVA, M. A. O. **Extração semi-automática de rodovias combinando o princípio de bordas anti-paralelas com um novo modelo de correlação da superfície identidade.** Relatório de Pesquisa FAPESP, FCT - Unesp, Presidente Prudente, 2001.

TOMMASELLI, A. M. G.; TOZZI, C. L. **Extração de linhas retas em imagens digitais.** In: Anais do XVI Congresso Brasileiro de Cartografia, Rio de Janeiro, 1993.

VALE, G. M. **Extração semi-automática do eixo de rodovias em imagens de média e alta resolução usando programação dinâmica.** Dissertação de Mestrado, Universidade Estadual Paulista (UNESP), 2003, 115p..

WANG, Y. **Principles and applications of structural image matching.** ISPRS Journal of Photogrammetry & Remote Sensing V.53, 1998. p.154-165.

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

YANNIRIS, Y. **Improvements to the off-line epipolar correlation.** Dissertação de mestrado, Universidade de New Brunswick, 104p, 1974.

ZANIN, R. B. **Metodologia automática para extração de cruzamentos de rodovias em imagens digitais de alta resolução.** Dissertação de Mestrado, Universidade Estadual Paulista (UNESP), 2004, 120p..