

CLAUDIONOR RIBEIRO DA SILVA

**EXTRAÇÃO DE ESTRADAS VICINAIS EM IMAGENS DIGITAIS E DADOS LASER  
SCANNER USANDO ABORDAGENS AUTOMÁTICA E SEMI-AUTOMÁTICA**

Tese apresentada ao Curso de Pós-Graduação em Ciências Geodésicas, Setor de Ciências da Terra, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Doutor em Ciências Geodésicas.

Orientador: Prof. Dr. Jorge Antônio Silva Centeno

CURITIBA  
2008

# **Livros Grátis**

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

## TERMO DE APROVAÇÃO

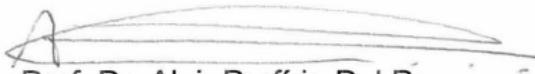
CLAUDIONOR RIBEIRO DA SILVA

“EXTRAÇÃO DE ESTRADAS VICINAIS EM IMAGENS DIGITAIS E DADOS LASER  
SCANNER USANDO ABORDAGENS AUTOMÁTICA E SEMI-AUTOMÁTICA”

Tese nº 63 aprovada como requisito parcial do grau de Doutor no Curso de Pós-Graduação em Ciências Geodésicas, Setor de Ciências da Terra da Universidade Federal do Paraná, pela seguinte banca examinadora:

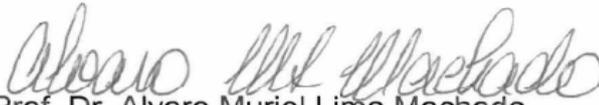
Orientador:

  
Prof. Dr. Jorge Antonio Silva Centeno  
Departamento de Geomática, UFPR

  
Prof. Dr. Aluir Porfírio Dal Poz  
Universidade Estadual Paulista, UNESP

  
Prof. Dr. Jacques Facon  
Pontifícia Universidade Católica do Paraná, PUCPR

  
Prof.ª Dr.ª Selma Regina Aranha Ribeiro  
Universidade Estadual de Ponta Grossa, UEPG

  
Prof. Dr. Alvaro Muriel Lima Machado  
Departamento de Geomática, UFPR

  
Prof. Dr. Daniel Rodrigues dos Santos  
Departamento de Geomática, UFPR

Curitiba, 21 de novembro de 2008.

## DEDICATÓRIA

*Aos meus insubstituíveis e eternos pais:  
Alexandre (in memoriam) e Juraci*

## AGRADECIMENTOS

À Deus, a vida;

À UFPR e CPGCG, a oportunidade;

Ao Professor Dr. Jorge Antônio Silva Centeno, a orientação, a amizade, a disponibilidade, ensinamentos e apoio fundamentais durante todo o processo de criação e elaboração dessa Tese. E, especialmente, ao consentimento e ao crédito apostados nessa proposta desde o início;

Aos órgãos que fomentaram esta pesquisa: CAPES, REUNI (bolsas de estudo), UFPR (estrutura e laboratórios) e UFPI (afastamento remunerado);

À Mônica, a atenção e o carinho especial;

Aos professores, o ensinamento e a amizade;

Aos colegas do CPGCG e de república, a amizade, as discussões e trocas de idéias, especialmente ao grupo de futebol;

Aos funcionários que cuidam da limpeza do Departamento de Geomática;

À Ara, o carinho, consentimento e apoio;

À minha família, irmãos, irmãs, sobrinhos, sobrinhas, cunhados, cunhadas, o carinho e apoio indispensáveis; especialmente à minha MÃE, exemplo de perseverança e vida.

"Mesmo estando na estrada certa, você será atropelado se  
ficar apenas sentado nela."

Will Rogers.

“Com a SABEDORIA se edifica a casa, e com a INTELIGÊNCIA  
ela se firma; e pelo CONHECIMENTO se encherão as câmeras  
de todas as substâncias preciosas e deleitáveis.”

Provérbios 24 : 3 - 4.

## RESUMO

O objetivo principal desse trabalho é extrair estradas vicinais usando imagens digitais de alta resolução espacial e dado LASER (Light Amplification by Stimulated Emission of Radiance) integrado com imagens digitais. A metodologia proposta para atender a esse objetivo é dividida em duas fases. Na primeira fase é proposta uma técnica para determinar as medidas de larguras de estradas vicinais. Um método para detecção de segmentos de retas, ou eixos de estradas, é proposto na segunda fase. Essa segunda fase é subdividida em três etapas, sendo que em cada etapa é analisada uma função objetivo, ou de aptidão, proposta para realizar a tarefa de detecção de eixos. Os métodos desenvolvidos nessas três etapas são avaliados por meio de abordagens automática e semi-automática. Os algoritmos genéticos e algoritmos ótimos são testados na abordagem semi-automática, enquanto, na automática, é avaliada a aplicação da transformada Radon. Adicionalmente às três fases, é proposto um modelo matemático para mensurar a qualidade geométrica dos eixos detectados e é realizada uma etapa em que as pistas de rolamento das estradas vicinais são extraídas para fins de visualização. Os métodos propostos foram avaliados por meio de experimentos. A acurácia dos resultados foi avaliada por meio dos índices: completeza, correção e RMS. Embora tenham ocorrido algumas falhas, em muitos dos casos examinados os resultados são satisfatórios. Esses resultados são apresentados e discutidos em capítulo oportuno.

Palavras-chave: Extração de estradas vicinais. Algoritmos ótimos. Algoritmos Genéticos. Transformada Radon. LASER scanner. Imagens digitais.

## **ABSTRACT**

The main objective of this study is to extract local road using digital images of high resolution and data LASER (Light Amplification by Stimulated Emission of Radiance) integrated with digital images. The methodology proposed to accomplish this objective is divided in two phases. In the first phase a technique is proposed to determine the measures of local road widths. A method for detection of segments of straight line, or axes of road, is proposed in the second phase. This second phase is subdivided in three stages. In each stage an objective (or fitness) function is proposed and tested to accomplish the task of axes detection. The methods developed in those three stages are appraised through automatic and semiautomatic approaches. The genetic algorithms and optimum algorithms are tested in the semiautomatic approach, while in the automatic the application of Radon transform is evaluated. Additionally, a mathematical model is proposed for measuring the geometric quality of the detected axes and a stage is performed in which the tracks of the local road are extracted for visual analysis purposes. Several experiments were accomplished intending to validate the proposed methodology. The accuracy of the results was evaluated through the indexes: completeness, correctness and RMSEixo. Although some flaws have occurred, in many of the examined cases the results are satisfactory. Those results are presented and discussed in opportune chapter.

Key words: Extraction of local road. Optimum algorithms. Genetic algorithms. Radon transform. LASER scanner. Digital images.

## LISTA DE FIGURAS

Figura 1 -	Exemplos de estradas vicinais .....	18
Figura 2 -	Aprimoramento dos sensores ao longo do tempo.....	19
Figura 3 -	Funcionamento da técnica de seleção por roleta.....	25
Figura 4 -	Escopo dos algoritmos genéticos.....	27
Figura 5 -	Transformada Radon .....	28
Figura 6 -	Resultado da transformada Radon (imagem negativa).....	29
Figura 7 -	IMAGEM 1 (a) Eixos de referência (b) Estradas de referência (c) .....	37
Figura 8 -	IMAGEM 2 (a) Estradas de referência (b).....	38
Figura 9 -	IMAGEM 3 (a) Estrada de referência (b).....	39
Figura 10 -	IMAGEM 4 (a) Estradas de referência (b).....	40
Figura 11 -	IMAGEM 5 (a) Estradas de referência (b).....	41
Figura 12 -	IMAGEM 6 (a) Dado LASER - MDT (b).....	42
Figura 13 -	Definição de largura de estradas .....	44
Figura 14 -	Perfil transversal de estrada ( a ) Módulo do Gradiente do perfil ( b )..	45
Figura 15 -	Fluxograma do processo de detecção de eixos de estradas usando algoritmos ótimos .....	47
Figura 16 -	Exemplos de segmentos semente (pixels 1 e 2) (a) espaço de busca (b).....	48
Figura 17 -	Perfis retirados de imagem real (a, b, c) e perfil de referência (d) .....	50
Figura 18 -	Seleção do perfil para fins de comparação .....	51
Figura 19 -	Fluxograma do processo de detecção de eixos de estradas usando algoritmos genéticos .....	57
Figura 20 -	Espaço de busca.....	58
Figura 21 -	Exemplo de indivíduo codificado.....	60
Figura 22 -	Operador de cruzamento (a) e de mutação (b).....	62
Figura 23 -	Exemplos de perfil transversal selecionado .....	63
Figura 24 -	Fluxograma do processo de detecção de eixos de estradas usando abordagem automática.....	67
Figura 25 -	Exemplos de imagem subdividida (a) e possíveis segmentos semente (b).....	68
Figura 26 -	Coordenadas de segmentos semente no espaço imagem .....	69
Figura 27 -	Problemas decorrentes do uso da transformada Radon na detecção de linhas largas .....	71

Figura 28 - Seleção de segmentos candidatos a semente.....	72
Figura 29 - Plano ajustado sobre os pontos altimétricos .....	77
Figura 30 - Eixo (a), Primeiro círculo (b), Segundo círculo (c) e Estrada extraída (d).....	79
Figura 31 - Erro existente entre dois eixos de estrada .....	80
Figura 32 - Exemplo de erros entre os eixos detectados e de referência.....	82
Figura 33 - Imagem sintética simulando pistas de estradas .....	84
Figura 34 - Erro medindo largura em segmentos inclinados .....	85
Figura 35 - Recortes de imagem digital real .....	85
Figura 36 - Alargamento da estrada 2 na IMAGEM 1.....	87
Figura 37 - Eixos detectados na IMAGEM 1 usando algoritmos ótimos.....	89
Figura 38 - Eixos detectados na IMAGEM 2 usando algoritmos ótimos.....	90
Figura 39 - Eixos detectados na IMAGEM 3 usando algoritmos ótimos.....	91
Figura 40 - Eixos detectados na IMAGEM 1 usando algoritmos genéticos .....	95
Figura 41 - Eixos detectados na IMAGEM 2 usando algoritmos genéticos .....	96
Figura 42 - Eixos detectados na IMAGEM 3 usando algoritmos genéticos .....	97
Figura 43 - Imagem SINTÉTICA 1 com os segmentos detectados .....	101
Figura 44 - Pixels candidatos ao eixo de estrada vicinal .....	101
Figura 45 - Imagem SINTÉTICA 2 com os segmentos detectados .....	102
Figura 46 - Eixos detectados na IMAGEM 1 usando abordagem automática .....	103
Figura 47 - Eixos detectados na IMAGEM 2 usando a abordagem automática ...	105
Figura 48 - Eixos detectados na IMAGEM 3 usando abordagem automática .....	106
Figura 49 - Eixos detectados na IMAGEM 4 usando abordagem automática .....	109
Figura 50 - Eixos detectados na IMAGEM 5 usando abordagem automática .....	111
Figura 51 - Resultado usando somente imagem digital.....	114
Figura 52 - Resultado usando imagem e dado LASER.....	115
Figura 53 - Estradas extraídas usando a IMAGEM 1 .....	118
Figura 54 - Estradas extraídas usando a IMAGEM 2 .....	119
Figura 55 - Estradas extraídas usando a IMAGEM 3 .....	120

## LISTA DE TABELAS

Tabela 1-	Larguras de segmentos em imagem sintética (em <i>pixels</i> ) .....	84
Tabela 2 -	Largura de segmentos em imagem real (em <i>pixels</i> ) .....	86
Tabela 3 -	Larguras de referência de estradas (em <i>pixels</i> ) .....	86
Tabela 4 -	Qualidade dos eixos detectados usando algoritmos ótimos.....	92
Tabela 5 -	Qualidade dos eixos detectados usando algoritmos genéticos .....	98
Tabela 6 -	Qualidade dos eixos detectados usando abordagem automática .....	108
Tabela 7 -	Comparação entre os reultados dos métodos propostos .....	108
Tabela 8 -	Qualidade dos eixos detectados com abordagem automática usando a IMAGEM 5 .....	112
Tabela 9 -	Qualidade dos eixos detectados .....	115
Tabela 10 -	Qualidade dos eixos detectados com os métodos propostos .....	122
Tabela 11 -	Resultaods obtidos por Wiedemann (2003) .....	123
Tabela 12 -	Melhores resultados obtidos por Zhang(2006).....	123
Tabela 13 -	Resultados obtidos por Close et al. (2007) .....	124

## SUMÁRIO

### CAPÍTULO 1 - INTRODUÇÃO

1.1	INTRODUÇÃO GERAL .....	11
1.1.1	Objetivo geral .....	14
1.1.1.1	Objetivos específicos .....	14
1.1.2	Justificativa .....	15
1.1.3	Contribuição da tese .....	15
1.1.4	Estrutura do trabalho .....	16

### CAPÍTULO 2 - CONCEITOS FUNDAMENTAIS

2.1	INTRODUÇÃO .....	17
2.2	ESTRADAS VICINAIS .....	17
2.3	DADOS ESPACIAIS .....	18
2.4	DETECÇÃO DE DESCONTINUIDADES .....	21
2.4.1	Detecção de bordas .....	21
2.4.2	Detecção de linhas .....	22
2.5	ALGORITMOS GENÉTICOS .....	23
2.5.1	Teoria da evolução das espécies .....	24
2.5.2	Seleção natural e seleção artificial .....	25
2.5.3	Composição dos algoritmos genéticos .....	26
2.6	TRANSFORMADA RADON .....	28
2.7	EXTRAÇÃO DE FEIÇÕES LINEARES .....	30
2.7.1	Extração de estradas .....	31
2.7.1.1	Extração usando somente imagens digitais .....	32
2.7.1.2	Extração usando somente dados altimétricos .....	34
2.7.1.3	Extração usando dados altimétricos e imagens digitais .....	35

### CAPÍTULO 3 – RECURSOS UTILIZADOS

3.1	ÁREA DE ESTUDO .....	36
3.2	IMAGENS DIGITAIS .....	36
3.3	IMAGEM DIGITAL E DADO LASER .....	41
3.4	SOFTWARES .....	42

### CAPÍTULO 4 – METODOLOGIA

4.1	DETERMINAÇÃO DE LARGURAS DE ESTRADAS VICINAIS .....	43
4.1.1	Definição dos perfis transversais de estradas vicinais .....	43
4.1.2	Método proposto para cálculo de larguras de estradas vicinais .....	44
4.2	DETECÇÃO DE LINHAS USANDO ALGORITMOS ÓTIMOS (EXAUSTIVO) .....	46
4.2.1	Detecção de eixo de estradas vicinais .....	46
4.2.2	Iniciando o algoritmo .....	47
4.2.3	Cálculo das larguras das estradas .....	49
4.2.4	Construção do perfil de referência .....	49
4.2.5	Localização do perfil transversal pertencente à estrada .....	51
4.2.6	Determinação dos parâmetros da função objetivo/aptidão .....	52
4.2.6.1.	Correlação linear entre perfis transversais de estradas .....	52
4.2.6.2.	Delimitação da região de busca de novos segmentos .....	53

4.2.6.3.	Similaridade radiométrica entre perfis transversais .....	54
4.2.7	Critérios de parada do processo de detecção.....	55
4.3	DETECÇÃO DE LINHAS USANDO ALGORITMOS GENÉTICOS.....	56
4.3.1	Detecção de eixo de estradas vicinais .....	57
4.3.2	Adaptação dos algoritmos genéticos .....	57
4.3.2.1.	Espaço de busca.....	58
4.3.2.2.	Codificação dos indivíduos e definição da população inicial .....	59
4.3.2.3.	Técnica de seleção e operadores genéticos .....	61
4.3.2.4.	Função de aptidão proposta.....	63
4.3.3	Critérios de parada do processo de detecção.....	64
4.4	DETECÇÃO DE LINHAS USANDO TRANSFORMADA RADON.....	66
4.4.1	Detecção de segmentos lineares .....	66
4.4.1.1.	Detecção de segmentos sementes usando a transformada Radon .....	67
a)	Subdivisão da imagem original .....	67
b)	Posicionamento dos segmentos detectados na imagem .....	68
c)	Seleção dos melhores segmentos semente.....	70
4.4.1.2.	Determinação de larguras de estradas vicinais.....	73
4.4.1.3.	Seleção de novos segmentos e critérios de parada.....	73
4.5	CONTRIBUIÇÃO DA INTEGRAÇÃO DE DADOS ALTIMÉTRICOS.....	75
4.5.1	Método proposto para integração dos dados.....	76
4.6	EXTRAÇÃO DE PISTAS DE ROLAMENTO DE ESTRADAS VICINAIS .....	79
4.7	VALIDAÇÃO DE RESULTADOS.....	80

## **CAPÍTULO 5 – EXPERIMENTOS**

5.1	DETERMINAÇÃO DE LARGURAS DE ESTRADAS VICINAIS.....	84
5.1.1	Usando imagem sintética.....	84
5.1.2	Usando imagem real .....	85
5.1.3	Resumo.....	87
5.2	DETECÇÃO DE LINHAS USANDO ALGORITMOS ÓTIMOS.....	88
5.2.1	Experimento usando a IMAGEM 1.....	88
5.2.2	Experimento usando a IMAGEM 2.....	89
5.2.3	Experimento usando a IMAGEM 3.....	90
5.2.4	Resumo.....	93
5.3	DETECÇÃO DE LINHAS USANDO ALGORITMOS GENÉTICOS.....	94
5.3.1	Experimentos usando a IMAGEM 1 .....	94
5.3.2	Experimentos usando a IMAGEM 2.....	95
5.3.3	Experimentos usando a IMAGEM 3.....	96
5.3.4	Resumo.....	99
5.4	DETECÇÃO DE LINHAS USANDO TRANSFORMADA RADON.....	100
5.4.1	Experimento usando imagens sintéticas .....	100
5.4.2	Experimento usando a Imagem 1 .....	103
5.4.3	Experimento usando a IMAGEM 2.....	104
5.4.4	Experimento usando a IMAGEM 3.....	106
5.4.5	Experimento usando a IMAGEM 4.....	109
5.4.6	Experimento usando a IMAGEM 5.....	110
5.4.7	Resumo.....	113
5.5	CONTRIBUIÇÃO DA INTEGRAÇÃO DE DADOS ALTIMÉTRICOS.....	114
5.5.1	Resumo.....	116
5.6	EXTRAÇÃO DE PISTAS DE ROLAMENTO DE ESTRADAS VICINAIS .....	118

5.6.1	Extração de pistas de estradas a partir das IMAGENS 1, 2 e 3.....	118
5.6.2	Resumo.....	121
5.7	COMPARAÇÃO COM OUTROS MÉTODOS .....	122
5.7.1	Comparação com o método de Wiedemann (2003).....	122
5.7.2	Comparação com o método de ZHANG (2006).....	123
5.7.3	Comparação com o método de Clode et al. (2007) .....	124

## **CAPÍTULO 6 – CONCLUSÃO**

6.1	CONSIDERAÇÕES FINAIS.....	125
6.2	RECOMENDAÇÕES .....	127

## **REFERÊNCIA BIBLIOGRÁFICA**

## **CAPÍTULO 1 – INTRODUÇÃO**

### **1.1 INTRODUÇÃO GERAL**

O sensoriamento remoto, de modo geral, tem sido uma ferramenta útil e de baixo custo na obtenção de informações espaciais. Essas informações têm servido de fonte de dados para diferentes finalidades, tais como estudos e levantamentos cartográficos, geológicos ou florestais (RICHARDS e JIA, 1998; NOVO, 1992; CROSTA, 1993; SWAIN e DAVIS, 1978; LILLESAND e KIEFER, 2000; MOREIRA, 2003).

Inovações tecnológicas ocorridas no sensoriamento remoto, tais como o aumento de resolução espacial e a possibilidade de coleta de dados altimétricos, permitem estudos mais detalhados sobre feições existentes na superfície da terra. Em menos de três décadas, a resolução espacial variou de muitos metros para uma proporção centimétrica. Um avanço, relativamente rápido, ocorreu também no processo de coleta de dados altimétricos, por exemplo, a melhora da acurácia altimétrica. Essa nova realidade proporcionou desafios aos pesquisadores de áreas como o sensoriamento remoto e o processamento digital de imagens. Técnicas como classificação, detecção e extração de feições são exemplos típicos de desafios emergentes. Por exemplo, a detecção e extração de feições lineares que apresentam rupturas ou falhas, como sombras, similaridade radiométrica e/ou ruídos, são temas bastante pesquisadas atualmente.

Feições como construções, quadras e estradas são difíceis de serem extraídas em imagens digitais. Uma das dificuldades é a similaridade radiométrica entre feições distintas. Uma forma de amenizar esse tipo de problema é o uso de informações que extrapolam o conhecimento intrínseco do objeto. Por exemplo, uso de informações de feições vizinhas.

Existem dois processos distintos na extração de estradas: o automático e o semi-automático. No primeiro, não há participação do analista. No segundo, entretanto, o analista fornece informação, a priori, para o programa (DAL POZ et al., 2000; DAL POZ, 2000; DAL POZ, 2001; PEREZ-JIMENEZ e PEREZ-CORTES, 2006).

A extração automática ou semi-automática de quaisquer tipos de estradas minimiza o trabalho exaustivo de digitalização ou vetorização, além de diminuir custos inerentes ao processo de criação de mapas rodoviários (LIU et al., 2003; SILVA et al., 2004). A prática de vetorização é comum em órgãos que usam mapas rodoviários, por exemplo, o Instituto Brasileiro de Geografia e Estatística (IBGE), Departamento Nacional de Infra-Estrutura de Transportes (DNIT) e outras empresas, como agências de turismo.

A extração de rodovias e/ou estradas, a partir de imagens digitais, tem sido abordada de diferentes formas, com aplicação de diferentes algoritmos, de acordo com o tipo de dados usado. Exemplos podem ser encontrados em Baumgartner et al. (1999), Wiedemann e Hinz (1999), Dal Poz et al. (2001), Clode et al. (2004) e Hasegawa (2004).

Quanto aos dados usados, eles podem ser imagens de alta ou baixa resolução, ou dados da varredura a LASER (CLODE et al., 2007); e quanto às estratégias usadas, elas podem ser de baixo ou alto nível (VALADAN ZOEJ e MOKHTARZADE, 2004). O grupo dos algoritmos robustos, ou de alto nível, apresenta um escopo mais complexo, pois extrapola o conhecimento intrínseco do objeto estudado, usando informação contextual de vizinhança (VOSSELMAN e KNECHT, 1995; CLODE et al., 2004; EKER e SEKER, 2004; MOHAMMADZADEH et al., 2004; WESSEL, 2004; HU e TAO, 2007).

A maioria das técnicas de extração de estradas aborda o uso de detecção de linhas e/ou bordas. São vários os detectores de bordas de feições, em imagens digitais, propostos na literatura. Dentre os mais usados, podem ser citados: Canny, Prewitt e Sobel (CANNY, 1986; ARGIALAS e MAVRANTZA, 2004; BACHER e MAYER, 2004). Por outro lado, estudos sobre detecção de linhas não têm recebido a mesma atenção dada às bordas. Mesmo assim, existem diferentes métodos de detecção de feições lineares (STEGER, 1998; MAYER e STEGER, 1998; ARGIALAS e MAVRANTZA, 2004; BACHER e MAYER, 2004). Como exemplo, pode-se citar a detecção de estradas em imagens de baixas e médias resoluções (GOMES et al., 2004; DAL POZ e AGOURIS, 2000).

As rodovias e/ou estradas, segundo Vosselman e Knecht (1995), apresentam características radiométrica, geométrica, topológica, funcional e contextual. Porém, neste estudo, são consideradas apenas as características radiométricas e geométricas de estradas vicinais, isto é, os parâmetros intrínsecos à

estrada, tais como direção e comprimento dos segmentos, largura da estrada (geométricas) e valores digitais (radiométrica). As características geométricas e radiométricas da feição estrada fazem parte de um modelo global denominado modelo intrínseco. Entre outras características, esse modelo leva em consideração a geometria e o material das estradas (ZANIN, 2004).

Entre os estudos realizados nesta linha de pesquisa, algumas propostas buscam extrair a estrada usando algoritmos ótimos (busca exaustiva). Esses algoritmos aperfeiçoam a detecção dos parâmetros geométricos da estrada (DAL POZ e AGOURIS, 2001; ZANIN, 2004). Outras abordagens, usando algoritmos subótimos, têm sido usadas na tentativa de reduzir o custo computacional (MIRMEHDI et al., 1997). Os algoritmos do primeiro grupo, algoritmos ótimos, são rotinas computacionais que buscam exaustivamente a solução de um determinado problema, isto é, analisa todas as possibilidades de solução do problema. Por outro lado, os algoritmos subótimos realizam buscas aleatórias de possíveis soluções no espaço n-dimensional de soluções. Essa característica é interessante para solução de problemas complexos, em espaços multidimensionais. Os algoritmos genéticos são exemplos do segundo grupo de algoritmos.

A proposta desse trabalho é baseada no uso de imagem aérea, imagem IKONOS e dado LASER, e é dividida em duas fases: a medição de larguras, a detecção seqüencial com realimentação de eixos de estradas vicinais. O método proposto para medir larguras de estradas vicinais é baseado no gradiente de perfis transversais. Os métodos propostos para detecção de eixos de estradas vicinais fazem uso dos algoritmos genéticos, de algoritmos ótimos e da transformada Radon em abordagens automática e semi-automática. Adicionalmente, as pistas de rolamento das estradas vicinais são extraídas para fins de visualização. É proposto ainda um método para avaliação da qualidade dos eixos detectados.

O método proposto para detectar segmentos de reta (eixos de estrada vicinal) é fundamentado em uma função objetivo, ou de aptidão, composta por três parâmetros. O primeiro parâmetro refere-se à correlação linear entre dois perfis transversais de estrada; o segundo indica a melhor direção do segmento procurado; e o terceiro mede a similaridade radiométrica entre o perfil de referência e o perfil procurado. Os dois casos experimentados, semi-automático e automático, são iterativos e, em cada iteração, um segmento candidato à estrada vicinal é selecionado.

Os processos de detecção de linhas e cálculo das larguras das estradas vicinais são baseados em segmentos sementes. Nas abordagens semi-automáticas, os segmentos sementes são fornecidos pelo operador, contudo, na abordagem automática, esses segmentos são selecionados por meio de um método proposto, usando a transformada Radon. Essa transformada permite detectar linhas tanto claras quanto escuras, em imagens digitais. Contudo, nesse estudo, atenção foi dada às linhas claras, por definirem bem a feição de interesse.

Findada a detecção de eixos, inicia-se o processo de extração das pistas das estradas vicinais, utilizando os eixos e as larguras detectados. Por fim, a validação dos produtos resultantes é realizada por meio dos índices completeza, correção e RMSEixo. É proposto, nesse estudo, um modelo matemático para cálculo do RMSEixo. A descrição detalhada dos métodos propostos é apresentada ao longo desse texto.

### 1.1.1 Objetivo geral

Extrair estradas vicinais por meio de métodos de buscas seqüenciais, usando imagens digitais e dado LASER.

#### 1.1.1.1 Objetivos específicos

Criar uma função objetivo eficiente no processo de detecção semi-automática de eixos de estradas vicinais, usando imagens digitais e algoritmos ótimos (exaustivo);

Desenvolver uma função de aptidão hábil no processo de detecção semi-automática de eixos de estradas vicinais, usando imagens digitais e algoritmos genéticos (subótimos);

Avaliar uma metodologia para detecção automática de segmentos semente, usando imagens digitais e a transformada Radon;

Propor uma função objetivo eficiente no processo de detecção automática de eixos de estradas vicinais, usando imagens digitais e algoritmos ótimos (exaustivo);

Elaborar uma função objetivo hábil no processo de detecção automática de eixos de estradas vicinais, usando imagens digitais, dados LASER e algoritmos ótimos (exaustivo).

### 1.1.2 Justificativa

A principal justificativa dessa pesquisa é a tentativa de reduzir o trabalho exaustivo de vetorização manual de estradas realizado por muitos órgãos, por exemplo, o IBGE, diminuindo custos inerentes ao processo.

Face à importância das estradas vicinais para o desenvolvimento de qualquer município no âmbito econômico, social e político, a escassez de mapeamento dessas feições devida principalmente à morosidade do processo, é uma justificativa para a concretização desse trabalho de pesquisa, tendo em vista que são propostos métodos que facilitam a realização dessa tarefa, usando imagens digitais, que são dados de custo relativamente baixo nos dias atuais.

A questão da automatização de métodos de extração de feições em imagens digitais tem sido bastante pesquisada, mas ainda é um desafio, tendo em vista a complexidade dessa tarefa. Portanto, quando se trata da proposição de métodos automáticos, independentemente da feição alvo, ela é, atualmente, uma justificativa plausível para a continuidade de qualquer pesquisa que tenha essa temática como objetivo.

Além de ser um tema inovador, foram encontradas poucas (quatro) pesquisas que abordam a extração de estradas, usando dado LASER scanner aerotransportado. Portanto, essa é outra justificativa plausível, pois o presente texto será base para pesquisas futuras, principalmente, no Brasil.

### 1.1.3 Contribuição da tese

- a) Modelo matemático para avaliação da qualidade dos produtos gerados;
- b) Método para cálculo da largura de estradas vicinais;

- c) Método semi-automático para detecção de eixos de estradas vicinais usando algoritmos ótimos (exaustivo);
- d) Método semi-automático para detecção de eixos de estradas vicinais usando algoritmos genéticos (subótimo);
- e) Método para detecção de segmentos sementes e eixos de estradas vicinais usando a transformada Radon, em abordagem automática; e
- f) Extração de pistas de estradas vicinais.

#### 1.1.4 Estrutura do trabalho

Este trabalho de tese é composto por seis capítulos, que descrevem todo o estudo realizado na elaboração de métodos usados na extração de estradas vicinais. Uma introdução geral, juntamente com os objetivos e as justificativas da pesquisa, é apresentada no presente capítulo. No capítulo 2, são expostos alguns conceitos fundamentais relacionados com o contexto da pesquisa, tais como: estradas vicinais, dados espaciais, detecção de descontinuidades, transformada Radon, algoritmos genéticos e extração de feições lineares. Os materiais utilizados, imagens digitais, dados LASER scanner e *softwares*, são indicados no capítulo 3. A metodologia proposta é apresentada no capítulo 4 contendo: (a) um método para determinar larguras de estradas vicinais; (b) um método para detecção de eixos de estradas vicinais em uma abordagem semi-automática e usando algoritmos ótimos; (c) um método para detecção semi-automática de eixos de estradas vicinais usando algoritmos genéticos; (d) um método para detecção automática de eixos de estradas vicinais; (e) um método para detectar eixos de estradas vicinais usando dado LASER scanner integrado com imagem digital; (f) Extração de pistas de rolamento de estradas vicinais; e (g) um modelo para avaliar a qualidade geométrica dos eixos detectados. Os experimentos, as discussões acerca dos resultados obtidos e um breve resumo de cada método são apresentados no capítulo 5. Finalmente, no capítulo 6, é apresentada uma conclusão geral, incluindo recomendações.

## **CAPÍTULO 2 - CONCEITOS FUNDAMENTAIS**

### **2.1 INTRODUÇÃO**

Alguns conceitos necessários para o entendimento do texto exposto nesse trabalho são apresentados na seguinte ordem: estradas vicinais, dados espaciais, detecção de descontinuidade, algoritmos genéticos, transformada Radon e extração de feições lineares.

### **2.2 ESTRADAS VICINAIS**

O interesse, nessa pesquisa, são as estradas sem pavimentação asfáltica e que se localizam no meio rural. São várias as nomenclaturas existentes, como estradas rurais, estradas de terra, estradas de chão e estradas vicinais. Essa última terminologia é a mais adequada para descrever as estradas de interesse nesse estudo, pois as demais terminologias não fazem distinção entre as estradas em meio urbano e rural.

De acordo com DNIT (2007), estradas vicinais são vias de acessos às pequenas vilas, fazendas e sítios, ou caminhos que ligam povoações relativamente pequenas e próximas. Adicionalmente, são estradas compostas por solo exposto, sem pavimentação asfáltica.

Escoamento da produção agrícola, transporte coletivo e escolar e transporte de produtos primários são tipos de conduções realizadas com frequência, nesses tipos de estradas. Segundo Castro (2003), a interrupção de uma dessas vias acarreta prejuízos como perda de produtos perecíveis, ausência dos alunos e professores nas escolas, impossibilidade de atendimento médico, aumento dos custos no transportes dos produtos agrícolas, além de estimular o êxodo rural. Dessa forma, o desenvolvimento econômico e social de um determinado município depende da existência e condições de trafegabilidade dessas estradas.

Cruz (2005) relata que a malha viária brasileira é constituída de aproximadamente 1.724.929,00 km de estradas, das quais aproximadamente 90,4%

são de estradas não pavimentadas, sem considerar as redes de estradas florestais, que geralmente são não pavimentadas.

Diante de tamanha importância é prudente, por parte dos municípios, elaborar um mapeamento dessas estradas, para que se tenha controle de parâmetros como localização e extensão, facilitando, dessa forma, a tomada de decisões em processos como a manutenção, restauração e construção desse tipo de estradas. A Figura 1 mostra alguns exemplos de estradas vicinais.



Figura 1 - Exemplos de estradas vicinais

Uma característica intrínseca dessa feição, importante para essa pesquisa, é sua composição, com solo exposto, sem pavimentação asfáltica. Essa característica possibilita uma análise radiométrica semelhante à realizada sobre o solo exposto, sendo, portanto, explorada nessa pesquisa.

### 2.3 DADOS ESPACIAIS

A corrida pós-segunda guerra mundial por informação espacial foi um dos fatores que deram início ao sensoriamento remoto. Essa ciência teve início objetivando atender à demanda militar. Todavia, os desenfreados avanços tecnológicos nas indústrias dos sensores despertaram interesses comerciais de particulares, tornando impossível o controle sigiloso desses dados. Mais precisamente, o sensoriamento remoto teve sua origem na década de 70 e os sensores criados e lançados ao espaço, nessa época, apresentavam baixa resolução espacial ( $\approx 80$  metros), radiométrica (de 2 até 15 bandas espectrais) e radiométrica (de 2 até 8 *bits*).

Com as inovações tecnológicas ocorridas nas indústrias de sensores, poucos anos depois, uma nova configuração, no que tange a resoluções, é

apresentada. Entretanto, só a partir do final da década de 80 é que ocorreram mudanças significativas no aprimoramento dos sensores, no âmbito espacial, espectral e radiométrico. A Figura 2 mostra os principais sensores e o avanço ocorrido em termos de resolução espacial.

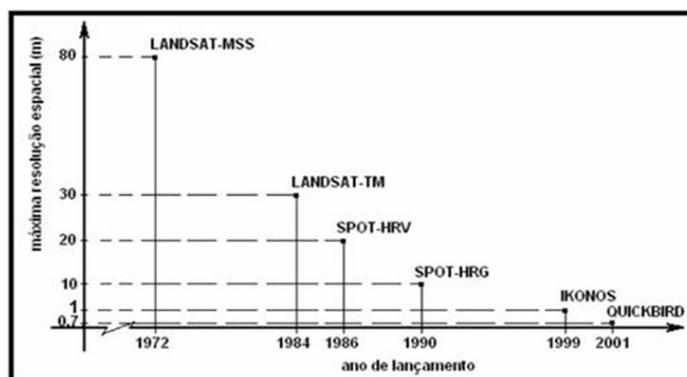


Figura 2 - Aprimoramento dos sensores ao longo do tempo  
Fonte: Adaptado de Centeno (2004)

Verifica-se na Figura 2 que os sensores dos satélites IKONOS e QUICKBIRD apresentam resolução espacial de 1 e 0,7, respectivamente. A denominação de alta resolução espacial surge a partir desses pequenos valores, quando comparados à resolução dos demais sensores apresentados (baixa resolução espacial). Vários estudos, utilizando os dados de sensores de alta resolução espacial, têm sido realizados em diversos tipos de aplicações, alguns exemplos podem ser vistos em Liu et al. (2003), Silva e Dal Poz (2003), Vale (2003), Poon et al. (2005), Perkins et al. (2000).

Paralelamente às mudanças espaciais, espectrais e radiométricas, surgiram os sensores para captação de dados altimétricos. Esses sensores podem ser classificados em três categorias, de acordo com a forma de coleta de informação e processo de cálculo da altitude. A primeira categoria é a Radargrametria (ou estereoscopia), ou seja, é o processo de medida da altimetria por estereoscopia, que leva em consideração a paralaxe existente em um par de imagens de amplitudes (BASKAKOV et al., 1984; LEGRESY e REMY, 1998; PARADELLA et al., 2005; ROCHA et al., 2005). A segunda categoria é o radar por interferometria, que determina a altimetria por diferenças da fase do sinal retroespalhado, em tomadas sob geometrias distintas (FRANCESCHETTI et al., 2000; LILLESAND e KIEFER, 2000; SUNA et al. 2003; HALL et al., 2005; PARADELLA et al., 2005; RODRÍGUEZ

et al., 2005). Finalmente, a terceira categoria é o LASER scanner, que é classificado como terrestre (HANCOCKA et al., 1998; LICHTI et al., 2002; KERSTING et al., 2004; RIETDORF et al., 2004; VALANIS e TSAKIRI, 2004; WUTKE, 2006) e aerotransportado (TOCH, 1998; BALTSAVIAS, 1999; CUDAHY et al., 1999; CROSILLA et al., 2005) de acordo com a plataforma usada. Isto é, se a plataforma é uma aeronave, o LASER é aerotransportado, mas se o equipamento está em terra firme ou em um veículo, carros e caminhões, o LASER é terrestre.

O LASER scanner é um sistema composto por dois grupos de sensores. O primeiro grupo é um tipo de sensoriamento remoto ativo, que tem por objetivo a medição da altimetria com base em pulsos LASER; por outro lado, o segundo grupo é um tipo de sensoriamento remoto passivo, responsável pela obtenção de duas imagens digitais, denominadas de intensidade e hipsométrica.

O sensor utilizado na obtenção de informação altimétrica é composto por um emissor e um receptor de pulsos LASER. A distância entre o equipamento e o alvo, atingido pelo pulso, é medida pela diferença de tempo entre a emissão e a recepção do pulso e a velocidade da luz, em tempo real.

O conjunto de instrumentos (emissor/receptor) é organizado de forma que possa emitir pulsos LASER em direção ao objeto de interesse e receber/medir a intensidade da energia desses pulsos que retornam ao equipamento. A energia que retorna ao equipamento é função do tipo e/ou forma dos objetos com que os pulsos LASER interagem na superfície terrestre. A energia ou pulso que retorna ao equipamento é armazenada de duas formas distintas, comumente denominadas de primeiro e último pulso (*first/last pulse*).

As distâncias medidas pelo LASER são associadas a um sistema de referência por intermédio de um conjunto de medições de apoio. As informações de apoio são geradas simultaneamente às distâncias obtidas com o LASER, usando GPS diferencial (dGPS) e IMU (Inertial Measurement Unit). O dGPS tem a função de fornecer as coordenadas locais instantaneamente, e o IMU mede a instabilidade da aeronave, isto é, os movimentos da aeronave em torno dos eixos de um determinado sistema de referência.

## 2.4 DETECÇÃO DE DESCONTINUIDADES

Estudos sobre a técnica de detecção de descontinuidades também não são recentes. Mesmo antiga, essa técnica ainda é intensamente aplicada no processamento de imagens. O uso incessante dessa técnica deve-se à grande aplicação em várias áreas do conhecimento, desde o artístico (fotografias) até o técnico científico, por exemplo, nas engenharias e medicina. Outra importância dessa técnica é que a informação derivada do seu processamento pode ser usada na fase prévia para outras técnicas, como a extração de feições e o reconhecimento de padrão. Boochs e Heinz (1999) usaram um algoritmo para detectar pontos homólogos em um par de fotos, visando a uma posterior extração de objetos a partir do modelo gerado.

Existem três tipos diferentes de descontinuidades: pontos, linhas e bordas (GONZALEZ e WOODS, 2004). A forma de detecção de descontinuidades mais comum é por meio de uma convolução. O processo de convolução é a varredura da imagem com uma janela (ou máscara), computando a soma dos produtos dos coeficientes (ou pesos) pelos níveis de cinza contidos na região coberta pela máscara.

No contexto dessa pesquisa, as descontinuidades a serem detectadas são as linhas (ou segmentos) candidatas ao eixo de estrada vicinal e as bordas candidatas a limites (ou margem) dessa estrada, para obtenção das larguras das estradas.

### 2.4.1 Detecção de bordas

Bordas em uma imagem são as mudanças de intensidade (nível de cinza), originadas de aspectos físicos de uma superfície iluminada. Portanto, o detector de bordas objetiva encontrar e caracterizar essas mudanças significativas de intensidade. Conceitos de derivadas e escalas são usados para caracterizar o tipo de mudança de intensidade ocorrido (TORRE e POGGIO, 1986; ZANIN, 2004; YOUNAN et al., 2005). Contudo, além da proposta de uso de derivadas, outras

abordagens têm sido exploradas no sentido de aprimorar a técnica de detecção de bordas. Younan et al. (2005) usaram a máxima entropia para detectar bordas em imagem multiespectral. A escolha de uso da máxima entropia foi baseada na simplicidade de implementação e por apresentar características vantajosas em relação aos métodos convencionais. A aplicação deste método no processo de extração de estradas, usando imagens digitais, é mostrada como robusta no que tange ao desempenho do algoritmo.

Um problema da derivação é o fato de ser sensível aos ruídos existentes em uma imagem. A recomendação, portanto, é que antes da derivação seja processada uma suavização da imagem. Contudo, a suavização também produz efeitos indesejáveis, tais como, deslocamento de bordas e perda de informação. Devido a esses problemas, vários detectores de bordas foram propostos, cada um com sua particularidade.

#### 2.4.2 Detecção de linhas

Para detectar linhas em imagens digitais, são comumente usadas máscaras com configurações definidas de acordo com o tipo de linha que se deseja detectar. Em Gonzalez e Woods (2004), são apresentadas máscaras apropriadas para detectar linhas horizontais, verticais ou inclinadas ( $45^\circ$ ). Os conceitos de derivada e gradiente também são aplicados nessa técnica.

Outros trabalhos com abordagens diferentes têm sido propostos. Por exemplo, Wu (1993) apresentou uma técnica de detecção de linhas que evita o uso de derivadas. O foco do estudo foi a detecção de linhas de contornos fechados, usando relações topológicas. Foi criado um sistema interativo que permite ao operador a decisão de ligação das linhas não-fechadas, detectadas automaticamente. A metodologia proposta é recomendada para dados similares, como batimetria e mapas geológicos. A formalização de regras topológicas e, conseqüentemente, sua aplicação para a detecção de linhas de contorno é, sem dúvida, um avanço em direção à automatização do processo.

Diferentemente da técnica que usa varredura com máscaras (filtros), o presente estudo apresenta uma técnica para detecção seqüencial de linhas,

candidatas à estrada vicinal, usando conceitos de algoritmos ótimos (exaustivo), algoritmos genéticos e de transformada Radon.

Os algoritmos ótimos são rotinas computacionais que avaliam todas as possibilidades de solução de um determinado problema. Essa característica dos algoritmos ótimos pode ser uma desvantagem, dependendo da quantidade de possibilidades de solução existentes, isto é, se o número de soluções é muito grande o processamento é exaustivo.

## 2.5 ALGORITMOS GENÉTICOS

A partir da década de 30, estudiosos da área biológica e informática começaram a se interessar pelos algoritmos genéticos. Todavia, só na década de 70 é que houve maiores avanços nessa linha de pesquisa. John Holland, citado por Goldberg (1989), como o pioneiro no assunto, buscou elaborar algoritmos que descrevessem o comportamento da natureza no que tange à evolução das espécies e aos processos genéticos dos organismos biológicos. O princípio de funcionamento desses algoritmos baseia-se na teoria Darwiniana de seleção natural e na teoria Genética de Mendel. A idéia principal enfocada por John Holland e outros estudiosos era resolver problemas reais, em especial problemas complexos de otimização, por meio de sistemas inspirados na natureza, simulando os processos naturais.

Goldberg (1989), um dos precursores dos algoritmos genéticos, descreveu-os como uma pesquisa baseada no mecanismo de seleção e genética natural objetivando a otimização. Segundo este autor, os algoritmos genéticos superam os outros métodos tradicionais de otimização encontrados na literatura, por terem as seguintes vantagens:

- a) Trabalham com a codificação dos parâmetros e não com os dados reais, podendo, em alguns casos, reduzir o tempo de processamento.
- b) Fazem busca em uma população e não em um único ponto;
- c) Usam a informação de aptidão e não outro conhecimento auxiliar; e
- d) Usam regra de transição probabilística e não determinística.

Lutton e Martinez (1994) caracterizaram os algoritmos genéticos como uma técnica estocástica de grande eficiência no processo de busca em espaço

dimensional elevado. Wang e Fan (1996) fizeram um estudo sobre as vantagens e desvantagens do uso desses algoritmos em problemas de otimização. Uma aplicação dos algoritmos genéticos na extração de feições lineares é encontrada em Perez-Jimenez e Perez-Cortes (2006). Esses autores concluíram que os algoritmos genéticos apresentam um número maior de vantagens quando comparadas com as desvantagens inerentes ao seu funcionamento.

Os algoritmos genéticos, a programação genética e a programação evolucionária são modelos trabalhados na área de computação evolucionária. As redes neurais artificiais, os sistemas fuzzy e a computação evolucionária, por sua vez, fazem parte da denominada inteligência computacional. A inteligência computacional é caracterizada por manipulação numérica (e não simbólica) do conhecimento, adaptabilidade e tolerância a informações imprecisas (LOPES, 1999).

### 2.5.1 Teoria da evolução das espécies

Foram muitas as teorias que tentavam explicar a origem da vida e a evolução das espécies. O biólogo francês Lamarck, no início do século XIX, defendeu a teoria do transformismo, ao julgar que, na luta pelo alimento, os seres vivos se desenvolviam fisicamente de acordo com suas necessidades alimentares e transmitiam essas características para seus descendentes (PAULINO, 1995).

Em 1859, o naturalista inglês Charles R. Darwin, influenciado pela teoria de Lamarck, propôs a teoria da evolução das espécies. A teoria Darwiniana afirma que a evolução ocorre devido à seleção natural: “Não há exceção à regra de que cada ser orgânico aumenta naturalmente a uma média tão alta que, se não destruído, a terra logo estará povoada com a progênie de um único par” (BOLTON, 1944).

Após a realização do trabalho de Mendel (descoberta da genética), a teoria Darwiniana ganhou um significado maior, tendo sido possível explicar as mudanças genéticas dos indivíduos e, conseqüentemente, a evolução das espécies.

## 2.5.2 Seleção natural e seleção artificial

A principal diferença conceitual entre a seleção natural - processo que ocorre naturalmente, sem a ação do homem - e a seleção artificial implementada nos programas de computadores, é que na seleção natural não existem regras para que ela aconteça, enquanto a seleção artificial é dotada de regras impostas com objetivos específicos.

A técnica de seleção utilizada pelos algoritmos genéticos é a seleção artificial, porém esses algoritmos se baseiam nos princípios de seleção natural e sobrevivência dos indivíduos mais aptos e também nos processos genéticos dos organismos vivos, descritos, respectivamente, por Charles Darwin (1809 - 1882) em "Origem das Espécies" e por Gregor J. Mendel (1822 – 1884).

No decorrer deste texto, a menção ao termo seleção será referente à seleção artificial. Entre as técnicas de seleção mais utilizadas, podem ser citadas: roleta, torneio e elitismo (GOLDBERG, 1989).

A seleção por roleta é uma técnica que consiste da escolha aleatória de um indivíduo. Esse procedimento é realizado da seguinte forma: (a) os indivíduos da população são organizados em ordem decrescente, de acordo com seus valores de aptidão (Figura 3); (b) um valor entre zero e um é gerado aleatoriamente; e (c) o indivíduo correspondente à aptidão acumulada, imediatamente superior ao valor aleatório gerado, é selecionado. Por exemplo, seja uma população com cinco indivíduos, apresentada na Figura 3, e 0,863, o valor gerado aleatoriamente; o elemento selecionado para a próxima geração é o indivíduo 3.

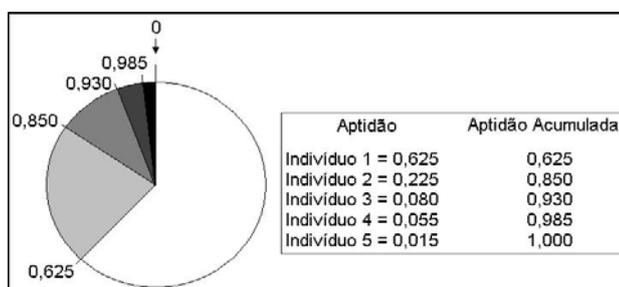


Figura 3 - Funcionamento da técnica de seleção por roleta

A aptidão acumulada é gerada a partir da aptidão do primeiro indivíduo somada à aptidão do segundo, posteriormente, somada à aptidão do terceiro indivíduo e, assim, sucessivamente.

Existem várias formas de aplicar a técnica de seleção torneio, um exemplo seria a seleção aleatória a priori, de uma dupla de indivíduos, e, posteriormente, selecionar um desses dois indivíduos, de acordo com um critério. Esse critério pode ser, por exemplo, o maior valor de aptidão do par de indivíduos escolhido. Assim, o indivíduo que possuir maior aptidão será selecionado.

Finalmente, o elitismo é uma técnica de seleção que preserva um grupo de elite da população antiga, na nova população. Essa técnica é realizada em duas fases: na primeira fase, o grupo elite é selecionado e armazenado na nova população; na segunda, os indivíduos necessários para completar a nova população são selecionados por meio de outra técnica, por exemplo, por torneio.

### 2.5.3 Composição dos algoritmos genéticos

O esquema básico do escopo dos algoritmos genéticos é composto pelos seguintes componentes:

- a) Codificação das variáveis de interesse no problema (cromossomo);
- b) Configurações da população inicial;
- c) Proposta da função de aptidão;
- d) Definição dos operadores genéticos que serão utilizados no processo de reprodução (cruzamento e mutação); e
- e) Definição dos valores dos parâmetros que serão usados (tamanho da população e probabilidades associadas aos operadores genéticos).

Os elementos comuns nos algoritmos genéticos simples, segundo Mitchell (1997), são: a população de cromossomos, a seleção de acordo com a aptidão, o cruzamento para produzir nova prole e a mutação aleatória da nova geração. Existe ainda um quarto elemento que é a inversão, mas, por ser raramente usado, não é discutido, nem aplicado, nesse trabalho.

Os parâmetros (ou constantes) que definem o funcionamento dos algoritmos genéticos simples, propostos por Goldberg (1989), são:

- a) Tamanho máximo que a população poderá assumir;
- b) Tamanho máximo do indivíduo (ou cromossomo);
- c) Probabilidades de cruzamento e mutação;
- d) O valor de aptidão; e
- e) Critérios de parada: número máximo de iterações e/ou limiar para a aptidão.

A Figura 4 ilustra o escopo básico de funcionamento dos algoritmos genéticos.

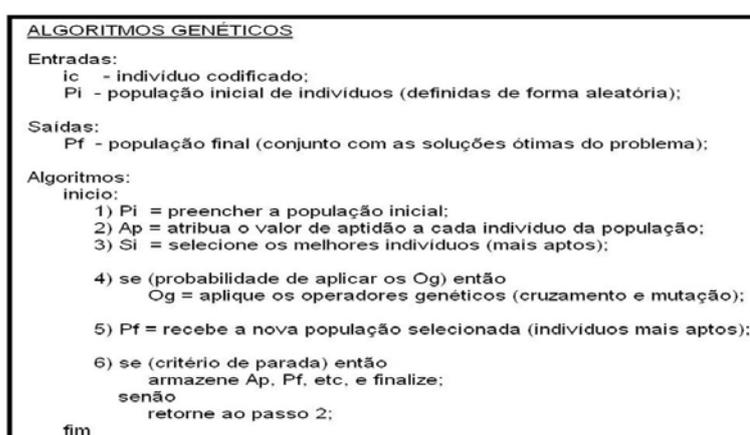


Figura 4 - Escopo dos algoritmos genéticos

Michalewicz (1999) também descreve os algoritmos genéticos como uma seqüência de linhas de comando, como apresentado na Figura 4.

Na transformação do conjunto de variáveis de interesse numa cadeia similar à cadeia genética, a representação binária é geralmente utilizada. Dentro da codificação binária, cada elemento pode assumir dois valores: 0 (zero) ou 1 (um). Um número com oito *bits*, por exemplo, é definido a partir de um arranjo de zero e um, sendo as cadeias limites: 00000000 e 11111111. A decodificação, ou a transformação do número binário em decimal, é necessária para recuperar os valores armazenados numa cadeia binária.

Os algoritmos genéticos apresentam vantagens e desvantagens em relação aos algoritmos ótimos. Adicionalmente às vantagens apresentadas anteriormente, esses algoritmos podem exigir menor esforço computacional (depende de parâmetros como o número de iterações e a complexidade matemática da função de aptidão) e buscam por um ponto subótimo e não, necessariamente, um ponto ótimo, sendo isto importante em problemas complexos, em espaços multidimensionais. As

principais desvantagens inerentes aos algoritmos são um elevado número de parâmetro e, para problemas que interessam somente ao ponto ótimo, o processo deve ser repetido várias vezes.

## 2.6 TRANSFORMADA RADON

A transformada Radon é uma função que retorna uma matriz  $TR(x', \theta)$  que contém em cada célula a soma das intensidades presentes ao longo de uma direção na imagem (AVERBUCH, et al., 2001; VENTURAS e FLAOUNAS, 2005). Por exemplo, na Figura 5a, a posição 0, no eixo  $x'$ , contém a soma das intensidades do eixo da estrada. Nota-se, nesse exemplo, que o valor de  $TR(x', \theta)$ , em qualquer outra linha, por exemplo,  $TR(-dst, \theta)$  e/ou  $TR(dst, \theta)$ , tem magnitude menor que a linha  $TR(0, \theta)$ , que representa o eixo da estrada na subimagem. As distâncias  $dst$  são afastamentos quaisquer da origem do eixo  $x'$ , em ambos os sentidos, negativo e positivo. Na Figura 5b, o pico referente ao maior somatório de intensidades está na posição  $dst$ , no eixo  $x'$ , assim,  $TR(dst, \theta)$  é o valor máximo em relação ao valor de qualquer outra direção nessa imagem.

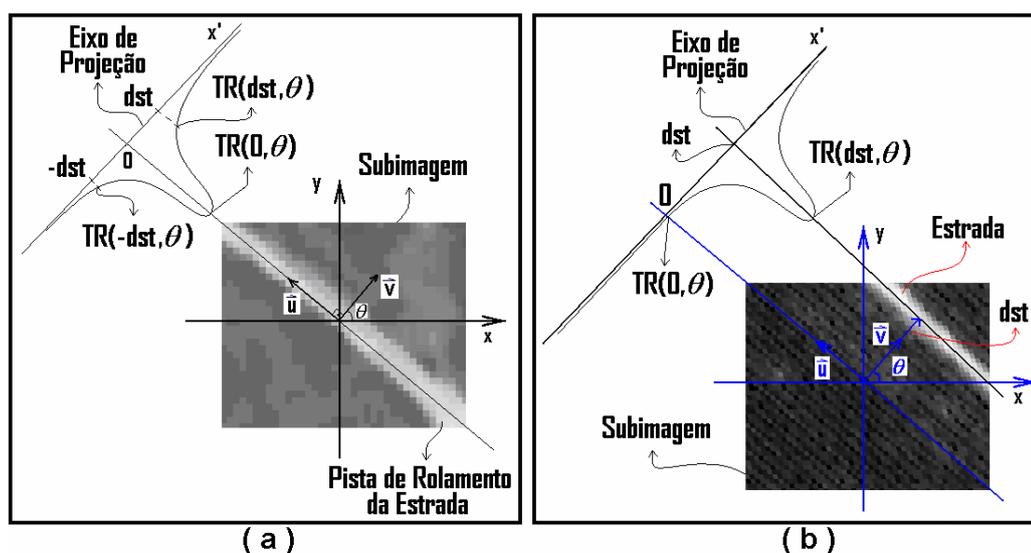


Figura 5 - Transformada Radon

Em outras palavras, a transformada Radon é uma função que atribui um valor numérico para cada membro (posições em  $x'$ ) de uma família ( $\theta$ ) de linhas. A

origem do eixo  $x'$  corresponde à linha que passa pelo centro da subimagem original, na direção  $\theta$ . O sentido positivo de  $x'$  é o mesmo do vetor unitário  $\vec{v}$ .

Segundo Averbuch et al. (2001), a transformada Radon, em termos contínuos, é o mapeamento da função  $f(x,y)$  pela função  $TR(x',\theta)$ , em que  $(x,y) \in \mathbb{R}^2$ ,  $x \in \mathbb{R}$  e  $\theta \in [0,\pi)$ . O modelo matemático da transformada Radon ( $TR$ ) é apresentado na equação 1.

$$TR(x',\theta) = \iint f(x,y) \cdot \delta(x \cos \theta + y \sin \theta - x') dx dy \quad (1)$$

em que  $\theta$  é a direção do vetor normal à linha de interesse;  $\delta$  é o impulso unitário ou delta de Dirac, que tem por propriedade assumir valor zero, caso seu argumento seja diferente de zero, e valor de sua integral igual a 1 (um), no caso contrário.

Neste estudo, o espaço original é discreto, ou seja, uma imagem digital, portanto, a integral, é substituída pelo somatório. Assim,  $TR$  receberá na posição  $(x',\theta)$  (em que  $x'$  são as linhas e  $\theta$  são as colunas de  $TR$ ) a soma das intensidades dos *pixels* que estão sobre uma linha coincidente ou paralela ao vetor unitário  $\vec{u}$ , ilustrado na Figura 5a. A imagem negativa da  $TR$ , gerada da Figura 5a, pode ser vista na Figura 6.

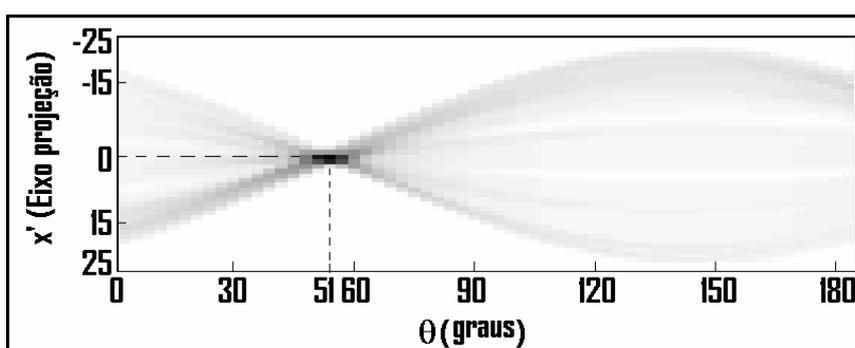


Figura 6 - Resultado da transformada Radon (imagem negativa)

O pico correspondente às intensidades do eixo da estrada é evidenciado na Figura 6 (região escura). Esse pico indica que na direção  $\theta = 51^\circ$  existe uma feição linear que passa pela origem ( $x'=0$ ), ou centro da imagem original.

A transformada Radon é uma técnica conceitualmente similar à transformada *Hough*, mas apresenta as seguintes vantagens: é hábil na extração de linhas em imagens com ruídos, apresenta boa eficiência computacional e possibilita

detectar tanto linhas claras quanto escuras na mesma imagem (MURPHY, 1986; COPELAND et al., 1995; TOFT, 1996; ZHANG, 2006).

As duas primeiras vantagens são de interesse dessa pesquisa, mas a terceira não é relevante, uma vez que a feição estrada vicinal é composta somente de linhas claras (altos valores digitais).

O exemplo apresentado anteriormente ilustra a aplicação da transformada Radon sobre uma imagem que possui uma única feição linear, ou única estrada. Ressalta-se que essa técnica não se limita a esse tipo de imagem. Isto é, ela pode ser aplicada a imagens que possuam várias feições lineares. Porém, a complexidade de interpretação dos resultados aumenta com o crescimento do número de feições lineares presentes, pois são criados tantos picos quantas forem as feições lineares presentes.

## 2.7 EXTRAÇÃO DE FEIÇÕES LINEARES

As técnicas de extração de feições podem ser automáticas ou semi-automáticas. A automática não necessita da participação do operador. Por outro lado, a semi-automática carece da interação do operador (ZANIN, 2004).

A extração de feições lineares, tais como rios e estradas, é muito utilizada em áreas do conhecimento como Fotogrametria e Sensoriamento Remoto (JEON et al., 2002). Esse processo é fundamentado na associação de medidas que caracterizam o objeto de interesse (SANTOS et al., 2005; OLIVEIRA et al., 2005). Uma feição não é determinada, necessariamente, por um único atributo. Portanto, a identificação de uma feição pode ser computada como o somatório das medidas que a caracterizam. Funções de aptidão ou objetivo, por exemplo, condensam várias informações acerca de uma feição.

### 2.7.1 Extração de estradas

Buscando simplificar o entendimento do tópico apresentado nessa seção, o termo estrada é usado em substituição aos termos rodovias e qualquer outro tipo de estradas.

Desde a década de 70, estudos sobre a automatização do processo de extração de estradas vêm sendo desenvolvidos. A forma de abordar o tema evoluiu juntamente com os avanços tecnológicos dos sensores. Isto é, no início, as abordagens se apoiavam apenas no uso de imagens de baixa resolução, produto comum daquela época. Contudo, com o surgimento dos sensores de alta resolução espacial e de dados altimétricos, a técnica de extração de estradas passou por alterações para se adaptar à nova realidade. Exemplo dessas alterações é o uso de parâmetros como a largura da estrada nos escopos dos algoritmos.

Várias abordagens têm sido propostas para a extração de estradas. A diferença entre essas propostas deve-se à estratégia usada, por exemplo: tipo e resolução de imagem usada, configuração dos experimentos, formas de processamento e suposições gerais (WANG et al., 2005). Por exemplo, Eidenbenz et al. (2000) propuseram uma abordagem que usa fusão de múltiplas estratégias sobre a existência do objeto estrada. Para elaboração dessas estratégias, empregaram o conhecimento existente, regras e modelos que tratam, diferentemente, cada subclasse de estradas. O objetivo dessa multiplicidade é o aumento da taxa de sucesso e confiança dos resultados.

O processo de extração de estradas, segundo Dal Poz (2000), pode ser abordado em três níveis: modelagem da malha viária, princípios para extração e metodologia para extração. A modelagem da malha viária é consolidada por meio de dois modelos: o intrínseco e o contextual. O primeiro está relacionado com os parâmetros que descrevem a estrada e, o segundo, com as relações existentes entre estrada e imagem de fundo.

Baseado na forma de coleta de dados, o processo de extração de estradas é dividido em dois tipos: extração usando dados coletados de sensores terrestres e extração usando dados coletados de sensores aéreos e/ou orbitais. A maioria dos autores que pesquisaram o primeiro tipo usa equipamentos acoplados em veículos.

No segundo, entretanto, referem-se aos dados adquiridos a partir de aeronaves ou satélites orbitais.

De acordo com a literatura consultada, ambos os tipos de extração de estradas podem ser subdivididos em três classes: extração usando somente imagens digitais; extração usando somente dados altimétricos; e extração usando dados altimétricos e imagens digitais integrados.

#### 2.7.1.1 Extração usando somente imagens digitais

A extração de estradas em imagens digitais ocorre por meio da análise das características geométricas, radiométricas e topológicas em diferentes resoluções espacial. Wang et al. (2005) fizeram um estudo sobre a influência da escala (resolução espacial) da imagem no processo de extração de estradas. Mostraram que a variação de escala é importante, mas melhorias adicionais são necessárias para uma extração mais acurada. Esse fato evidencia a importância da fusão de informações nos processos de automatização de tarefas, como a extração de estradas.

É fato a existência de similaridade radiométrica entre diferentes feições em imagens digitais. Dependendo da imagem, a similaridade radiométrica pode prejudicar a análise radiométrica, uma vez que feições diferentes são rotuladas como uma única feição. Outro problema existente na análise de imagem digital é a existência de obstáculos (sombra, ruídos e outros) sobrepostos à feição de interesse (SANTOS e TOMMASELLI, 2002).

Alguns autores obtiveram resultados satisfatórios analisando casos particulares, como obtenção de bordas em imagens de vídeo. Wilson e Dickson (1999) usaram um algoritmo robusto, denominado de POPPET (Position of Pivot Point Estimating Trajectory), para detectar e marcar os limites, direito e esquerdo da estrada. O algoritmo Poppet acumula *pixels* de bordas na imagem e toma uma decisão na posição do limite de estrada, baseando-se no máximo dos valores acumulados. A desvantagem desse algoritmo é o alto custo computacional.

Com o objetivo de extrair feições de interesse (estrada, poste, sarjetas e outras) em um mapeamento móvel, Silva et al. (2004) utilizaram o algoritmo de

Canny para detectar bordas das feições presentes nas cenas usadas. Esses autores avaliaram dois conjuntos de parâmetros (desvio padrão (dp) e limiares alto (la) e baixo (lb)), definidos empiricamente para o funcionamento do algoritmo de Canny. O conjunto 1, com desvio padrão igual 1,5, limiar baixo igual a 40 e limiar alto igual a 85, apresentou acurácia superior ao conjunto 2 (dp=2,0, la=90, lb=40), nas duas imagens utilizadas.

Estudos usando fotos aéreas ou imagens de satélites de baixas, médias ou altas resoluções espaciais, também apresentaram sucessos em casos particulares. Por exemplo, a utilização de técnicas, como a programação dinâmica, permite o uso de imagens de baixa ou alta resolução. Dal Poz et al. (2000) mostraram a aplicabilidade dessa técnica em imagens Spot (10 metros de resolução) e recomendam o seu uso em imagens de alta resolução.

Em Dal Poz e Silva (2002), foi explorado um delineador baseado em teste ativo e análise de bordas. Teste ativo pode ser entendido como uma estratégia usada para extrair pontos do eixo da rodovia. Essa estratégia usa uma biblioteca de modelos para referência. Uma deficiência desse método é a interrupção do processo de busca, caso não seja encontrado um objeto similar àquele da biblioteca. Entretanto, foi considerada robusta por esses autores, por permitir um tratamento de irregularidades (por exemplo: sombras e árvores) presentes nas estradas.

Usando a técnica de classificação e análise de agrupamento em imagens, QUICKBIRD, Liu et al. (2003) obtiveram resultados acurados. Esses autores usaram os algoritmos genéticos para definir os parâmetros de agrupamento e para selecionar os melhores grupos de forma automática. A desvantagem do método é que exige grande esforço computacional.

Outro método bastante utilizado na extração de estradas, principalmente em imagens de baixa resolução, é o controle simultâneo. Tendo por base alguns pontos semente, distribuídos ao longo da rodovia, esse método busca modelar simultaneamente o contorno da feição linear. Uma melhor descrição sobre o assunto pode ser visto em Oliveira (2003).

O uso de programação dinâmica em imagens de média e alta resolução apresentou maior acurácia em relação ao seu uso em imagens de baixa resolução. A função objetivo desses algoritmos é estruturada com parâmetros geométricos da rodovia. Vale (2003) apresentou resultados que mostram a eficiência do método,

usando programação dinâmica e imagens de média e alta resolução, quando comparado à aplicação em imagens de baixa resolução.

Fazendo uso do conceito de mínimos locais, uma estrada pavimentada pode ser extraída a partir dos princípios da morfologia matemática. Para tanto, considera-se que a resposta radiométrica da feição estrada (rodovia pavimentada) seja igual ou próxima de zero. A não linearidade desse processo fornece um novo enfoque na técnica de extração de estradas. O uso dessa técnica pode ser visto em Candeias e Silva (2004).

Um algoritmo de delineamento seqüencial, usando técnicas de correlação, foi aplicado por Mendes et al. (2004) na extração de estradas vicinais. No estudo, foi analisada a correlação entre perfis transversais da rodovia. Isto é, um perfil modelo é definido, a priori, e usado como referência, e a cada passo na extrapolação do eixo da rodovia, outro perfil é selecionado e comparado com o modelo por meio da técnica de correlação. Baseado nos resultados, o autor aponta o método como promissor.

A descrição de um conjunto de pesquisas realizadas sobre o tema extração de rodovias em imagens digitais é apresentada, de forma sucinta, em Dal Poz (2005).

#### 2.7.1.2 Extração usando somente dados altimétricos

Nessa linha de estudos, existem trabalhos que analisam tanto os dados de LASER terrestre quanto os dados de LASER aerotransportado. A maioria dos trabalhos encontrados na literatura usa dados de LASER terrestre, geralmente dados coletados com o LASER acoplado sobre veículos. O objetivo dos pesquisadores dessa linha é a extração das bordas (margens) das estradas.

Kirchner e Heinrich (1998) apresentam um sistema de detecção de limites de estradas usando dados LASER terrestre. O sensor é acoplado a um veículo, que, quando em movimento, mede as distâncias entre o equipamento e os objetos existentes em um plano horizontal, à frente do veículo. Esses autores usaram o filtro de Kalman no processamento do conjunto de dados coletados sucessivamente, considerando o movimento do veículo. Os limites da estrada foram detectados com

confiança, e o tempo de processamento foi reduzido quando comparado com outros métodos. O método foi indicado como promissor.

A técnica do filtro de Kalman é também aplicada em Cramer e Wanielik (2002). A idéia básica apresentada por esses pesquisadores é fundamentada na detecção e extração de bordas de estradas em áreas não cooperativas, usando dados LASER terrestre. A metodologia é baseada no uso de uma abordagem estatística para detecção de bordas e na elaboração de um algoritmo para traçar as bordas detectadas. O método é recomendado para vários cenários de estradas.

Dentro do grupo de estudos que usam dados coletados via plataforma aérea, pode ser mostrado o trabalho de Jeon et al. (2002). Os algoritmos genéticos foram usados como função objetivo do algoritmo de análise de agrupamento. Os segmentos candidatos a estradas são extraídos de uma imagem SAR (Synthetic Aperture Radar) usando o detector de estrutura curvilinear. O funcionamento desse detector baseia-se na detecção de segmentos de curva existentes em um raio predefinido. Segundo esses autores, as estradas são detectadas com acurácia, e os algoritmos genéticos melhoram o desempenho computacional.

Outros métodos de extração de estradas podem ser vistos em Hatger (2006). Informações adicionais sobre esse tema podem ser consultadas em (ALHARTHY e BETEL, 2003; CLODE et al., 2004; CLODE et al., 2007).

### 2.7.1.3 Extração usando dados altimétricos e imagens digitais

A integração de dados LASER e imagens digitais, no contexto de extração de rodovias, é um tema emergente, pouco estudado. Foram encontrados trabalhos que abordam esse assunto com um único foco: o uso de imagens de vídeo e dados LASER terrestre (TRUONG e AGASSOUNON, 2006). Outra abordagem já explorada é o uso de dados LASER com uma base cartográfica existente (HATGER e BRENNER, 2003; HATGER, 2005).

## CAPÍTULO 3 – RECURSOS UTILIZADOS

### 3.1 ÁREA DE ESTUDO

Uma fotografia aérea e uma cena IKONOS de propriedade do Laboratório de Fotogrametria e Sensoriamento Remoto, da Universidade Federal do Paraná (UFPR), foram usadas para realização dos experimentos.

A área teste localiza-se no município de Campina Grande do Sul, no Estado do Paraná/Brasil. Essa área é limitada pelas seguintes coordenadas:

$$\begin{array}{ll} \textit{Latitude} = 25^{\circ}07'40'' & \textit{Longitude} = 48^{\circ}51'24'' \\ \textit{Latitude} = 25^{\circ}08'30'' & \textit{Longitude} = 48^{\circ}52'34'' \end{array}$$

### 3.2 IMAGENS DIGITAIS

Devido aos dois fatores menor esforço computacional e alto contraste da feição estrada com sua vizinhança (pastagens, florestas e outras feições) foram usadas somente as bandas referentes à região do vermelho do espectro-eletromagnético.

A foto aérea foi reamostrada para uma resolução espacial de 0,8 metros, sendo, ainda, considerada de alta resolução. Tanto na foto quanto na cena IKONOS foram filtradas com o filtro (máscara) da mediana. O intuito dessa filtragem é a suavização de bordas que é útil na criação dos perfis transversais de estradas. Esses perfis transversais são definidos em capítulo oportuno, nesse texto.

Nos experimentos, foram usados seis recortes das cenas originais. As imagens recortadas foram escolhidas estrategicamente de forma que apresentem diferentes desafios aos algoritmos detectores de linhas. As Figuras 7, 8 e 12 mostram três recortes da foto aérea, e as Figuras 9, 10 e 11 ilustram as três imagens recortadas da cena IKONOS.

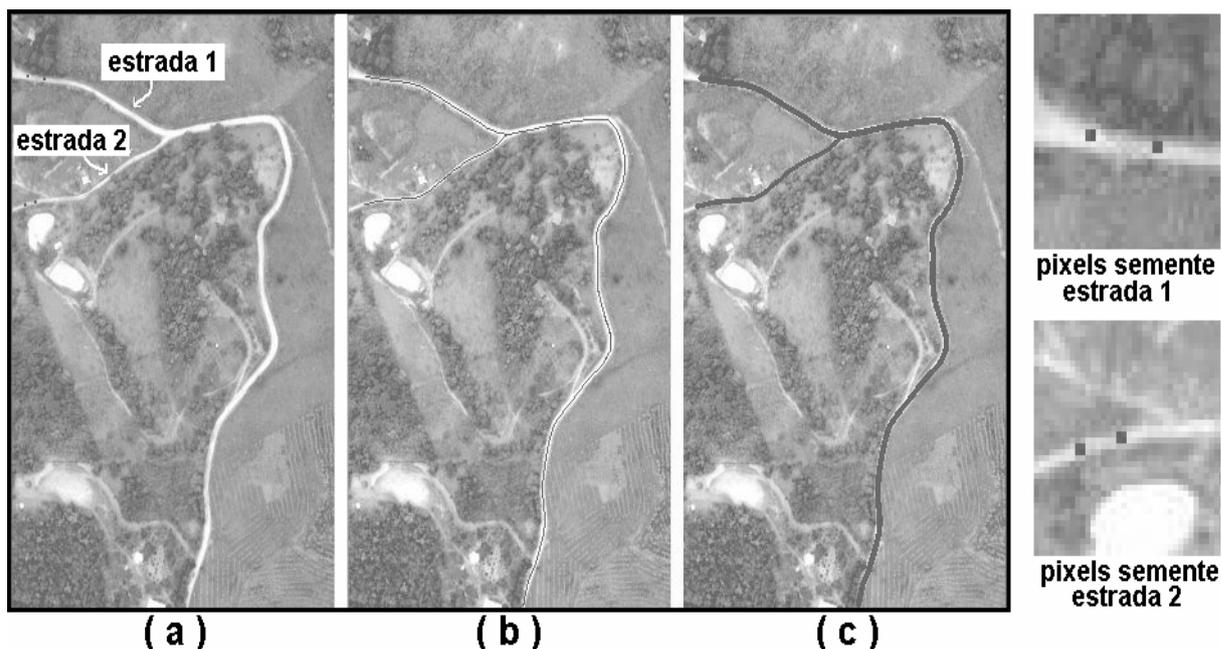


Figura 7 - IMAGEM 1 (a) Eixos de referência (b) Estradas de referência (c)

A primeira imagem (Figura 7a), denominada de IMAGEM 1, possui 800x500 (linhas x colunas) *pixels*. Essa imagem apresenta uma estrada vicinal (estrada 1) com trechos em curvas sinuosas. Na curva mais acentuada dessa estrada, existe uma bifurcação em Y, criada por uma via de acesso, localizada exatamente no ápice dessa curva. Ao logo dos eixos existem outros acessos por vias que podem confundir os algoritmos de detecção de feições lineares.

No início das estradas 1 e 2, estão representados os pontos sementes (em destaque à direita na Figura 7) que formam os segmentos semente, fornecidos pelo operador. Nas Figuras 7b e 7c, estão ilustrados os eixos e as estradas, extraídos manualmente e usados como referência. As larguras das estradas também foram extraídas por um processo manual, na IMAGEM 1.

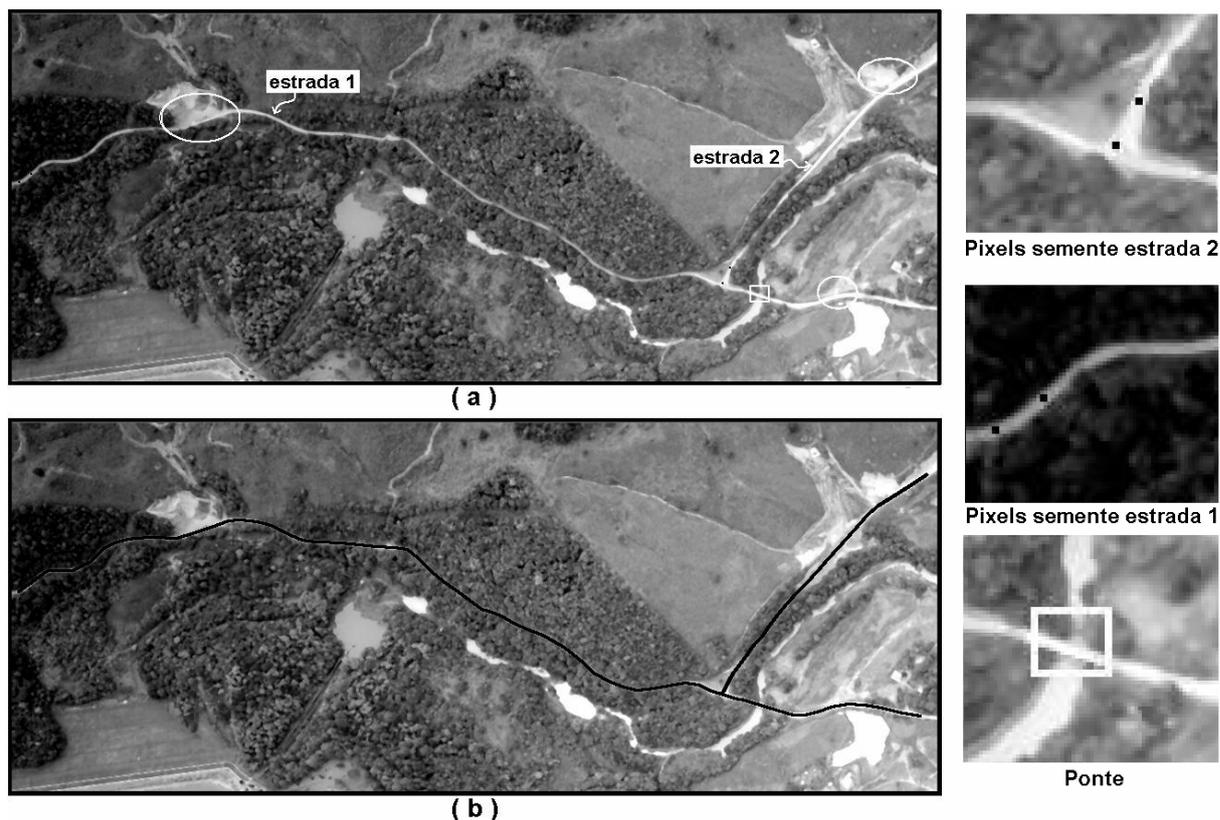


Figura 8 - IMAGEM 2 (a) Estradas de referência (b)

Apesar dos obstáculos mencionados, a IMAGEM 1 apresenta desafios menores que os existentes nas demais imagens, apresentadas a seguir. A Figura 8 mostra a imagem do tamanho 400x1000 *pixels*.

Essa imagem apresenta duas estradas vicinais com algumas peculiaridades, tais como, curvas, ponte, bifurcações e regiões com similaridade radiométrica entre a feição estrada e sua vizinhança. A Figura 8b ilustra as estradas, extraídas ou digitalizada manualmente, e usadas como referência. Como as pistas de rolamento dão uma idéia de localização dos eixos de referência, esses eixos não serão apresentados nesta e nem nas próximas imagens.

As circunferências brancas, na Figura 8a, mostram as regiões em que ocorre similaridade radiométrica. Uma ponte, localizada na parte sudeste da Figura 8, sobre a estrada 1, é destacada à direita dessa figura, no quadrado branco. Próximo à ponte, existe uma bifurcação em T entre as estradas 1 e 2 (área em destaque na Figura 8). Essas peculiaridades existentes nessa imagem, em geral, proporcionam desafios aos algoritmos de detecção de feições lineares. As localizações dos *pixels* dos segmentos semente estão em destaque na Figura 8.

A IMAGEM 3, com dimensões de 275x1100 *pixels*, é apresentada na Figura 9a. A pista de rolamento de referência da estrada de interesse é delineada na Figura 9b.

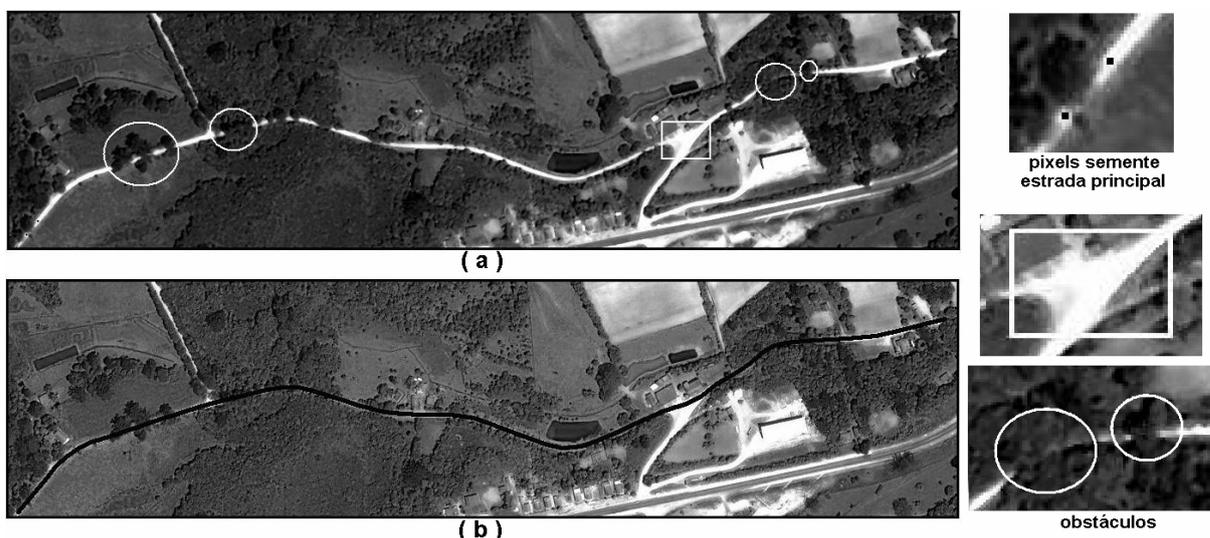


Figura 9 - IMAGEM 3 (a) Estrada de referência (b)

Além dos problemas com curvas, vias de acesso, similaridade radiométrica com outras feições, a estrada de interesse, na IMAGEM 3, possui trechos obstruídos total ou parcialmente por sombras de árvores (áreas circuladas, algumas estão em destaque à direita da Figura 9). O acesso para uma via local (área em destaque no quadrado, na Figura 9), existente na porção oeste dessa imagem, provoca um alargamento na pista de rolamento da estrada de interesse. Esses dois obstáculos são desafios para algoritmos de detecção de linhas que atuam usando apenas informações espectrais. Os pixels representantes do segmento semente também estão em destaque à direita na Figura 9.

A IMAGEM 4 (Figura 10) é usada para testar o método com abordagem automática. Essa imagem é composta por 1115x1000 *pixels*.

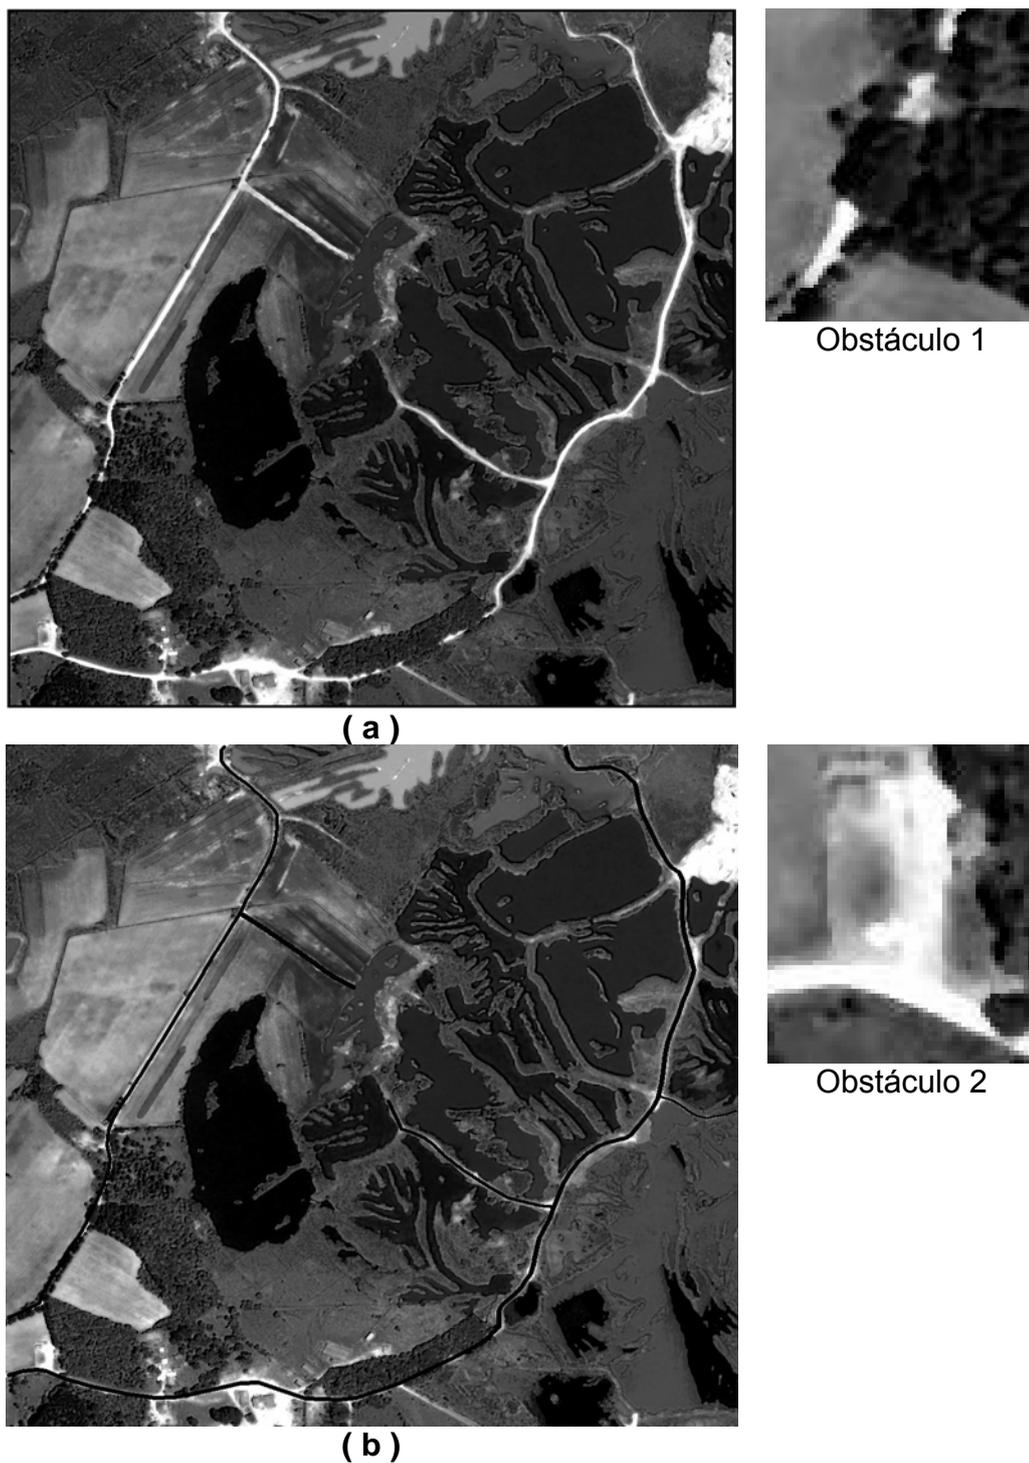


Figura 10 - IMAGEM 4 (a) Estradas de referência (b)

Existem, nessa imagem, duas estradas vicinais principais e três secundárias (ou vias de acessos). Com exceção de pontes, essa imagem possui todos os obstáculos existentes nas Imagens 1, 2 e 3, como obstruções causadas por árvores (área em destaque na Figura 10 – obstáculo 1) e similaridade radiométrica da estrada com sua vizinhança (área em destaque na Figura 10 – obstáculo 2).

A quinta imagem (IMAGEM 5) usada, com tamanho igual a 350x350 *pixels*, é ilustrada na Figura 11.

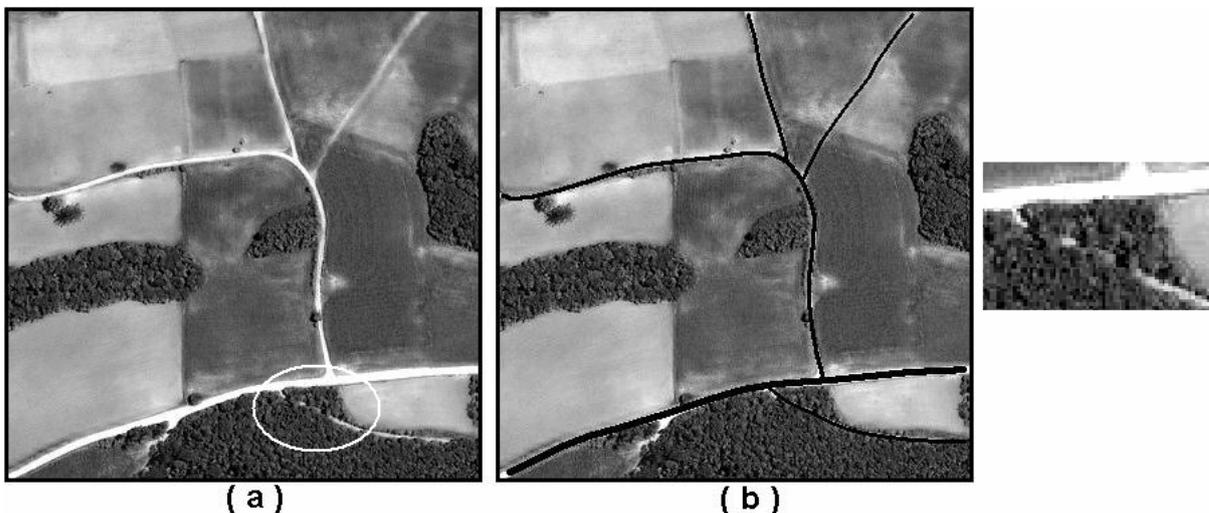


Figura 11 - IMAGEM 5 (a) Estradas de referência (b)

Essa imagem possui cinco estradas vicinais com grande variação radiométrica entre elas. A estrada localizada na parte inferior dessa imagem tem parte de sua pista de rolamento obstruída por árvores (área em destaque na Figura 11).

### 3.3 IMAGEM DIGITAL E DADO LASER

A partir de um conjunto de dado LASER, correspondente a uma porção da área coberta pela foto aérea e, cedido pelo Lactec (Laboratório de Desenvolvimento), foi gerado um MDT (Modelo Digital do Terreno). A informação contida nesse MDT foi usada com o recorte da foto aérea, correspondente à mesma área. A Figura 12 mostra o MDT e o recorte da foto aérea (IMAGEM 6) usados.

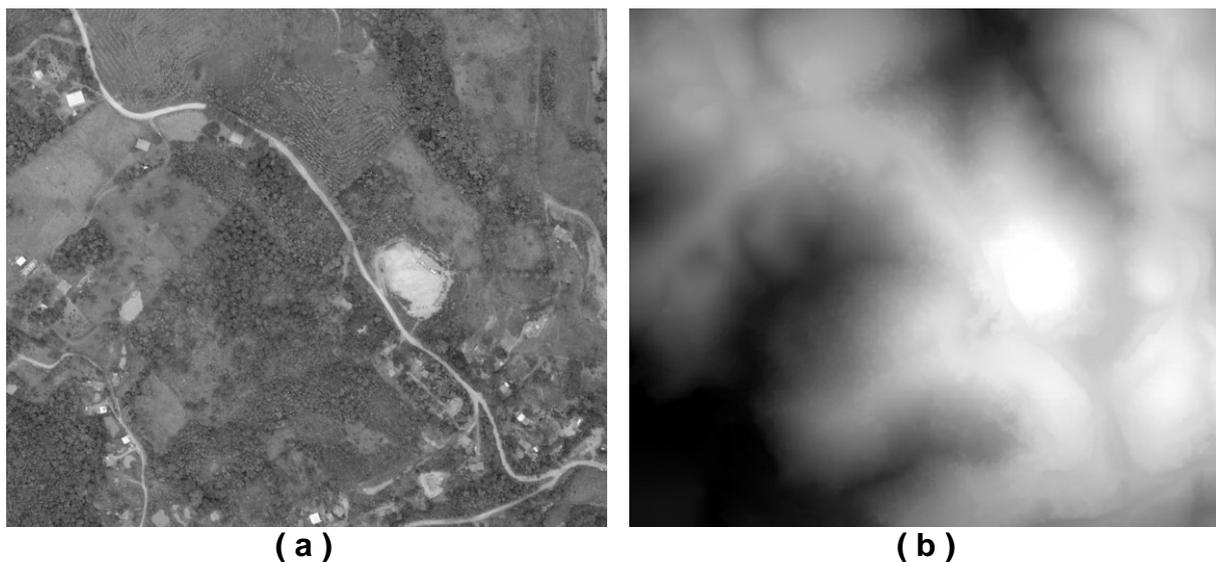


Figura 12 - IMAGEM 6 (a) Dado LASER - MDT (b)

Os dados altimétricos foram obtidos com o LASER Scanner modelo ALTM 2050, do fabricante Optech, fabricado em 2002, com frequência de 50.000,00 pulsos LASER por segundo (50Khz). Esse equipamento coleta de 1 a 4 pontos por  $m^2$  e tem precisões planimétrica e altimétrica de 50 e 15 cm, respectivamente (MARTINS et al., 2004). O MDT criado e a imagem aérea reamostrada têm resoluções espaciais de 1 metro.

### 3.4 SOFTWARES

Foram utilizados o MultispecW32 para manipulação das imagens e a plataforma MatLab R2007a para elaboração das rotinas.

## CAPÍTULO 4 – METODOLOGIA

### 4.1 DETERMINAÇÃO DE LARGURAS DE ESTRADAS VICINAIS

A característica intrínseca das estradas vicinais, de maior interesse nessa pesquisa, é a sua composição, que é de solo exposto, sem pavimentação asfáltica. Dessa forma, a análise radiométrica realizada sobre essa feição é idêntica à análise realizada sobre solo exposto.

Como foram usadas somente as bandas referentes ao vermelho do espectro eletromagnético, essa feição apresenta alto contraste em relação à vizinhança. Isto é, possui valores digitais superiores aos dos *pixels* vizinhos. A metodologia proposta se apóia nessa característica radiométrica das estradas vicinais, tanto para determinar as larguras quanto para detectar os eixos dessas estradas.

O método proposto para determinação da largura de estrada vicinal tem por base os segmentos semente. Em abordagem semi-automática de extração de estradas, os segmentos semente são fornecidos pelo operador; contudo, em abordagem automática, esses segmentos são detectados, geralmente, por processos de buscas exaustivas. Esses segmentos devem, necessariamente, representar o eixo da estrada, pois são usados como base nos processos de detecção de eixo, medida de largura e extração de pistas de rolamento de estradas. A forma de definição dos segmentos semente é descrita nas seções seguintes, em que são usados para detectar eixos de estradas vicinais.

#### 4.1.1 Definição dos perfis transversais de estradas vicinais

Para melhor compreensão do método proposto nessa seção, deve-se entender o segmento 1-2, ilustrado na Figura 13, como um segmento semente. Assim, a partir do ponto 1, com uma direção  $\theta/2$  e raios menores que a distância entre os pontos 1 e 2, são traçados 3 semi-arcs que cruzam o segmento 1-2, formando perfis transversais à estrada, conforme ilustra a Figura 13.

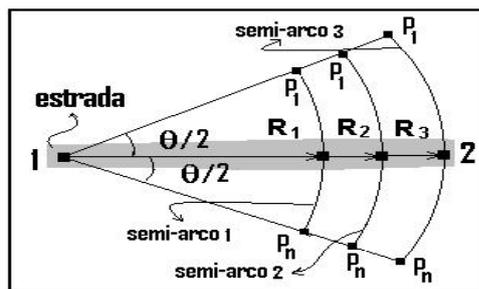


Figura 13 - Definição de largura de estradas

Os valores digitais correspondentes aos *pixels* pertencentes aos semi-arcos 1, 2 e 3 são armazenados nos três vetores distintos 1, 2 e 3, respectivamente.

#### 4.1.2 Método proposto para cálculo de larguras de estradas vicinais

Sobre cada um dos vetores (ou perfil) definidos anteriormente, é calculado o gradiente, gerando novos vetores denominados vetores gradiente. O gradiente pode ser entendido como uma coleção de vetores que apontam na direção de valores crescentes e é definido pelas derivadas parciais em relação a cada eixo. Por exemplo, o gradiente de uma função contínua de duas variáveis  $f(x, y)$  é definido como  $\nabla f = \frac{\partial f}{\partial x} \hat{i} + \frac{\partial f}{\partial y} \hat{j}$ , em que  $\frac{\partial f}{\partial x}$  é a derivada parcial na direção do eixo x e  $\frac{\partial f}{\partial y}$  é a derivada parcial na direção do eixo y. Para o caso unidimensional  $f(x)$ , ou vetor, o gradiente é calculado sobre essa única direção, isto é,  $\nabla f = \frac{\partial f}{\partial x} \hat{i}$ .

Em imagem digital (dados discretos), é comum aproximar o gradiente por meio de uma convolução de uma janela, filtro ou máscara predefinida, com a imagem original. Devido à simplicidade matemática e à fácil adequação ao problema foi usado nessa pesquisa o filtro de prewitt, com a máscara  $[-1 \ 0 \ 1]$ . A Figura 14 mostra o gráfico de um perfil transversal ou semi-arco (Figura 14a) e o gráfico do módulo do seu gradiente (Figura 14b).

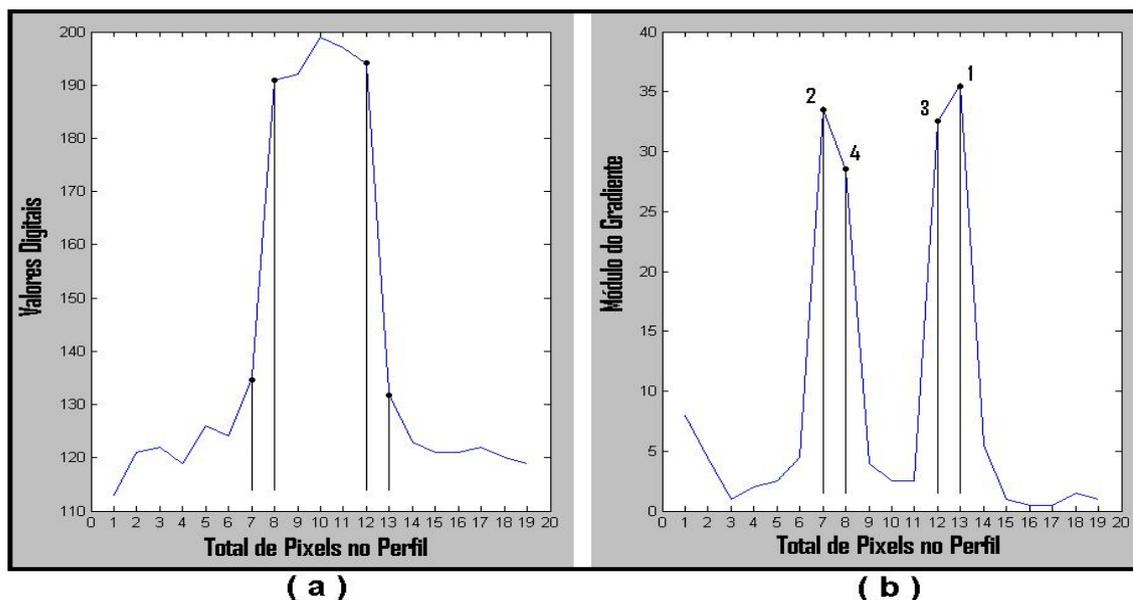


Figura 14 - Perfil transversal de estrada ( a ) Módulo do Gradiente do perfil ( b )

Definidos os vetores gradiente, dois pontos de máximo (pontos 1 e 2 na Figura 14b) são coletados, em cada um dos vetores. Para cada um dos máximos, é coletado um ponto vizinho de maior módulo (pontos 3 e 4 na Figura 14b). Nessa fase, verifica-se se a distância entre os máximos é menor ou igual a 7 metros (largura máxima de estradas vicinais, considerada nesse trabalho). A partir desses pontos, são calculadas duas distâncias: uma entre os pontos de máximo (pontos 1 e 2) e outra entre os vizinhos dos pontos de máximo (pontos 3 e 4). Ressalta-se que essas distâncias são calculadas no espaço imagem. Finalmente, a distância  $d$  é calculada pela média dessas duas medidas.

Determinadas as distâncias ( $d$ ) referentes aos três perfis transversais (semi-arcos), calcula-se a média, sendo este valor assumido como a largura ( $w$ ) da estrada. Esse procedimento é realizado sobre todos os segmentos semente fornecidos pelo operador (semi-automático) ou detectados (automático).

## 4.2 DETECÇÃO DE LINHAS USANDO ALGORITMOS ÓTIMOS (EXAUSTIVO)

Nesta seção, é apresentado o primeiro método para detectar linhas, ou eixos de estradas. Para tanto, serão usados os algoritmos ótimos ou exaustivos. No decorrer desse texto, sempre que se fizer menção ao termo “algoritmo ótimo”, entenda-o como “algoritmo exaustivo”. Esses algoritmos apresentam a vantagem de buscar o ponto ótimo, independentemente da dimensão do problema; conseqüentemente, têm a desvantagem, em problemas que envolvem muitas variáveis, com o aumento considerável do esforço computacional.

No processo de detecção de linhas (eixo da estrada), a função objetivo proposta é analisada com base em três parâmetros. O primeiro parâmetro refere-se à correlação linear entre dois perfis transversais de estrada, o segundo indica a melhor direção do segmento procurado e o terceiro mede a similaridade radiométrica entre o perfil de referência e o perfil procurado. O método de detecção de linhas proposto é iterativo, detectando um segmento candidato a estrada vicinal, em cada iteração.

A partida do processo de detecção de linhas é baseada em segmentos semente, nesse caso, fornecidos pelo operador. A participação do operador no processo classifica o método como semi-automático. Para cada estrada de interesse, o operador deve fornecer um segmento semente (ou dois *pixels* semente). Isto é, o operador fornece dois *pixels* para cada estrada vicinal que deseja extrair, sendo ambos os *pixels* pertencentes ao eixo e, preferencialmente, no início da estrada, como mostrado nas Figuras 7 e 8.

O método apresentado na seção 4.1, para medir larguras de estradas, é usado nessa seção. A descrição detalhada do método proposto para detecção de linhas retas (eixos de estradas) é apresentada nas seções seguintes.

### 4.2.1 Detecção de eixo de estradas vicinais

O algoritmo proposto para detecção de eixos de estradas, descrito a seguir, pode ser compreendido com auxílio da Figura 15.

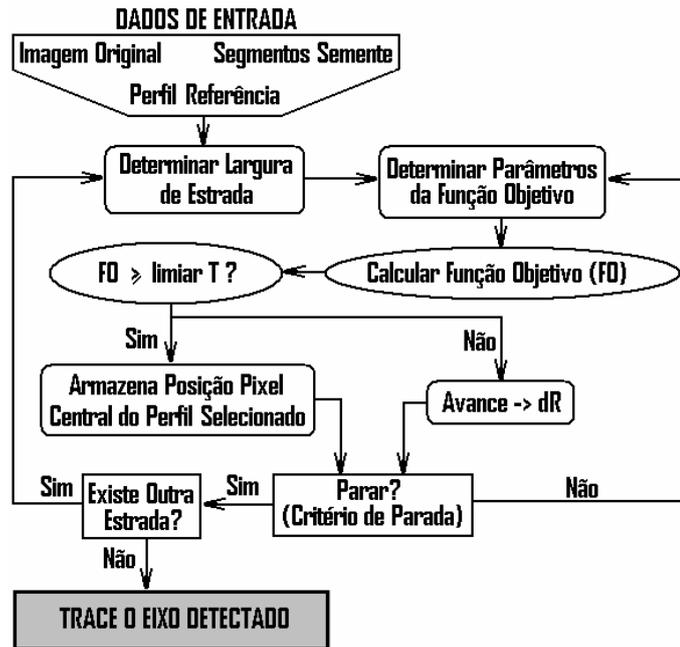


Figura 15 - Fluxograma do processo de detecção de eixos de estradas usando algoritmos ótimos

#### 4.2.2 Iniciando o algoritmo

Para iniciar o processo de detecção de eixos de estradas vicinais, é necessário o fornecimento de um segmento semente (um par de *pixels*) que represente o início da estrada de interesse. Exemplos desses segmentos podem ser vistos na Figura 16a.

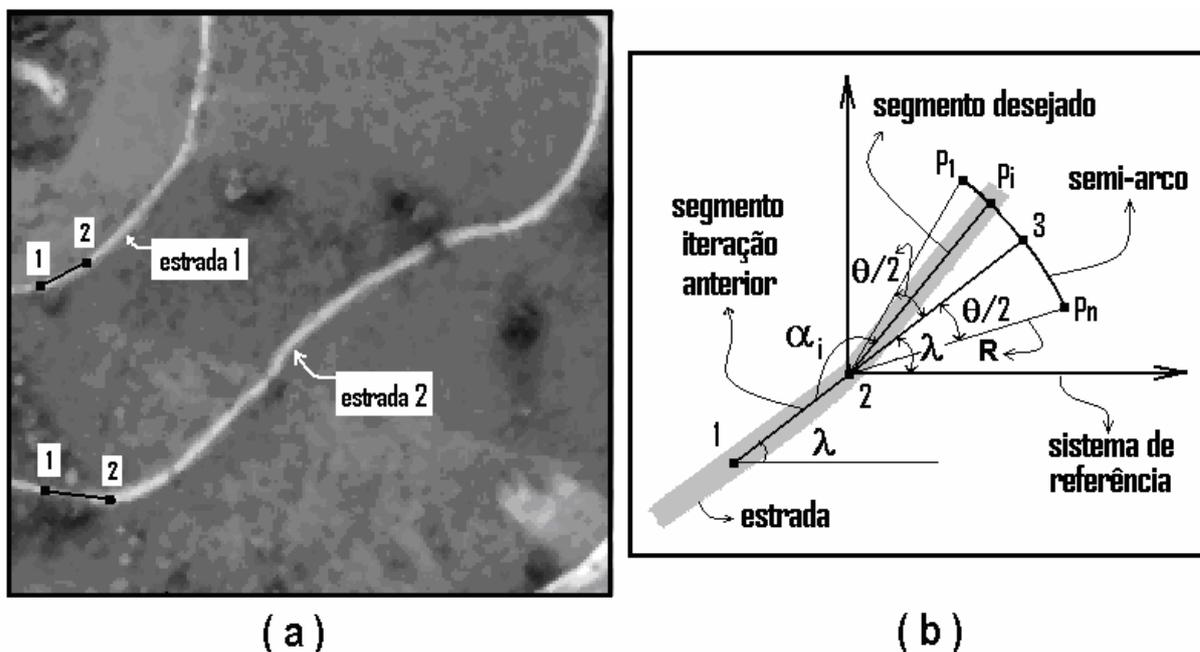


Figura 16 - Exemplos de segmentos semente (*pixels* 1 e 2) (a) espaço de busca (b)

O ângulo de inclinação ( $\lambda$ ) da reta que une os pontos 1 e 2, é usado para localizar um terceiro ponto (*pixel* 3 mostrado na Figura 16b), pertencente a esta mesma reta e afastado do ponto 2 de uma distância ou raio  $R$ . Ressalta-se que a direção horizontal do sistema de referência coincide com as linhas da imagem, conseqüentemente, o eixo das ordenadas coincide com as colunas.

Identificado o ponto 3, o passo seguinte é delinear um semi-arco ( $\overrightarrow{SA}$ ) com as seguintes características: raio  $R$ , ponto médio coincidindo com o ponto 3 e origem (centro) no ponto 2. Esse semi-arco ( $\overrightarrow{SA}$ ) delimita a região ou área de busca do próximo ponto ou vértice ( $P_i$ ), tendo como limites os *pixels*  $P_1$  e  $P_n$ , em que  $n$  representa o total de *pixels* necessários para representar SA. Os valores digitais dos  $n$  *pixels* (pontos) existentes no semi-arco  $\overrightarrow{SA}$ , correspondente à área de busca, são armazenados em um vetor denominado  $\overrightarrow{AB}$ .

O ângulo de direção  $\theta$  é fornecido pelo operador. O valor máximo para esse ângulo deve ser  $180^\circ$ , a fim de evitar um retorno sobre o segmento anterior. Por exemplo, se  $\theta = 360^\circ$ , o segmento 1-2, mostrado na Figura 16b, pode ser detectado na iteração seguinte, impedindo o avanço na direção de interesse da estrada. Todavia,  $\theta$  não pode ser muito pequeno, pois, em curvas muito sinuosas, é preciso

uma área de busca maior para que o semi-arco se sobreponha ao eixo da estrada ou o cruze.

A partir dos ângulos  $\theta$  e  $\lambda$ , todas as posições  $P_i$  do semi-arco, inclusive as extremas,  $P_1$  e  $P_n$ , são determinadas usando a equação 2.

$$\begin{cases} x_i = x_2 + R \cos(\delta) \\ y_i = y_2 + R \sin(\delta) \end{cases} \quad (2)$$

em que  $1 \leq i \leq n$ ,  $\lambda - \theta \leq \delta \leq \lambda + \theta$ ,  $R$  é o raio e  $(x_2, y_2)$  são as coordenadas do ponto 2. Ressalta-se que em cada iteração o ponto 2 é movido para a nova posição detectada  $(x_i, y_i)$ .

Para os valores de  $R$  e  $\theta$ , apesar de definidos empiricamente, é razoável considerar  $\theta \leq 180^\circ$ , como discutido anteriormente, e  $R < 33$  pixels (considerando a resolução espacial das imagens usadas  $R$  é de aproximadamente 20 metros). Em estradas vicinais, objeto deste estudo, é comum a ocorrência de mudanças bruscas (curvas agudas) no seu eixo, assim, quanto menor o valor de  $R$ , menor a possibilidade de erro.

#### 4.2.3 Cálculo das larguras das estradas

Tanto a construção do perfil de referência quanto o processo de detecção de segmentos propostos fazem uso das larguras  $w$  das estradas vicinais. Assim, toda metodologia exposta na seção 4.1 é aplicada nessa seção. As larguras são medidas em cada segmento semente fornecido e usadas na detecção da respectiva estrada.

#### 4.2.4 Construção do perfil de referência

Um perfil transversal de referência bem representativo pode ser construído com base nas propriedades radiométricas, intrínsecas às estradas vicinais, que apresentam altos valores digitais no seu leito (ou pista de rolamento) e, alto contraste, em relação às feições vizinhas.

O perfil transversal de referência proposto, além de considerar essa característica radiométrica, faz uso das larguras ( $w$ ) das estradas vicinais, previamente calculadas. Assim, o perfil criado apresenta as seguintes características:

- é unidimensional e armazenado na forma de vetor ( $\vec{vr}$ );
- possui tamanho maior que a largura ( $w$ ) da estrada para possibilitar a análise da variação radiométrica entre o leito e as margens; e
- a parte central do perfil (vetor  $\vec{vr}$ ) deve conter valores maiores que as margens, correspondendo à característica intrínseca das estradas vicinais.

Com base nessas premissas, o tamanho adotado para o perfil ( $\vec{vr}$ ) é de  $3w$  pixels. Esse grupo de pixels é armazenado em  $\vec{vr}$ , de modo que os primeiros  $w$  pixels (parte 1) tenham baixos valores digitais, representando uma das margens da estrada; os próximos  $w$  pixels (parte 2) do vetor possuem maiores valores digitais, representando a pista de rolamento da estrada; e, finalmente, os  $w$  pixels restantes (parte 3), também possuem baixos valores digitais, representando a outra margem da estrada. Portanto, na parte 2 de  $\vec{vr}$ , todas as células recebem valores iguais a 1 (um) e nas partes 1 e 3 de  $\vec{vr}$  são atribuídos valores iguais a zero, como ilustra a Figura 17d. O perfil de referência simulado na Figura 17d considera a largura ( $w$ ) da estrada com 6 pixels.

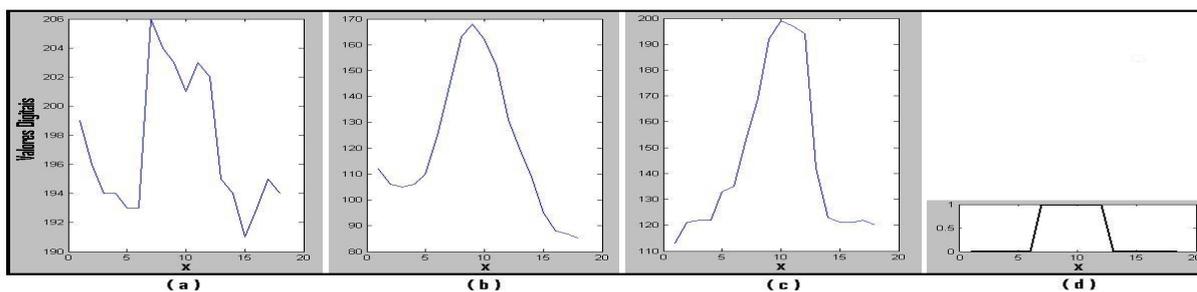


Figura 17 - Perfis retirados de imagem real (a, b, c) e perfil de referência (d)

As Figuras 17a, 17b e 17c ilustram perfis transversais retirados, manualmente, de uma imagem real.

#### 4.2.5 Localização do perfil transversal pertencente à estrada

A localização do perfil transversal, que apresenta maior correlação com o perfil de referência, é feita por meio de busca exaustiva sobre os valores digitais armazenados no vetor  $\overrightarrow{AB}$  (semi-arco  $\overrightarrow{SA}$ ). Essa localização é feita por meio de uma varredura do perfil de referência sobre o vetor  $\overrightarrow{AB}$ . Por esse motivo, o vetor  $(\overrightarrow{AB})$ , definido na seção 4.2.2, é propositalmente maior que o perfil de referência  $(\overrightarrow{vr})$ . Dessa forma, a cada iteração, uma porção do vetor  $\overrightarrow{AB}$ , com mesmo tamanho de  $\overrightarrow{vr}$ , é retirada e comparada com o perfil de referência. Essa porção é denominada de vetor selecionado, ou vetor  $\overrightarrow{vs}$ . Em cada iteração, o vetor  $\overrightarrow{vs}$  é retirado de  $\overrightarrow{AB}$  variando de um *pixel*, como mostra a Figura 18.

Valores Digitais																															
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
<b>AB =</b>		118	114	120	117	114	120	136	154	150	150	141	158	<b>204</b>	<b>203</b>	<b>201</b>	<b>199</b>	<b>198</b>	122	120	115	111	108	107	103	103	101	104	104	108	109
Iterações	1	0	0	0	0	0	0	<b>1</b>	<b>1</b>	<b>1</b>	<b>1</b>	<b>1</b>	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
	2	0	0	0	0	0	0	0	<b>1</b>	<b>1</b>	<b>1</b>	<b>1</b>	<b>1</b>	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
	3	0	0	0	0	0	0	0	0	<b>1</b>	<b>1</b>	<b>1</b>	<b>1</b>	<b>1</b>	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	

Figura 18 - Seleção de perfis para fins de comparação

O exemplo hipotético da Figura 18 mostra um vetor  $\overrightarrow{AB}$  com 30 *pixels*, em que os valores digitais correspondentes à pista de rolamento da estrada estão em negrito. Assim, sendo a largura da estrada  $w$  igual a 5 *pixels*, no primeiro passo, o vetor  $\overrightarrow{vs}$  recebe os valores digitais dos 15 primeiros *pixels* ( $3w$ ) do vetor  $\overrightarrow{AB}$ ; no segundo passo,  $\overrightarrow{vs}$  recebe os *pixels* de 2 a 16; e no terceiro, são usados os *pixels* de 3 a 17. Esse procedimento é repetido até que todos os valores digitais do vetor  $\overrightarrow{AB}$  sejam comparados, por meio da função objetivo, com o perfil de referência.

A função objetivo usada para medir a similaridade entre os perfis selecionados e de referência é composta por três parâmetros, apresentados nas seções seguintes.

#### 4.2.6 Determinação dos parâmetros da função objetivo/aptidão

A função objetivo foi elaborada com base em três parâmetros intrínsecos de estradas vicinais. O primeiro (a) está relacionado com a correlação linear entre o perfil transversal detectado e o perfil de referência; o segundo (b) descreve a delimitação da região de busca de novos segmentos; e o terceiro (c) refere-se à similaridade radiométrica entre os perfis, selecionado e de referência.

##### 4.2.6.1. Correlação linear entre perfis transversais de estradas

Uma forma de quantificar a força de associação linear entre duas variáveis é calculando o coeficiente de correlação. Um coeficiente muito usado é o coeficiente de correlação de Pearson ( $r$ ). Esse coeficiente descreve quão bem uma linha reta se ajusta por meio de uma nuvem de pontos em que  $r = 1$  indica que todos os pontos se encontram exatamente sobre uma reta ajustada crescente; e  $r = -1$  indica que todos os pontos estão localizados exatamente sobre uma reta ajustada decrescente. A ausência de correlação entre as duas variáveis implica um valor nulo para o coeficiente ( $r = 0$ ).

O objetivo nessa fase é analisar o quão correlacionados, positivamente, são dois perfis transversais. Assim, a correlação linear entre dois perfis transversais pode ser medida pelo coeficiente de correlação de Pearson. Quanto mais próximo de 1 (um) for o valor de  $r$ , maior é a probabilidade de o perfil analisado ser um perfil transversal de estrada vicinal. Esse coeficiente é definido pela equação 3.

$$r = \frac{\sum_i (vdr_i - \overline{vdr})(vds_i - \overline{vds})}{\sqrt{\sum_i (vdr_i - \overline{vdr})^2 \sum_i (vds_i - \overline{vds})^2}} \quad (3)$$

em que  $vdr_1, vdr_2, \dots, vdr_{3w}$  são os valores digitais do perfil de referência ( $\overline{vr}$ );  $vds_1, vds_2, \dots, vds_n$  são os valores digitais pertencentes ao perfil selecionado ( $\overline{vs}$ );  $\overline{vdr}$  é o valor médio de  $\overline{vr}$ ;  $\overline{vds}$  é o valor médio de  $\overline{vs}$ ; e  $i = 1, \dots, 3w$ .

Os coeficientes de correlação  $r$  dos perfis ilustrados nas Figuras 17a, 17b e 17c e do perfil de referência (Figura 17d) são 0,92, 0,88 e 0,92, respectivamente. Esses valores, superiores a 88%, indicam a potencialidade do perfil de referência proposto na localização dos perfis transversais de estrada vicinal.

Neste contexto, o parâmetro relacionado com a correlação entre perfis transversais ( $p\_C$ ) é medido de acordo com a equação 4.

$$p\_C = \begin{cases} r & \text{se } 0 \leq r \leq 1 \\ 0 & \text{se } -1 \leq r < 0 \end{cases} \quad (4)$$

#### 4.2.6.2. Delimitação da região de busca de novos segmentos

O espaço ou região de busca do novo segmento é computado com base no ângulo entre o segmento anterior e o segmento selecionado. No primeiro passo, ou primeiro laço de alimentação, o segmento anterior é o segmento semente. O ângulo entre dois vetores é determinado pela equação 5.

$$\cos(\alpha_i) = \frac{\vec{K}_i \times \vec{L}_i}{\|\vec{K}_i\| \|\vec{L}_i\|} \Rightarrow \alpha = a \cos\left(\frac{\vec{K}_i \times \vec{L}_i}{\|\vec{K}_i\| \|\vec{L}_i\|}\right) \quad (5)$$

em que  $\vec{K}_i$  e  $\vec{L}_i$  são os vetores correspondentes ao segmento anterior e ao segmento selecionado, respectivamente.

Ambos os segmentos possuem tamanhos iguais ao raio  $R$ , exceto o vetor  $\vec{K}_1$  no primeiro passo, que, não necessariamente, tem tamanho igual ao raio. O objetivo desse parâmetro é forçar a busca do novo segmento sempre à frente (a vante), evitando o retorno sobre segmentos já detectados. Observando a Figura 16b, percebe-se que o ângulo  $\alpha$  é limitado pelo ângulo  $\theta$ , isto é,  $\alpha$  pode assumir somente valores no intervalo  $\left(180^\circ - \frac{\theta}{2}\right) \leq \alpha \leq 180^\circ$ . Se  $\alpha$  é igual a  $180^\circ$ , a contribuição desse parâmetro, com a função objetivo, é máxima, igual a 1 ou 100%.

A equação 6 mostra como é calculado o parâmetro relacionado com a direção dos segmentos.

$$p_{-D} = \begin{cases} |\cos(\alpha)| & \text{se } \left(180^\circ - \frac{\theta}{2}\right) \leq \alpha \leq 180^\circ \\ 0 & \text{caso contrário} \end{cases} \quad (6)$$

#### 4.2.6.3. Similaridade radiométrica entre perfis transversais

O terceiro parâmetro, relacionado com a similaridade radiométrica entre perfis, é definido com base na propriedade radiométrica da estrada vicinal. Isto é, a estrada vicinal possui maior valor digital em relação à vizinhança. Esse parâmetro é determinado de acordo com a equação 7.

$$p_{-S} = e^{\left(\frac{-Dm(vd,vs)}{5}\right)} \quad (7)$$

em que  $e$  é a função exponencial;  $Dm$  é a distância de *Mahalanobis* medida de um determinado valor digital ( $vd$ ), que necessariamente pertence à estrada, aos valores digitais pertencentes ao perfil transversal selecionado ( $\overline{vs}$ ). A distância de *Mahalanobis* é uma medida que avalia a similaridade entre duas feições. Detalhes sobre essa medida podem ser vistos em Richards e Jia (1998).

A magnitude de  $vd$  é determinada a partir dos valores digitais dos *pixels* extremos dos segmentos semente, do valor digital máximo da imagem e do valor digital máximo de  $\overline{vs}$ . Como descrito em parágrafos anteriores, as estradas vicinais possuem altos valores digitais, por isso são usados os valores máximos da imagem e do perfil selecionado ( $\overline{vs}$ ), na definição de  $vd$ . Enfim, o valor de  $vd$  é computado como o valor médio desse conjunto de valores digitais apresentados.

De acordo com a equação 7, quanto menor a distância de *Mahalanobis*, maior é a contribuição desse parâmetro com a função objetivo. Se essa distância é nula (zero), a contribuição é máxima, igual 1 ou 100%.

Finalmente, a função objetivo (FO) é definida pela equação 8, integrando a informação contida nos três parâmetros definidos acima.

$$FO = ap\_C + bp\_D + cp\_S \quad (8)$$

em que a, b e c são as ponderações atribuídas para cada parâmetro, e  $a + b + c = 1$ .

#### 4.2.7 Critérios de parada do processo de detecção

O critério de parada utilizado é baseado em um limiar mínimo (T) para a função objetivo. Para cada segmento selecionado, a medida da função objetivo (FO) é calculada, armazenada e comparada com esse limiar; se  $FO \geq T$ , o *pixel* central do perfil  $\vec{vs}$ , em análise, é escolhido como pertencente ao eixo da estrada. A posição do *pixel* escolhido (no espaço imagem) é armazenada e a busca por outro novo *pixel* recomeça. Contudo, se  $FO < T$ , um incremento de  $dR$  é feito no raio R e, com o novo raio (R+dR), recomeça um novo laço é executado. Persistindo a condição ( $FO < T$ ), após R ser incrementado por um determinado número de vezes, o processo de busca é encerrado.

Adicionalmente aos critérios de parada, internos à função objetivo, estão dois outros critérios, relacionados com parâmetros externos, que são o fim da imagem (linha e/ou coluna) e o cruzamento com outro eixo já detectado. Ocorrendo um desses critérios, é feita a seguinte pergunta: existe outro segmento semente representante de outra estrada que ainda não foi detectada? Se existe outro segmento semente, calcula-se a largura dessa nova estrada, cria-se um novo perfil de referência, iniciando o processo de busca do seu eixo; se não existe outro segmento semente, os eixos detectados devem ser traçados.

### 4.3 DETECÇÃO DE LINHAS USANDO ALGORITMOS GENÉTICOS

São usados, nessa seção, os algoritmos genéticos para avaliar a função objetivo ou de aptidão proposta. Esse método também é semi-automático, mas os algoritmos usados são subótimos. O objetivo é a obtenção de um conjunto de segmentos lineares que correspondam aos eixos de estradas vicinais. A metodologia proposta é aplicada sobre imagens digitais e faz uso do método de determinação de larguras de estradas, apresentado na seção 4.1.

Os mesmos parâmetros usados na função objetivo da equação 8 são empregados na função de aptidão elaborada para os algoritmos genéticos. Isto é, são usados três parâmetros: um referente à correlação linear entre dois perfis transversais de estrada; outro que indica a melhor direção do segmento procurado; e um terceiro que mede a similaridade radiométrica entre o perfil de referência e o perfil selecionado. O método de detecção de linhas proposto também é seqüencial, detectando um segmento candidato a estrada vicinal a cada passo (laço de alimentação).

Os algoritmos genéticos simples (AGs) são rotinas que simulam as teorias da Evolução das Espécies e da Genética. Desse grupo de algoritmos, um é usado para selecionar os melhores indivíduos (técnicas de seleção), outro para estimular a evolução das espécies (cruzamento e mutação) e um terceiro para ponderar cada indivíduo de acordo com sua capacidade de resolver o problema (aptidão). Em cada iteração do processo de detecção de segmentos, os AGs são acionados para selecionar o melhor segmento candidato à estrada vicinal. Detalhes sobre os algoritmos genéticos podem ser vistos em Silva (2006).

A partida do processo de detecção de linhas é baseada no segmento semente fornecido pelo operador. Portanto, o método é semi-automático. Novamente, para cada estrada de interesse, o operador deve fornecer um segmento semente. A descrição detalhada do método proposto é apresentada nas seções seguintes.

#### 4.3.1 Detecção de eixo de estradas vicinais

A Figura 19 mostra as fases do método proposto nessa seção, desde o dado de entrada (imagem original) até o eixo detectado.

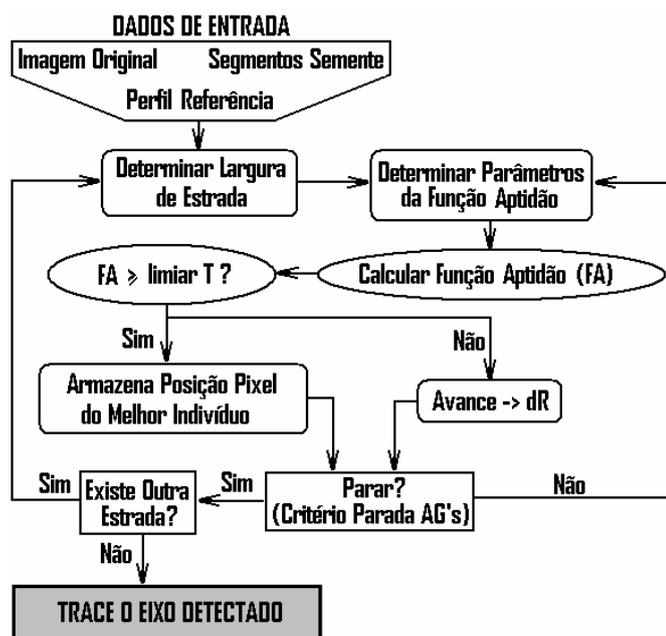


Figura 19 - Fluxograma do processo de detecção de eixos de estradas usando algoritmos genéticos

De modo semelhante ao primeiro método proposto para detectar segmentos de reta (eixo de estrada vicinal), o método usando algoritmos genéticos exige o fornecimento de segmentos semente (um par de *pixels*) e a determinação das larguras das estradas vicinais de interesse. Dessa forma, o método proposto para determinar larguras de estradas também é aplicado nessa seção. Outros dois parâmetros, já definidos, também são usados nessa seção, são o perfil transversal de referência ( $\overline{vr}$ ) e o valor digital  $vd$ , correspondente a uma estrada.

#### 4.3.2 Adaptação dos algoritmos genéticos

Um modelo conceitual de trechos de estrada vicinal foi proposto baseado em pares de segmentos contíguos. No modelo, uma estrada vicinal é descrita como

uma coleção de segmentos contíguos que, combinados, definem o eixo dessa estrada. As informações contidas nesse modelo, com base nos três parâmetros mencionados, são introduzidas na função aptidão dos algoritmos genéticos.

Nas seções seguintes, são apresentados os componentes dos algoritmos genéticos, tais como, o espaço de busca de novos segmentos, a codificação dos indivíduos, a definição da população inicial, a técnica de seleção e os operadores genéticos, todos já adaptados ao problema em questão.

#### 4.3.2.1. Espaço de busca

O espaço de busca de um novo segmento, candidato a estrada vicinal, é definido por uma circunferência de raio  $R$ , como mostra a Figura 20.

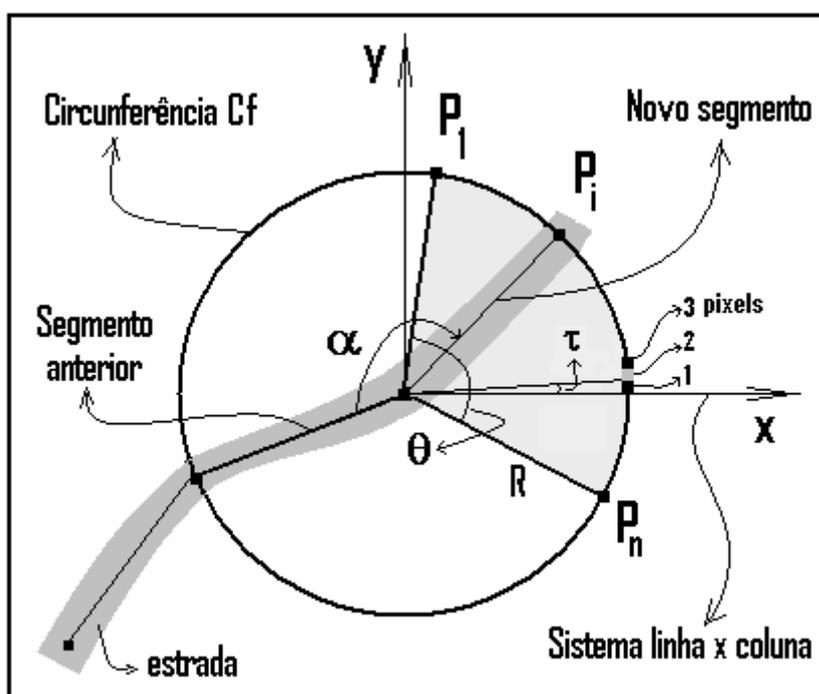


Figura 20 - Espaço de busca

O espaço de busca é formado pelo conjunto de *pixels* pertencentes à circunferência  $C_f$ . Todos os *pixels* são armazenados em um vetor denominado  $\vec{vC}$ . A quantidade ( $Q$ ) de *pixels* presentes nessa circunferência (no vetor  $\vec{vC}$ ) é definida em função de  $R$ , como mostram as equações 9 e 10. A equação 9 determina o

número de *bits* necessários para representar a quantidade  $Q$  e, a equação 10 é usada para calcular o módulo de  $Q$ . O modelo matemático proposto na equação 9 pode ser entendido com o auxílio da Figura 20.

$$bits = \frac{\log\left(\frac{2\pi}{\text{atan}\left(\frac{1}{R}\right)}\right)}{\log(2)} \quad (9)$$

$$Q = 2^{bits} \quad (10)$$

Vale ressaltar que o valor de *bits* é arredondando para o primeiro inteiro à frente. Por exemplo, se  $bits = 7,4$ , esse valor é arredondado para 8,0. O arredondamento para mais é feito com o intuito de não deixar espaços vazios (ausência de *pixel*) na circunferência, pois quanto maior o valor de *bits*, maior é a magnitude de  $Q$ .

Ressalta-se que os eixos  $x$  e  $y$  coincidem, respectivamente, com as linhas e colunas da imagem e que os ângulos  $\alpha$  e  $\theta$  são os mesmos definidos na seção 4.2.

#### 4.3.2.2. Codificação dos indivíduos e definição da população inicial

Os *pixels* da circunferência  $C_f$  podem ser representados por uma seqüência de números variando de um 1 até  $Q$ . Por definição, o número 1 representa o *pixel* que se encontra sobre o eixo das abscissas, no sentido positivo (Figura 20); o *pixel* número 2 encontra-se acima do *pixel* 1, no sentido anti-horário; o *pixel* 3 está localizado sobre o *pixel* 2, no sentido anti-horário; assim, todos os demais *pixels* da circunferência  $C_f$  podem ser localizados, seguindo a ordem numérica e o sentido anti-horário.

Como os *pixels* de  $C_f$  são representados por números inteiros, compreendidos entre 1 e  $Q$ , cada *pixel* pode ser representado na forma binária, ou seja, como cadeias ou vetores binários, contendo zeros 0s e 1s. Nesse estudo, cada cadeia binária representa um indivíduo. Assim, os indivíduos têm tamanhos iguais

ao tamanho das cadeias binárias, ou seja, possuem tamanho igual ao número de *bits* necessários para representar os *pixels* de Cf.

Seja, por exemplo,  $bits = 8$  e os *pixels* 7 e 12, selecionados aleatoriamente na circunferência Cf, os correspondentes indivíduos, codificados na forma de cadeias binárias ilustrados na Figura 21. Na linguagem genética, essa cadeia é um *cromossomo*, os valores 0s e 1s, contidos nas células, são denominados *genes* e as células são os *loci*.

<b>Indivíduo referente ao pixel 7 =</b>	0	0	0	0	0	1	1	1
<b>Indivíduo referente ao pixel 12 =</b>	0	0	0	0	1	1	0	0

Figura 21 - Exemplo de indivíduo codificado

Todos os *pixels* pertencentes ao espaço de busca são investigados como possíveis candidatos à estrada, independentemente da sua posição na circunferência Cf. O *pixel*  $P_i$ , na Figura 20, é o *pixel* desejado, pelo fato de se encontrar na região central da estrada.

A posição de um *pixel*  $P_i$ , em coordenadas de imagem (linha x coluna), na circunferência Cf, é determinada pela equação 11.

$$\begin{cases} x_i = x_c + R \cos(\tau P_i) \\ y_i = y_c + R \sen(\tau P_i) \end{cases} \quad (11)$$

em que  $x_i$  é a coluna do *pixel*  $P_i$ ;  $y_i$ , a linha do *pixel*  $P_i$ ;  $x_c$  a coluna do *pixel* localizado no centro da circunferência Cf;  $y_c$  é a linha do *pixel* localizado no centro da circunferência Cf;  $R$  é o raio da circunferência;  $P_i$  é o *pixel* analisado; e  $\tau$  (Figura 20) é o incremento máximo de um ângulo necessário para determinar a posição de um *pixel* na circunferência. O ângulo  $\tau$  é obtido usando a equação 12.

$$\tau = \frac{2\pi}{Q} \quad (12)$$

Após definição do indivíduo, a população inicial é criada por um grupo desses indivíduos, criados aleatoriamente. O tamanho da população é definido pelo usuário. Por exemplo, se o tamanho da população é de 30 indivíduos, são criadas 30 cadeias binárias, aleatoriamente, para representar a população inicial.

#### 4.3.2.3. Técnica de seleção e operadores genéticos

Como discutido em seções anteriores, são várias as técnicas de seleção. Contudo, a técnica de seleção usada nesse trabalho é o elitismo. Essa técnica de seleção apresenta vantagens por ser matematicamente simples e computacionalmente econômica. A seleção por elitismo pode ser processada da seguinte forma:

- a) organizar, em ordem decrescente, os valores de aptidão de todos os indivíduos que compõem a população;
- b) escolher um grupo G, a partir do vetor de aptidão, correspondente a 75% do tamanho da população ( $T_{pop}$ ), e esse grupo G deve conter os maiores valores (elite) de aptidão;
- c) escolher um subgrupo SG com os  $n$  primeiros valores do grupo G. O valor de  $n$  é, geralmente, igual a  $\frac{T_{pop}}{4}$  (25% da população); e
- d) extrair da população velha os indivíduos correspondentes ao SG, inserindo-os na nova população.

O complemento da nova população pode ser realizado usando os indivíduos restantes ( $G - SG$ ) ou todos os indivíduos do grupo G.

Por exemplo, seja uma população de 100 indivíduos, um grupo G com os 75 melhores indivíduos é selecionado. Do grupo G, os 25 melhores (subgrupo elite (SG)) são mantidos na nova população. Para complementar a nova população, são realizadas iterações em que, em cada iteração, um par de indivíduos (denominados de pais 1 e 2) é selecionado e submetido aos operadores de cruzamento e mutação. A prole (filhos 1 e 2) resultante desses operadores é inserida na nova população. Esse último processo é repetido até que os 75 indivíduos necessários para completar a nova população sejam selecionados e armazenados. Esse último

processo de seleção, usado para complementar a população, é a técnica por torneio.

Foram utilizados, nesse estudo, os operadores genéticos simples: mutação e cruzamento, com um único ponto de corte. Esses operadores têm por função estimular a evolução da espécie. O cruzamento atua de forma que dois ou mais cromossomos pais troquem material genético entre si, gerando suas proles (filhos). A mutação atua alterando o código genético. Isto é, um ou mais genes, escolhido aleatoriamente, são modificados no cromossomo pai, gerando um filho mutante. O objetivo da mutação é estimular a evolução com a geração de novos indivíduos modificados geneticamente.

A escolha dos cromossomos para a aplicação desses operadores é realizada de forma aleatória. A Figura 22 mostra o funcionamento desses operadores.

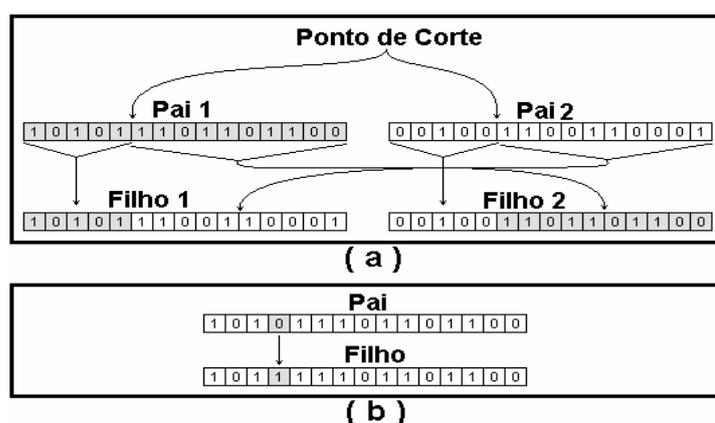


Figura 22 - Operador de cruzamento (a) e de mutação (b)  
Fonte: Adaptado de Silva, 2006.

O cruzamento simples baseia-se na escolha aleatória de um único ponto de corte (posição localizada entre dois *loci* quaisquer). A partir desse ponto de corte, é executada a troca de material genético entre os dois pais selecionados, como mostra a Figura 22a. Para a aplicação da mutação, é selecionado um *locus* e a informação genética contida nesse *locus* é alterada, como ilustra a Figura 22b.

Antes da aplicação dos operadores genéticos é avaliada a condição de ocorrência, ou não ocorrência, do cruzamento e mutação. Para tanto, dois valores aleatórios entre 0 e 1 são gerados e comparados com as probabilidades de mutação e cruzamento, definidas a priori. Assim, se os valores aleatórios forem maiores ou iguais aos respectivos valores de probabilidades, os operadores são aplicados. Caso

contrário, os indivíduos pais são repassados para a nova população sem alterações genéticas.

#### 4.3.2.4. Função de aptidão proposta

O potencial de cada indivíduo na solução do problema é calculado de acordo com a função de aptidão. Portanto, essa função deve conter parâmetros que descrevam o problema. No método proposto, a função de aptidão é desenvolvida compreendendo os três parâmetros supracitados.

O primeiro parâmetro informa à função de aptidão o quão correlacionado está o perfil selecionado aleatoriamente, em cada iteração, com o perfil de referência. O segundo expressa a direção do segmento selecionado aleatoriamente, em cada iteração, em relação ao segmento detectado no passo anterior. Por fim, o terceiro parâmetro indica a similaridade radiométrica entre o perfil de referência e o perfil transversal selecionado em cada iteração.

Para compreender o funcionamento desses parâmetros, é necessário conhecer os perfis transversais. O perfil de referência é o mesmo  $\vec{v}_r$  usado na seção 4.2. O perfil selecionado  $\vec{v}_s$  é obtido por processo similar, mas não idêntico ao  $v_s$  já apresentado. A forma de configuração desse perfil é apresentada a seguir.

É sabido, de discussões anteriores, que todo indivíduo corresponde a uma única posição na circunferência  $C_f$ ; assim, todo indivíduo selecionado define uma posição  $P_i$ , no vetor  $\vec{v}_C$ . A partir dessa posição  $P_i$ , um vetor  $\vec{v}_s$  é criado usando informações do vetor  $\vec{v}_C$ . O vetor  $v_s$  tem tamanho igual a  $3w$  e posição central coincidente com  $P_i$ , no vetor  $\vec{v}_C$ . Dois exemplos hipotéticos (a) e (b) do vetor  $\vec{v}_s$  são ilustrados na Figura 23.

		Valores Digitais																																
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	
<b>vc =</b>		118	114	120	117	114	120	136	154	150	150	141	158	204	203	201	199	198	122	120	115	111	108	107	103	103	101	104	104	108	109	101	104	
<b>(a)</b>		118	114	120	117	114	120	136	154	150	150	141	158	204	203	201																		
<b>(b)</b>									154	150	150	141	158	204	203	201	199	198	122	120	115	111	108											

Figura 23 - Exemplos de perfil transversal selecionado

Por exemplo, dado que a circunferência  $C_f$ , ou vetor  $\vec{vC}$ , contenha 32 valores digitais, que a largura  $w$  seja igual a 5 *pixels* e que o indivíduo selecionado represente o *pixel* 8, assim, o vetor  $\vec{vs}$  correspondente é o vetor composto pelos valores digitais mostrados em (a), na Figura 23. Sejam agora os mesmos  $\vec{vC}$  e  $w$ , porém, o indivíduo refere-se ao *pixel* 15, o novo  $\vec{vs}$  é aquele mostrado em (b), na Figura 23. Portanto, para todo indivíduo diferente é gerado um vetor  $\vec{vs}$  diferente. Para uma população com 20 indivíduos, são selecionados, em cada iteração, 20 vetores  $\vec{vs}$  e submetidos à análise de aptidão, por meio dos três parâmetros intrínsecos à função de aptidão.

A diferença do processo de seleção desse vetor  $\vec{vs}$  em relação ao mesmo vetor  $\vec{vs}$ , apresentado na seção 4.2, é que a posição  $P_i$ , além de selecionada aleatoriamente, pode assumir qualquer valor ou posição, em todo vetor  $\vec{vC}$ .

Finalmente, a função de aptidão ( $FA$ ) é definida pela equação 13, integrando a informação contida nos três parâmetros descritos pelas equações 4, 6 e 7.

$$FA = ap\_C + bp\_D + cp\_S \quad (13)$$

em que  $a$ ,  $b$  e  $c$  são constantes e  $a + b + c = 1$ .

#### 4.3.3 Critérios de parada do processo de detecção

São dois os critérios de parada utilizados: um limiar mínimo ( $T$ ) para a função objetivo e um número máximo de gerações ( $ng$ ). Para cada segmento selecionado, a medida da função objetivo ( $FO$ ) é calculada, armazenada e comparada com o limiar  $T$ ; se  $FO < T$  e o número de gerações (evolução) atual é menor que  $ng$ , uma nova geração recomeça, produzindo nova população e, automaticamente, nova busca. Contudo, se a condição  $FO \geq T$  é verdadeira, o *pixel* central do perfil  $\vec{vs}$ , em análise, é escolhido como pertencente ao eixo da estrada. A posição do *pixel* escolhido (no espaço imagem) é armazenada e a busca por outro

novo *pixel* recomeça. Por outro lado, se o número máximo de gerações é atingido e  $FO < T$ , um incremento de  $dR$  é alocado no raio  $R$  e, com o novo raio  $(R+dR)$ , é reiniciado o processo de evolução (busca). Persistindo a condição  $FO < T$ , após  $R$  ser incrementado por um determinado número de vezes, o processo de busca é encerrado.

Os critérios de parada externos, usados na seção 4.2, são também utilizados com os algoritmos genéticos.

#### 4.4 DETECÇÃO DE LINHAS USANDO TRANSFORMADA RADON

O que classifica um método como automático ou semi-automático é a existência ou não de interação do operador com o processo. Se existe a interação, o método é semi-automático, caso contrário, é automático. Os dois métodos de detecção de eixos propostos nas seções 4.2 e 4.3 são semi-automáticos, pois os segmentos semente são fornecidos pelo operador. Contudo, na presente seção, é proposto um método para detecção de segmentos semente, automaticamente.

O método proposto para detectar segmentos semente é fundamentado na transformada Radon. Esse método é iterativo e atua localmente, ou seja, em cada iteração é realizada uma busca local por segmentos sementes.

De posse dos segmentos sementes, o processo de detecção de eixos é iniciado. Esse processo é realizado similarmente aos métodos já apresentados. Portanto, são usados o método de medição de larguras de estradas e o método para detectar linhas retas. A metodologia é testada usando as Imagens 1, 2, 3, 4 e 5, exibidas nas Figuras de 7 a 11, respectivamente. Para validação do método, são usados os índices completeza, correção e RMSEixo. A descrição do método proposto é apresentada nas seções seguintes.

##### 4.4.1 Detecção de segmentos lineares

O algoritmo proposto para detectar eixos de estradas vicinais, automaticamente, pode ser compreendido com ajuda da Figura 24.

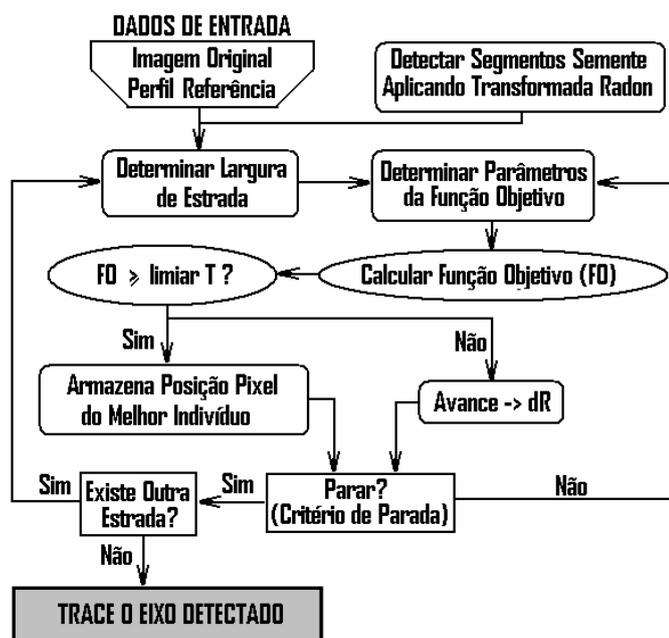


Figura 24 - Fluxograma do processo de detecção de eixos de estradas usando abordagem automática

#### 4.4.1.1. Detecção de segmentos sementes usando a transformada Radon

O primeiro passo do processo de detecção de eixos de estradas vicinais é a obtenção dos segmentos semente (um par de *pixels*) que representem as estradas. Partindo dessa premissa, um método para detecção de segmentos semente, usando a transformada Radon, é proposto. A transformada Radon é aplicada em subimagens, com o intuito de detectar feições lineares localmente. As subimagens são geradas a partir de uma partição da imagem original. Os procedimentos para essa partição ou subdivisão e o método proposto para cálculo das coordenadas dos segmentos detectados são apresentados a seguir. No método proposto, uma única feição linear é detectada em cada subimagem.

##### a) Subdivisão da imagem original

O tamanho de cada subimagem é função do parâmetro  $T_j$  (tamanho da janela), fornecido pelo operador. A magnitude de  $T_j$  depende da largura (aproximada) das estradas existentes na imagem original, isto é, deve ser superior à

maior largura de estrada existente. A Figura 25a mostra um exemplo hipotético de subdivisão de uma imagem, em que cada quadrado representa uma subimagem.

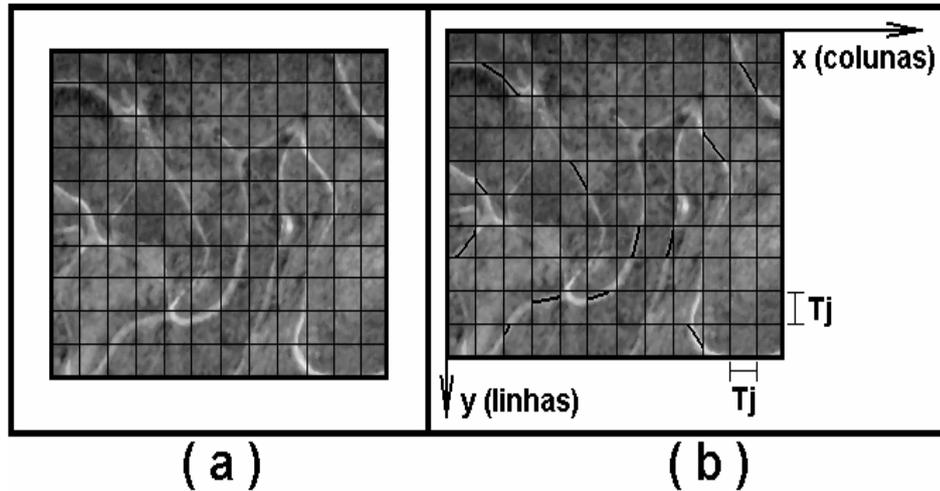


Figura 25 - Exemplos de imagem subdividida (a) e possíveis segmentos semente (b)

A quantidade de subimagens ( $Q_{SI}$ ) formadas a partir da divisão da imagem original é obtida pela equação 14.

$$Q_{SI} = QL \cdot QC \quad (14)$$

em que  $QL = \left\lfloor \frac{Nlin}{Tj} \right\rfloor$ ,  $QC = \left\lfloor \frac{Ncol}{Tj} \right\rfloor$ ,  $Nlin$  é o número de linhas da imagem original e  $Ncol$  é o número de colunas da imagem original. As frações  $QL$  e  $QC$  são arredondadas para baixo, gerando números inteiros, de forma que  $QL \cdot Tj \leq Nlin$  e  $QC \cdot Tj \leq Ncol$ .

Realizada a subdivisão da imagem original, a transformada Radon é aplicada a cada subimagem, a fim de detectar os segmentos semente. Exemplos de segmentos semente são mostrados na Figura 25b.

#### b) Posicionamento dos segmentos detectados na imagem

Como discutido na seção 2.6, os resultados da transformada Radon são pares de parâmetros representados por uma direção ( $\theta$ ), no sentido anti-horário, e a

uma distância (*dst*) correspondente ao afastamento entre a feição linear e o centro da imagem, ou origem do eixo  $x'$ . Todavia, o que se busca são as coordenadas, ou linhas e colunas, dos *pixels* que representam os extremos da feição linear (segmentos semente), por exemplo, os *pixels*  $P_k$  e  $P_i$  na Figura 26. Assim, é proposto um modelo matemático que converte os parâmetros fornecidos pela transformada Radon em coordenadas linhas e colunas. Esse modelo pode ser compreendido com auxílio da Figura 26 e é descrito pela equação 15.

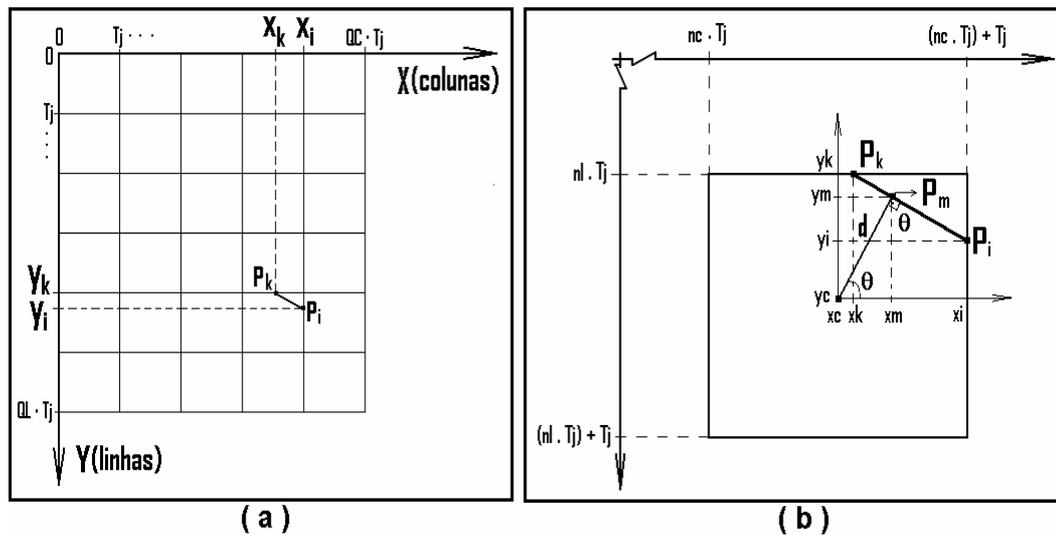


Figura 26 - Coordenadas de segmentos semente no espaço imagem

$$\begin{cases} y_i = (y_c + d \sin(\theta)) + \frac{(x_i - x_c - d \cos(\theta))}{\tan(\theta)} \\ y_k = (y_c + d \sin(\theta)) - \frac{(x_c + d \cos(\theta) - x_k)}{\tan(\theta)} \end{cases} \quad (15)$$

em que  $nl$  é a quantidade de subimagens existentes entre a origem da imagem completa e o ponto analisado, na direção das linhas; e  $nc$  é a quantidade de subimagens existentes entre a origem da imagem completa (original) e o ponto analisado, na direção das colunas;  $y_c$  e  $x_c$  são as coordenadas (linha x coluna) do

*pixel* central da subimagem, em que  $y_c = (nl \cdot T_j) + \left(\frac{T_j}{2}\right)$ ,  $x_c = (nc \cdot T_j) + \left(\frac{T_j}{2}\right)$ ; e o valor

de  $\frac{T_j}{2}$  é arredondado para o número inteiro à frente.

O processo para obtenção das coordenadas  $(x_i, y_i)$  e  $(x_k, y_k)$  é iterativo, ou seja, as abscissas  $x_i$  e  $x_k$  receberão valores inteiros compreendidos entre  $(nc \cdot Tj)$  e  $(nc \cdot Tj) + Tj$ , até que sejam encontrados os valores máximos para as ordenadas  $y_i$  e  $y_k$ , compreendidos entre  $(nl \cdot Tj)$  e  $(nl \cdot Tj) + Tj$ . Os pares ordenados  $(x_i, y_i)$  e  $(x_k, y_k)$ , para os quais  $y_i$  e  $y_k$  sejam máximos, são adotados como coordenadas dos pontos extremos  $P_i$  e  $P_k$ , respectivamente.

Para os casos especiais de  $\theta = 0^0$  e  $\theta = 180^0$ , o modelo matemático apresentado na equação 15 não se adapta. Portanto, nestes casos, é usado o modelo apresentado na equação 16.

$$\left\{ \begin{array}{l} x_i = x_k = da \\ y_i = y_c + \frac{Tj}{2} \quad e \quad y_k = y_c - \frac{Tj}{2} \quad se \quad \theta = 0^0 \\ y_i = y_c - \frac{Tj}{2} \quad e \quad y_k = y_c + \frac{Tj}{2} \quad se \quad \theta = 180^0 \end{array} \right. \quad (16)$$

Determinado o posicionamento dos segmentos detectados pela técnica da transformada Radon, inicia-se o método de análise da qualidade desses segmentos, como segmentos semente.

### c) Seleção dos melhores segmentos semente

O uso da transformada Radon na detecção de linhas largas, apresenta dois fatores inconvenientes. O primeiro é que essa transformada tende a detectar linhas que representam as diagonais das linhas largas, pois as diagonais possuem o maior valor de soma de intensidades, como mostra a Figura 27a (imagem negativa). O segundo é que em linhas largas verticais ou horizontais, que coincidem com os limites da janela  $Tj$ , são detectadas duas linhas representando a mesma feição linear, uma em cada subimagem (Figura 27b).

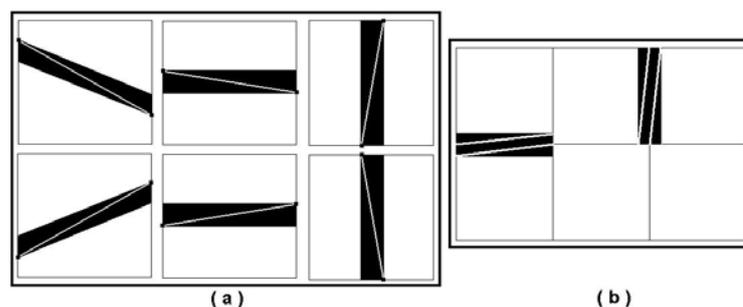


Figura 27 - Problemas decorrentes do uso da transformada Radon na detecção de linhas largas

Zhang (2006) propõe uma solução para o problema ilustrado na Figura 27a, usando apenas parâmetros intrínsecos à transformada Radon. Esse autor não analisa apenas o máximo pico formado na imagem Radon, mas toda a região formada na vizinhança desse pico. No presente estudo, a solução proposta para esse problema é dada com o auxílio de dois parâmetros relacionados com a estrada vicinal, ambos já definidos em seções anteriores. O primeiro parâmetro é pertinente à correlação linear entre os perfis transversais e o segundo refere-se a uma medida de similaridade radiométrica entre um valor digital  $vd$ , supostamente pertencente à estrada, e o perfil transversal selecionado ( $\vec{vs}$ ). O segundo problema é solucionado com a eliminação dos segmentos que possuem extremos próximos entre si.

Para determinar esses parâmetros, dois pares de perfis transversais (semi-arcos) são criados, como ilustra a Figura 28. O tamanho desses semi-arcos é função do ângulo  $\theta$ , fornecido pelo operador. Ambos os pares de semi-arcos (semi-arcos 1, 2 e semi-arcos 3, 4) estão na mesma direção, mas em sentidos opostos. Os dois semi-arcos extremos (1 e 3) possuem raios ( $R_1$ ) iguais ao comprimento dos segmentos detectados por meio da transformada Radon, entretanto, os outros dois possuem raios menores ( $R_2$ ). A diferença de tamanho entre os raios deve ser pequena, pois podem existir segmentos curtos entre aqueles selecionados pela técnica da transformada Radon, e isso ocasiona a criação de semi-arcos com pequenos raios e, conseqüentemente, não extrapolam ou nem mesmo se sobrepõem a toda a pista de rolamento da estrada. A não cobertura da pista de rolamento impossibilita a aplicação do método proposto. Para evitar esse problema, segmentos com tamanho menor ou igual a  $\frac{T_j}{2}$  são descartados.

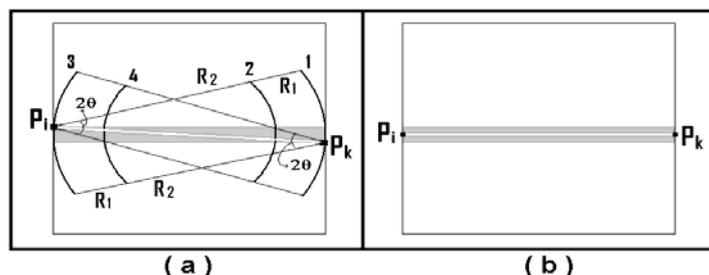


Figura 28 - Seleção de segmentos candidatos a semente

Para que o segmento ilustrado na Figura 28a ( $P_i$  e  $P_k$ ) assuma a posição do segmento mostrado na Figura 28b, uma função objetivo é criada englobando os dois parâmetros supracitados.

A medida do parâmetro referente à correlação linear entre perfis transversais é similar à medida usada nas seções 4.2 e 4.3, em que é criado um perfil transversal de referência ( $\vec{vr}$ ) que é correlacionado com os perfis  $vs$ , retirados dos semi-arcos, a cada iteração. Na presente seção 4.4, os perfis  $\vec{vs}$  são gerados a partir dos quatro semi-arcos apresentados na Figura 28. O perfil de referência é o mesmo definido na seção 4.2, composto de valores nulos (zero) nas extremidades e, 1s (um) na parte central do perfil.

Dependendo do tamanho de  $T_j$ , outras feições podem ser detectadas como segmentos de retas. Por exemplo, se  $T_j$  é grande, edificações que tenham o formato alongado podem ser detectadas como feições lineares. Especificamente, nesses casos, o processo de cálculo da largura de estrada é encarregado de eliminar tais segmentos. Para tanto, é assumido que a largura máxima de estradas vicinais não exceda 7 metros (aproximadamente 9 *pixels* em imagens com resolução espacial de 0,8 metros), e a largura mínima não seja inferior a 2 metros. O método proposto para determinar larguras de estradas vicinais também é aplicado nessa seção.

O parâmetro de correlação entre perfis ( $p_C$ ) e o parâmetro referente à medida de similaridade ( $p_S$ ) são medidos pelas equações 4 e 7, respectivamente. Determinados os valores de  $p_C$  e  $p_S$ , a função objetivo é calculada com base na equação 17.

$$FO = aP_C + bP_S \quad (17)$$

em que  $a$  e  $b$  são constantes e  $a + b = 1$ .

Duas condições são impostas para definir se um segmento é apto a ser semente ou se deve ser descartado. O primeiro critério é que  $p_C \geq T1$  e o segundo é que  $FO \geq T2$ . Dessa forma, todos os segmentos detectados usando a transformada Radon são submetidos a esses dois critérios. O segmento que atender a ambos os critérios é selecionado e armazenado como segmento semente. Finalizada a escolha dos segmentos semente, os processos de cálculo das larguras das estradas e de detecção de novos segmentos são iniciados. Esses procedimentos são apresentados nas seções seguintes.

#### 4.4.1.2. Determinação de larguras de estradas vicinais

As larguras das estradas são determinadas usando o método proposto nesse trabalho. Os segmentos semente, usados como base de cálculo de larguras, são aqueles selecionados pela aplicação da transformada Radon. Para cada segmento são determinadas quatro larguras (uma em cada semi-arco) e a média desse conjunto é assumida como a largura da estrada que contém tal segmento semente. Por outro lado, se existirem  $n$  segmentos semente em uma mesma estrada, são calculadas  $n$  larguras que podem ser usadas na detecção do eixo. Essa flexibilidade do método permite que variações na largura de uma estrada sejam percebidas e mensuradas.

#### 4.4.1.3. Seleção de novos segmentos e critérios de parada

Tanto o processo de busca por novos segmentos quanto os critérios de parada são similares àqueles usados nos algoritmos ótimos (seção 4.2).

A busca por novos segmentos é realizada por meio dos algoritmos ótimos. O processo de busca é exaustivo e, a cada passo (laço de alimentação), um novo segmento é detectado. Os novos segmentos, em relação aos segmentos anteriores, são consecutivos e colineares ou consecutivos e com pequenos ângulos de deflexão.

A função objetivo usada na seleção de novos segmentos é a função proposta na equação 8. Assim, são usados os três parâmetros já definidos com informações intrínsecas às estradas vicinais.

A cada passo, a medida da função objetivo de um determinado perfil  $\vec{v}_s$  é processada e armazenada. Após o último passo, o maior valor de aptidão (FA) é comparado com o limiar T. Se  $FO \geq T$ , o *pixel* central do perfil  $\vec{v}_s$ , correspondente ao referido valor FA, é selecionado e armazenado e a busca por um novo segmento recomeça. Caso contrário, se  $FO < T$ , um avanço de dR é incrementado ao raio R ( $R+dR$ ), o processo de busca é reiniciado usando o novo raio. Porém, se com o novo raio, FO é ainda menor que T, o incremento dR é somado ao novo raio. Esse processo é repetido até a n-ésima vez. Persistindo a ocorrência ( $FO < T$ ), o processo de detecção do eixo atual é encerrado.

Adicionalmente, é verificado se ainda existem outros segmentos semente que não tenham sido usados. Se existe outro segmento semente, todo o processo de detecção é repetido. Caso contrário, o processo de detecção é encerrado e os eixos detectados são delineados (traçados) gerando uma imagem com os eixos das estradas vicinais.

#### 4.5 CONTRIBUIÇÃO DA INTEGRAÇÃO DE DADOS ALTIMÉTRICOS

Por se tratar de uma tecnologia emergente, os dados LASER ainda são uma opção onerosa. Por outro lado, esses dados vêm despontando com sucesso em diversas áreas, tais como na Geologia e nas Ciências Geodésicas.

A aplicação dos dados LASER, isoladamente, no processo de detecção de rodovias/estradas em área rural, embora seja um assunto novo, não é inédito. Entretanto, ainda é um assunto carente de pesquisas, tendo em vista o pequeno número de trabalhos realizados sobre o tema. O processo de integração de dados, sejam dados LASER com imagens digitais (ou fotos aéreas digitais), ou mesmo imagens digitais com outras de resoluções e/ou fontes distintas, também não é um assunto inédito, contudo, com a freqüente inovação tecnológica, esse tema mantém-se sempre atual, necessitando cada vez mais de estudos, apontando a aplicabilidade de novos dados.

Nas seções anteriores foram usadas somente imagens digitais em todos os experimentos realizados. Na atual seção, pretende-se analisar a importância, ou contribuição, dos dados LASER no processo de detecção de feições lineares, mais precisamente, eixos de estradas vicinais. Ressalta-se que, devido à disponibilidade limitada de dados LASER, em áreas que possuam estradas vicinais, o estudo limitou-se a um único experimento.

Diante dos resultados dos experimentos anteriores, usando apenas imagens digitais, observou-se que a similaridade radiométrica e/ou a obstrução total de trechos das pistas das estradas, por exemplo, por árvores ou sombras de árvores, são obstáculos difíceis de serem superados. Portanto, espera-se que a integração da informação do dado LASER com a imagem digital contribua na solução desse problema, especialmente no problema de cobertura por árvores, analisado no experimento proposto.

#### 4.5.1 Método proposto para integração dos dados

A informação do dado LASER foi inserida na função objetivo (equação 8) proposta na seção 4.2. A opção por essa função deve-se ao fato de ser uma abordagem automática, portanto, de maior importância frente aos outros métodos semi-automáticos discutidos no presente texto.

Uma forma lógica de avaliar pontos homólogos dos dados LASER e imagem digital, simultaneamente, é colocando ambos no mesmo sistema de referência. O dado LASER, por natureza, é georreferenciado, portanto, a imagem digital usada foi corrigida geometricamente, usando pontos de controle retirados dos dados LASER (imagens de intensidade e hipsometria). O RMS da correção geométrica apresentou magnitude *subpixel*, isto é, menor que um *pixel*.

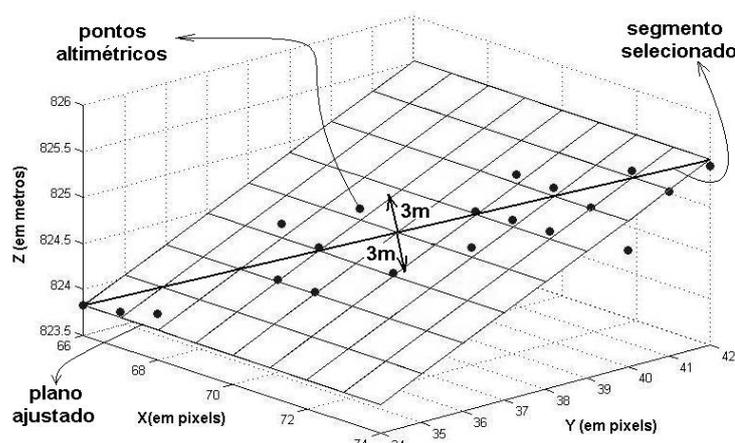
Após a preparação dos dados (imagem e dado LASER), iniciou-se a modificação da função objetivo apresentada na equação 8. Isto é, a nova função objetivo proposta é acrescida de uma parcela contendo informação do dado LASER. Essa nova parcela é definida levando em consideração a característica intrínseca de estradas existentes no dado LASER, ou seja, a superfície de pequenos trechos da pista de rolamento de uma estrada é, por definição, planar. Assim, para cada segmento selecionado, são analisados quatro parâmetros na função objetivo e não somente três como nos métodos anteriores.

No algoritmo usado, em cada iteração, um novo segmento é selecionado e submetido a uma análise de pertinência ao grupo de segmentos representantes dos eixos de estradas vicinais. Tal análise é realizada por meio da função objetivo. Dessa forma, a cada iteração é verificada se a superfície (janela) em torno do segmento selecionado está de acordo com a característica intrínseca das estradas; isto é, se é uma área planar ou não. Essa verificação é realizada levando em consideração conceitos de RMS, equação geral do plano, distância de um ponto ao plano e ajustamento de um plano ao conjunto de pontos em análise.

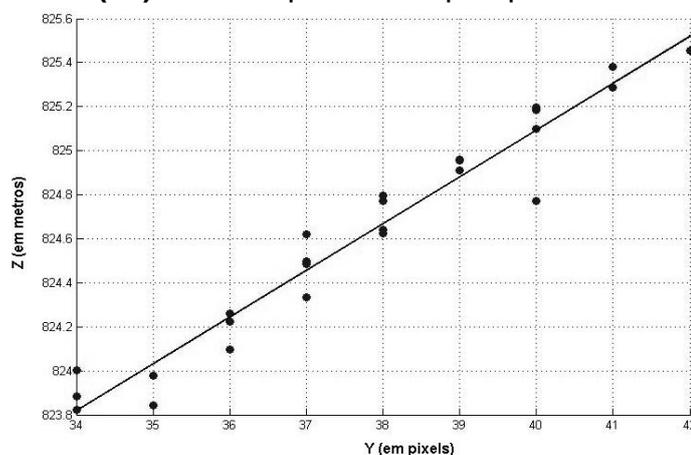
A largura da janela (superfície) analisada em torno do segmento selecionado pode ser definida pelo usuário, mas levando em consideração a correlação existente entre essa medida e o tipo de estrada que se pretende extrair. Por exemplo, para estradas estreitas deve ser considerada uma largura igual ou próxima da largura da estrada; por outro lado, para estradas mais largas, esta largura não precisa,

necessariamente, ser da largura da estrada. Isto é, larguras menores podem ser usadas na detecção de estradas mais largas. Frente a essa premissa, foi utilizada uma largura fixa de três metros (três *pixels*). Portanto, para cada segmento selecionado, são extraídos os pontos altimétricos vizinhos de ambos os lados, direito e esquerdo, desse segmento.

De posse dos pontos altimétricos, o passo seguinte é o ajustamento, por mínimos quadrados, de um plano sobre esses pontos, como mostra a Figura 29.



( a ) Vista do plano com perspectiva



( b ) Vista da face linear do plano

Figura 29 - Plano ajustado sobre os pontos altimétricos

O método aplicado no ajustamento foi o paramétrico linear. O modelo funcional  $La = F(Xa)$  usado é a equação geral do plano (equação 18), em que as altitudes ( $z_i$ ) são as observações e os coeficientes ( $A$ ,  $B$  e  $D$ ) são os parâmetros. As coordenadas  $x$  e  $y$  são as abscissas e ordenadas, respectivamente, de cada ponto altimétrico.

$$Ax + By + Cz_i + D = 0 \Rightarrow z_i = D + Ax + By, \quad \text{onde } C = 1 \quad (18)$$

Informações adicionais sobre ajustamento de observações podem ser encontradas em Mikhail (1976), Gemael (1994) e Dalmolin (2004).

Determinado o plano ajustado, as distâncias  $dt_i$  (perpendiculares), medidas a partir de todos os pontos altimétricos até plano em questão, são calculadas por meio da equação 19 (VENTURI, 1991).

$$dt_i = \frac{|Ax_i + By_i + Cz_i + D|}{\sqrt{A^2 + B^2 + C^2}} \quad (19)$$

O erro quadrático médio (RMS - *Root Mean Square*) é processado a partir dessas distâncias. Ressalta-se que essas distâncias são consideradas erros, embora não sejam, necessariamente, erros.

Finalmente, a parcela de contribuição dos dados LASER ( $p_L$ ), à função objetivo, é dada pelo modelo proposto na equação 20.

$$p_L = e^{(-RMS)} \quad (20)$$

A nova função objetivo proposta é, portanto, definida pela equação 21, em que  $a + b + c + f = 1$  e o ponto ótimo é 1.

$$FO = ap_C + bp_D + cp_S + fp_L \quad (21)$$

#### 4.6 EXTRAÇÃO DE PISTAS DE ROLAMENTO DE ESTRADAS VICINAIS

O objetivo nesta seção é a extração de pistas de rolamento das estradas vicinais para realização da análise visual do produto (imagem vetorizada) gerado. Essa tarefa é executada a partir dos eixos e das larguras detectados pelos métodos propostos nesse estudo. Portanto, detectados os eixos e as larguras das estradas, a extração das pistas de rolamento resume-se na rotulação dos *pixels* afastados dos eixos de uma distância menor ou igual a  $w/2$  *pixels*. Assim, são realizadas varreduras sobre todos os *pixels* dos eixos e, por meio de uma análise de vizinhança, todos os *pixels* que estiverem a uma distância menor ou igual a  $w/2$  são rotulados como rodovia.

A tarefa de análise de vizinhança é realizada usando um círculo de raio igual a  $w/2$ . Esse círculo é movido *pixel-a-pixel* sobre os eixos detectados. Isto é, o centro do círculo coincide com os *pixels* do eixo, e todos os *pixels* vizinhos que estiverem dentro do círculo, em cada posição, são rotulados como estrada. A Figura 30 mostra esse procedimento.

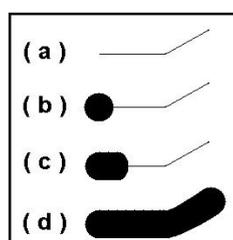


Figura 30 - Eixo (a), Primeiro círculo (b), Segundo círculo (c) e Estrada extraída (d)

Em (a), na Figura 30, é mostrado o eixo da estrada, que pode ser o detectado ou o extraído manualmente. No passo (b), é ilustrado o círculo extraído com base no primeiro *pixel* do eixo. Os círculos referentes aos primeiro e segundo *pixels* do eixo são mostrados em (c) e, finalmente, após varredura sobre todos os *pixels* do eixo, tem-se a pista da estrada extraída em (d).

As seções a seguir mostram os produtos resultantes (estradas extraídas) e as discussões acerca de cada resultado.

#### 4.7 VALIDAÇÃO DE RESULTADOS

O processo de validação dos resultados é realizado usando, como referência, imagens vetorizadas manualmente. Duas imagens de referência são criadas, uma representando os eixos e a outra representando a pista de rolamento das estradas. A vetorização é realizada de forma que todos os *pixels* possíveis de serem eixos de estradas e/ou pista de rolamento sejam rotulados como tal. Essas imagens vetorizadas são denominadas de imagens de referência.

São vários os índices propostos para medir a acurácia de linhas centrais ou eixos de estradas (HEIPKE et al., 1997; CLODE et al., 2004; ZHANG, 2006; HU e TAO, 2007). É consenso, nos estudos sobre a avaliação da acurácia geométrica de eixos de estradas, o uso do índice denominado “RMS diferente”, proposto por Heipke et al. (1997). Nesse tipo de índice, a forma de medir distâncias (ou desvios) entre os eixos (detectado e referência) é muito subjetiva. Nesse trabalho, é proposto um novo método para cálculo dessas distâncias. Adicionalmente, é proposto um modelo matemático para cálculo desse índice. O novo índice é denominado de RMSEixo. Esse erro expressa o deslocamento médio do eixo detectado em relação ao eixo de referência e, conseqüentemente, mede a acurácia geométrica do eixo detectado.

O modelo proposto é fundamentado no RMS (Root Mean Square) e na equação da reta. A Figura 31 auxilia na interpretação do método.

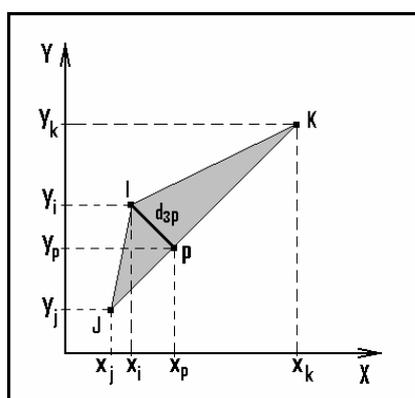


Figura 31 - Erro existente entre dois eixos de estrada

Sendo os pontos (vértices) J e K pertencentes ao eixo de referência e o ponto (vértice) I pertencente ao eixo detectado, a acurácia do eixo detectado é

medida em função do deslocamento do ponto I em relação ao eixo de referência (segmento  $\overline{JK}$ ). Portanto, sendo o segmento  $\overline{Ip}$  perpendicular ao segmento  $\overline{JK}$ , o deslocamento é medido pela distância ( $d_{ip}$ ) entre os pontos I e p.

A menor distância medida no conjunto  $d_{ip}$  é usada como a magnitude do erro entre as duas observações (vértice I e segmento  $\overline{JK}$ ). A equação 22 mostra o modelo que determina a distância entre um ponto e uma reta.

$$\left\{ \begin{array}{l} d_{ip}^2 = \left( \frac{m(y_i - y_j) + m^2(x_j - x_i)}{m^2 + 1} \right)^2 + \left( \frac{m(x_i - x_j) - (y_i - y_j)}{m^2 + 1} \right)^2 \\ \\ RMSE_{ixo} = \sqrt{\frac{\sum_{i=1}^n d_{ip}^2}{n}} \end{array} \right. \quad (22)$$

em que  $m = \frac{y_k - y_j}{x_k - x_j}$  é a inclinação da reta que passa pelos pontos J e K, mostrados na Figura 31;  $n$  é o número de vértices detectados como eixo; e  $j, k$  variam de 1 até o número total de vértices existentes no eixo de referência. Portanto, em cada vértice  $i$  são calculadas  $j$  distâncias  $d_{ip}$ . A menor  $d_{ip}$  do conjunto de  $j$  distâncias é armazenada e, em seguida, inicia o cálculo das  $d_{ip}$  para o vértice  $i+1$ . Finalmente, as  $i$  menores distâncias são usadas no cálculo do RMSEixo. Quanto mais próximo de zero é o valor do RMSEixo, maior é a qualidade geométrica do eixo detectado. Isto é, 0 (zero) é o ponto ótimo desse índice, indicando que o ponto analisado está exatamente sobre o eixo da estrada.

Considerem-se, por exemplo, os segmentos apresentados na Figura 32. Sendo o eixo de referência composto pelos segmentos  $\overline{ab}$ ,  $\overline{bc}$ ,  $\overline{cd}$ ,  $\overline{de}$ ,  $\overline{ef}$  e o eixo detectado composto pelos segmentos  $\overline{12}$ ,  $\overline{23}$ ,  $\overline{34}$ ,  $\overline{45}$ ,  $\overline{56}$ , o RMSEixo calculado é igual a 1, pois todos os vértices do eixo detectado estão afastados do eixo de referência de exatamente uma unidade de medida (um).

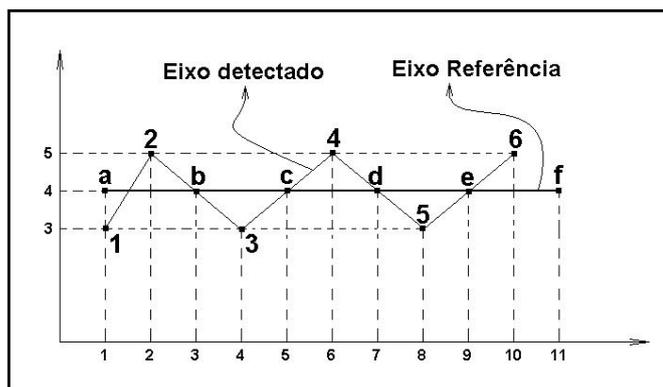


Figura 32 - Exemplo de erros entre os eixos detectados e de referência

Esse método é robusto para quantificar o erro inerente aos vértices detectados, entretanto, não mensura o erro causado pela negligência do algoritmo, isto é, o erro referente aos vértices não detectados. Esse tipo de erro é examinado por meio dos índices: *completeness* (completeza) e *correctness* (correção), descritos em Heipke et al. (1997), Clode et al. (2004), Zhang (2006) e Hu e Tao (2007).

Para entender melhor a definição desses índices, considere-se o exemplo: seja CD o número de dados corretamente extraído como estrada; ND o número dados rotulados como estrada na imagem de referência, mas que não são extraídos pelo método proposto; ED a quantidade de dados erroneamente extraída; Ld o comprimento total de eixos detectados; Ldc o comprimento de eixos detectados corretamente; Lr o comprimento total de eixos de referência; e Lrc o comprimento de eixos de referência que coincide com os eixos detectados;

O primeiro índice, segundo Hu e Tao (2007), é a porcentagem do dado de referência extraído pelo método proposto, de acordo com a equação 23. Pode ser entendida, ainda como a razão entre os dados de estrada de referência que coincidem com os dados de estradas extraídos e o comprimento total da rede de estrada de referência (Zhang, 2006). Esse erro refere-se ao erro de omissão, ou seja, quanto maior seu valor, maior é o comprimento dos eixos corretamente extraído.

$$completeness = \frac{CD}{CD + ND} = \frac{Lrc}{Lr} \quad (23)$$

O índice correção é a porcentagem calculada pela relação entre os dados extraídos corretamente e o total de dados extraídos. Segundo Zhang (2006), a

correção é a razão entre os dados de estrada extraídos que coincidem com os dados de referência e o comprimento da rede de estrada extraída. Esse índice é associado ao erro de comissão, isto é, quanto menor o valor desse índice, maior é a quantidade de eixos de estrada extraídos erroneamente. A correção é determinada pela equação 24.

$$\text{correção} = \frac{CD}{CD + ED} = \frac{Ldc}{Ld} \quad (24)$$

Os valores desses índices variam no intervalo [0, 1], em que 0 (zero) representa o erro máximo e 1 (um) indica o valor ótimo de acurácia.

A determinação do comprimento de eixos detectados corretamente é bem subjetiva, variando de um método para outro (HEIPKE et al., 1997; ZHANG, 2006). Nesse trabalho, é proposto um método baseado na partição dos segmentos detectados e de referência. Para tanto, são realizadas as seguintes etapas: (a) são criados vértices ao longo dos segmentos detectados, ou seja, esses segmentos são particionados em subsegmentos; (b) cada subsegmento possui tamanho igual à largura ( $w$ ) da estrada que contém o segmento detectado; e (c), por fim, as distâncias  $d_{ip}$  (Figura 31) são calculadas a partir de cada vértice criado até o eixo de referência. Se as distâncias  $d_{ip}$  dos dois vértices extremos de um determinado subsegmento são menores que a metade da largura ( $w/2$ ), o comprimento deste subsegmento é armazenado como segmento corretamente detectado ( $Ldc$ ). Esse mesmo procedimento é repetido com o eixo de referência, porém, nesse caso, o comprimento do subsegmento é armazenado como  $Lrc$ .

Ressalta-se que as larguras das estradas são determinadas automaticamente, por um método proposto na seção 4.1 do presente estudo.

## CAPÍTULO 5 – EXPERIMENTOS

### 5.1 DETERMINAÇÃO DE LARGURAS DE ESTRADAS VICINAIS

#### 5.1.1 Usando imagem sintética

Uma imagem sintética, contendo segmentos (pista hipotética de estrada) em diferentes direções, é usada para testar a metodologia proposta. A Figura 33 mostra o negativo dessa imagem sintética. Assim, as feições escuras (simulação de segmentos de estradas) foram usadas nos testes como feições claras.

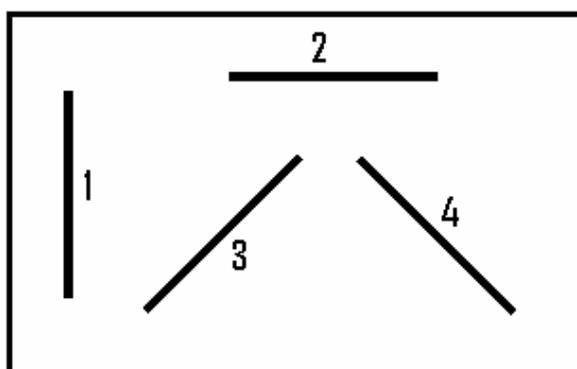


Figura 33 - Imagem sintética simulando pistas de estradas

Os dois segmentos retos (1 e 2) mostrados na Figura 33 foram criados com 5 *pixels* de espessura, os demais com 4 *pixels*. Os valores calculados automaticamente e medidos manualmente para as larguras das estradas (ou segmentos) na imagem sintética se encontram na Tabela 1, que, em sua última coluna, mostra os erros (ou desvios) encontrados.

Tabela 1- Larguras de segmentos em imagem sintética (em *pixels*)

Segmentos	Larguras Referência	Larguras Calculadas	Erros
1	5,00	5,00	0,00
2	5,00	5,00	0,00
3	4,00	4,35	0,35
4	4,00	4,35	0,35

Para o caso ideal, para os segmentos horizontais e verticais (segmentos 1 e 2) não existiram erros. Todavia, para segmentos inclinados (segmentos 3 e 4)

ocorreram erros *subpixels*. Esse erro pode ser explicado pelo serrilhamento criado por *pixels* quando a reta é inclinada. Dependendo da posição em que o semi-arco passa sobre o segmento inclinado, a largura medida pode ser maior ou menor para o mesmo segmento, como mostra a Figura 34.

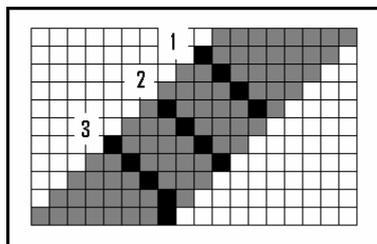


Figura 34 - Erro medindo largura em segmentos inclinados

As larguras do segmento nos semi-arcos 1 e 2 têm módulos iguais, entretanto, no semi-arco 3, existe a contribuição de um quinto *pixel*, como mostra a Figura 34.

#### 5.1.2 Usando imagem real

Quatro recortes de imagem digital contendo estrada vicinal são usados para testar a metodologia proposta. A Figura 35 ilustra os quatro recortes.

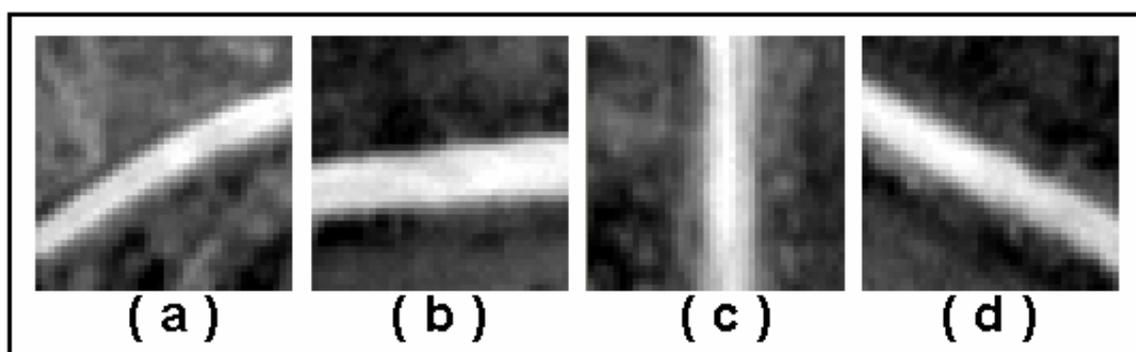


Figura 35 - Recortes de imagem digital real

Os recortes foram escolhidos de forma que representassem estradas em diferentes direções. Novamente, a metodologia proposta mostrou-se eficiente ao apresentar pequenos erros (*subpixels*), como mostrados na Tabela 2.

Tabela 2 - Larguras de segmentos em imagem real (em *pixels*)

<b>Recortes</b>	<b>Larguras Referência</b>	<b>Larguras Calculadas</b>	<b>Erros</b>
<b>a</b>	4,04	4,20	0,16
<b>b</b>	7,07	7,42	0,35
<b>c</b>	6,50	6,87	0,37
<b>d</b>	7,62	7,69	0,07

Para completar a verificação da metodologia, foram usadas as imagens 1 e 2 (Figuras 7 e 8), utilizadas nos experimentos. Buscando uma coerência com o método semi-automático proposto para detecção de linhas, as larguras de referência foram extraídas por um processo manual da seguinte forma: (a) três medidas são realizadas em cada estrada, nas proximidades dos segmentos semente e (b) os valores médios dessas três medidas foram adotados como as larguras  $w$  das estradas. A Tabela 3 mostra os valores das larguras  $w$ , medidas manualmente (referência) e calculadas pelo método proposto. Na última coluna dessa tabela são mostrados os erros decorrentes do método proposto.

Tabela 3 - Larguras de referência de estradas (em *pixels*)

<b>Estradas</b>	<b>Larguras Referência</b>	<b>Larguras Calculadas</b>	<b>Erros</b>
<b>IMAGEM 1 – Estrada 1</b>	5,59	5,74	0,15
<b>IMAGEM 1 – Estrada 2</b>	4,89	5,35	0,46
<b>IMAGEM 2 – Estrada 1</b>	3,53	3,87	0,34
<b>IMAGEM 2 – Estrada 2</b>	4,04	4,26	0,22

Os módulos dos erros são *subpixels*. É difícil fazer uma afirmação da qualidade dessa medida, uma vez que não existe uma Norma Técnica para comparação. Contudo, é verdade que são erros pequenos, considerando o módulo do erro e a resolução espacial da imagem usada (0,8 metros).

A estrada 2, na IMAGEM 2, apresenta um alargamento na região onde se encontra com a estrada 1. Nesse caso, a medida da largura é função do tamanho do raio  $R$  e da posição dos *pixels* do segmento semente fornecidos, pois quanto menor for o raio, maior é a largura medida. A Figura 36 mostra a área em que ocorre a bifurcação ou encontro das duas estradas.

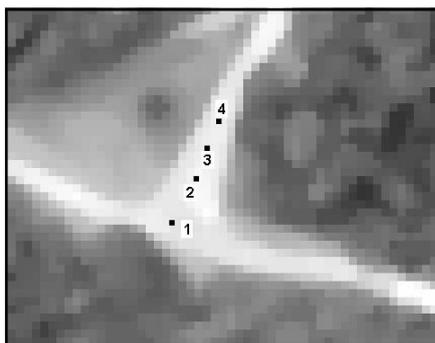


Figura 36 - Alargamento da estrada 2 na IMAGEM 1

Por exemplo, considerem-se as possibilidades de segmentos semente mostradas na Figura 36, segmentos  $\bar{12}$ ,  $\bar{13}$  e  $\bar{14}$ . Nessa ordem, a medida da largura será uma crescente, devido ao alargamento da pista de rolamento. O segmento  $\bar{14}$  foi usado nessa pesquisa por representar uma largura mais coerente com o restante da estrada.

Apesar dos erros apresentados serem todos positivos não implica que não sigam uma distribuição normal. Foram realizadas dezenas de outros testes a fim de verificar a existência de uma tendência. Nesses testes ocorreram erros tanto negativos quanto positivos, portanto não existe uma tendência.

### 5.1.3 Resumo

Foi proposto nessa seção um método para determinação de larguras de estradas vicinais. O exame da metodologia proposta foi realizado por meio de experimentos com imagens sintéticas e imagens reais. Considerando dois fatores: a não existência de Normas Técnicas (Leis) para essa medida, e a complexidade em estimá-la (forma irregular ao longo do seu eixo), pode-se classificar o método como eficiente frente aos erros de magnitudes *subpixels*. Porém, é evidente que ocorrerão falhas no método se a pista de rolamento for obstruída total ou parcialmente. Esses casos não foram testados por não serem foco desta pesquisa.

## 5.2 DETECÇÃO DE LINHAS USANDO ALGORITMOS ÓTIMOS

Foram apresentadas algumas constantes, ao longo da metodologia, necessárias para o início do processo de detecção de eixos. Os valores dessas constantes usadas nos experimentos são apresentados a seguir. Ressalta-se que todas essas constantes foram definidas empiricamente, ou seja, por meio de experimentos.

- a) Os valores usados para o raio  $R$  e o ângulo de direção  $\theta$  são 17 *pixels* e 180 graus, respectivamente.
- b) Para os coeficientes da função objetivo  $a$ ,  $b$  e  $c$  são usados os valores 0,6, 0,3 e 0,1, respectivamente.
- c) O limiar máximo  $T$  usado no critério de parada foi de 0,6.
- d) O incremento  $dR$  usado foi de 1 (um) *pixel* e o número de repetição do incremento foi de 5 vezes.

Nessa seção, foram usadas três imagens: Imagens 1, 2 e 3 apresentadas na seção 3.2. O grau de dificuldade na detecção de segmentos retos aumenta da IMAGEM 1 para a IMAGEM 3. Portanto, a IMAGEM 3 apresenta maiores desafios aos algoritmos propostos.

### 5.2.1 Experimento usando a IMAGEM 1

Os eixos detectados usando algoritmos ótimos e a IMAGEM 1 podem ser vistos na Figura 37.

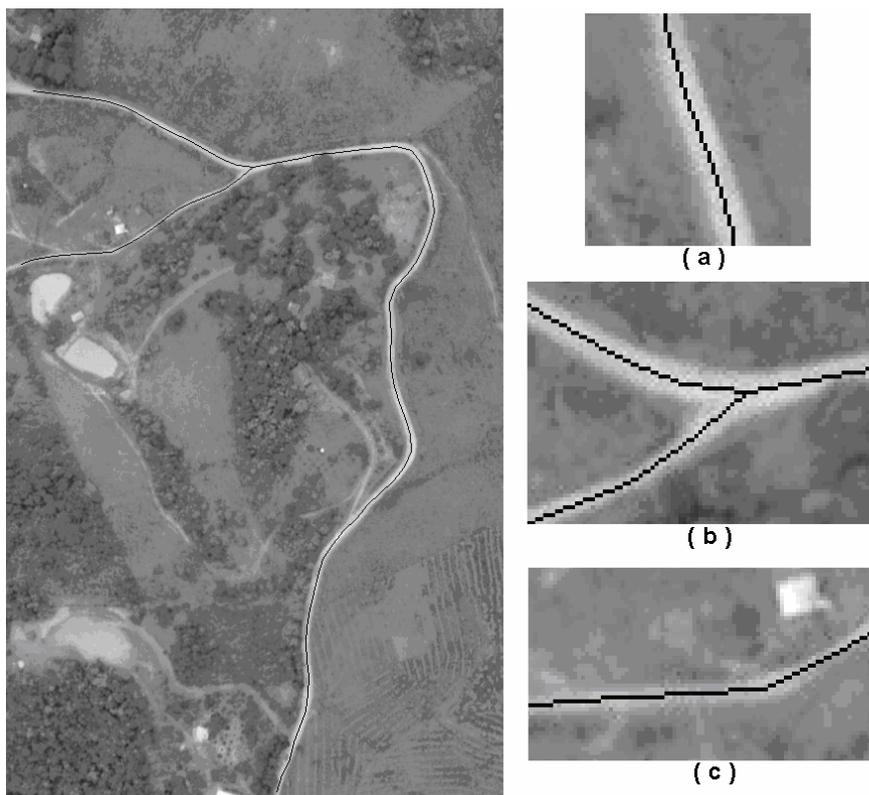


Figura 37 - Eixos detectados na IMAGEM1 usando algoritmos ótimos

Observando a Figura 37 e os recortes ampliados (a), (b) e (c), verifica-se que o resultado, em uma análise visual, é satisfatório. Os obstáculos existentes na IMAGEM 1 foram superados pelos algoritmos ótimos usados. Isto é, os desafios, tais como presença de vias de acesso, alargamento das estradas 1 e 2 no ponto de encontro das duas (ampliação (b) na Figura 37) e a existência de árvores cobrindo parte da pista de rolamento foram superados pelos algoritmos ótimos propostos.

### 5.2.2 Experimento usando a IMAGEM 2

O eixo detectado nesse segundo experimento é ilustrado na Figura 38. Uma falha no processo de detecção do eixo pode ser observada visualmente no meio da estrada 2 (ampliação (a) referente à circunferência branca). Na região em que ocorreu a falha, pode-se observar a presença de uma árvore sobre a estrada. Esse tipo de obstrução elimina total ou parcialmente o gradiente existente entre a feição estrada e as feições vizinhas.

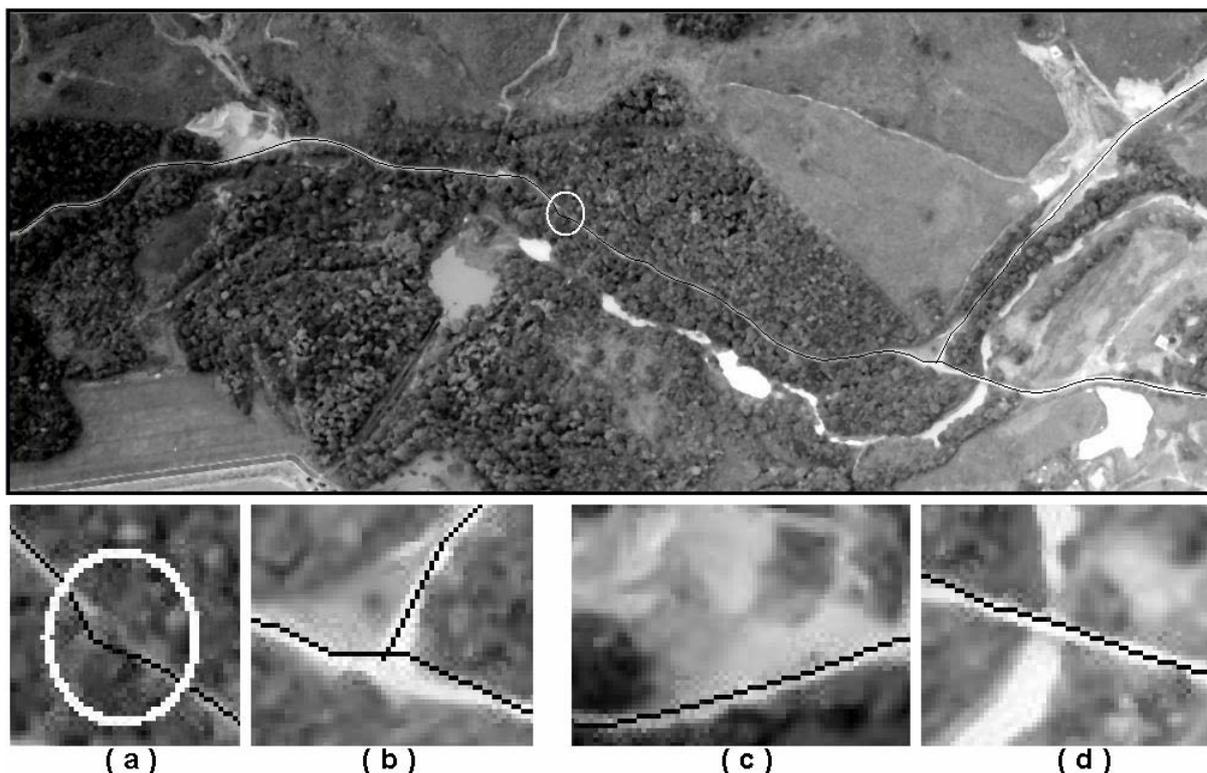


Figura 38 - Eixos detectados na IMAGEM 2 usando algoritmos ótimos

Outra falha ocorrida (ampliação (b) na Figura 38) pode ser vista na bifurcação, ou cruzamento, entre as estradas 1 e 2. Nas proximidades da bifurcação, ocorre um alargamento da estrada 1, o que provoca um deslocamento do eixo para uma das margens. Nesse caso, devido às propriedades intrínsecas do algoritmo, o deslocamento ocorreu para a margem superior. Isto é, a melhor combinação dos três parâmetros da função objetivo ocorreu nas proximidades da margem superior.

Apesar das falhas apontadas, os algoritmos se mostraram eficientes frente aos outros obstáculos existentes, tais como a presença de uma ponte e a similaridade radiométrica das estradas com as feições vizinhas (ampliações (c) e (d) na Figura 38).

### 5.2.3 Experimento usando a IMAGEM 3

Como discutido na seção 3.2, a IMAGEM 3 apresenta uma estrada vicinal com obstruções por sombras de árvores e uma via de acesso que provoca um alargamento da sua pista de rolamento. Os eixos detectados pelos algoritmos ótimos encontram-se na Figura 39.

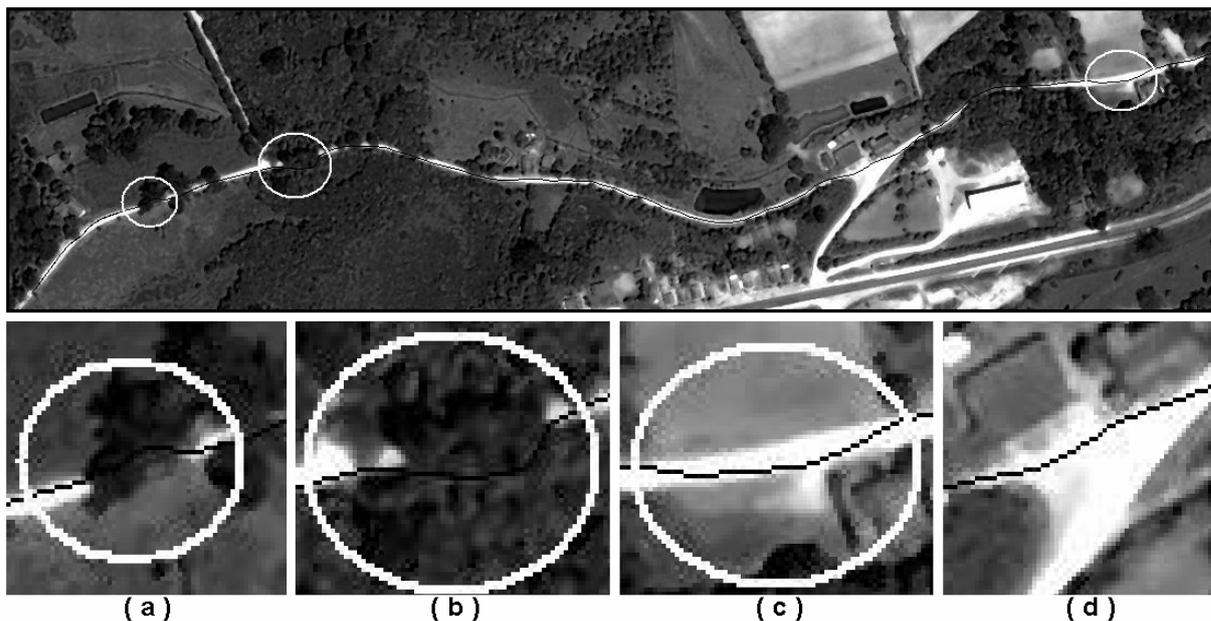


Figura 39 - Eixos detectados na IMAGEM 3 usando algoritmos ótimos

Três falhas percebidas visualmente na Figura 39 ocorreram devido, principalmente, à presença de árvores obstruindo a pista. As áreas com os erros são destacadas com circunferências e com ampliações (a) e (b), na Figura 39. Percebe-se, com os erros apontados, que o algoritmo proposto é sensível às obstruções por árvores, embora tenha ultrapassado os obstáculos. O parâmetro relacionado com a direção, juntamente com o passo de incremento, pressiona o algoritmo a seguir em linha reta, uma vez que os valores dos outros dois parâmetros são baixos. Isto é, não existe nem correlação, nem similaridade radiométrica nas áreas cobertas por árvores. Ressalta-se que são permitidos cinco avanços, portanto, em casos de obstruções muito longas, o algoritmo pode não superar o obstáculo.

Na área que existe o alargamento da pista (ampliação (d) na Figura 39), o algoritmo comportou-se bem, ou seja, não houve grande deslocamento do eixo. Na ampliação (c), da Figura 39, é evidenciado um erro causado pela similaridade dos valores digitais da estrada com os valores digitais de uma área de solo exposto na margem dessa estrada. Nesses casos, ocorre que a largura calculada para a estrada difere muito da largura obtida no local, e isso pode provocar um deslocamento do eixo para uma das margens, como ocorreu na região da via de acesso.

Para completar a avaliação visual, um estudo quantitativo da qualidade dos resultados (acurácia) é realizado, usando os índices supracitados. A Tabela 4

mostra os valores desses índices, calculados para os eixos detectados nas três imagens.

Tabela 4 - Qualidade dos eixos detectados usando algoritmos ótimos

Eixos Detectados	Medidas de Acurácia		
	Completeza	Correção	RMSEixo ( <i>pixels</i> )
<b>IMAGEM 1</b>	0,917	0,937	0,623
<b>IMAGEM 2</b>	0,912	0,895	0,740
<b>IMAGEM 3</b>	0,913	0,933	0,608

O comprimento total de eixos detectados, coincidentes com o respectivo eixo de referência, é similar nas três imagens (>91,2%). Todavia, a quantidade de eixos detectados erroneamente é maior na IMAGEM 2, isto é, 10,5% do comprimento de eixos detectados estão fora da margem considerada coincidente com os eixos de referência.

Os resultados obtidos usando as Imagens 1 e 3 são semelhantes, apesar do maior número de desafios encontrados na IMAGEM 3. A qualidade geométrica dos eixos detectados nessas duas imagens é bem parecida, com uma discrepância de apenas 1,5%.

A qualidade geométrica dos eixos detectados, no segundo experimento, foi inferior à qualidade obtida nos outros dois experimentos. Ressalta-se que o comprimento de eixos existentes na IMAGEM 2 é bem superior aos comprimentos dos eixos das outras duas imagens usadas. Portanto, proporcionalmente, o erro pode não ser tão discrepante.

Parte dos erros medidos nos resultados é inerente ao processo de detecção de eixos. Isto é, enquanto o eixo detectado é controlado por algumas constantes, como o tamanho do raio R (mesmo com o incremento inserido), o eixo de referência é detectado livremente, podendo variar a distância (raio) entre *pixels* selecionados como eixo.

Finalmente, a detecção de eixos, igualmente à medida de larguras de estradas, não possui uma Norma Técnica para avaliação da qualidade do produto final, portanto, é difícil afirmar que o produto gerado é de boa ou má qualidade. Todavia, pode-se considerar pequeno um erro de módulo *subpixel*, como é o caso dos valores dos RMSEixos medidos.

#### 5.2.4 Resumo

Nessa seção, o objetivo é avaliar a função objetivo proposta para uso em algoritmos ótimos (semi-automático), na detecção de segmentos de reta que caracterizam os eixos de estradas vicinais. Todo o processo de detecção é realizado em imagens digitais de alta resolução. Nesse estudo, a validação dos resultados, advindos dos algoritmos propostos, foi realizada com base em uma imagem de referência. A imagem de referência é uma imagem vetorizada manualmente sobre a imagem digital original. O julgamento da acurácia foi computado com base em um índice proposto, denominado de RMSEixo. A metodologia proposta mostrou-se eficiente em imagens sem obstrução total da pista, apresentando resultados com erros *subpixels*. Mesmo no caso em que existe obstrução sobre a pista de rolamento, o erro médio calculado não é expressivo, ainda de magnitude *subpixel*.

### 5.3 DETECÇÃO DE LINHAS USANDO ALGORITMOS GENÉTICOS

Todos os parâmetros, definidos empiricamente e usados nessa seção, foram testados em dezenas de experimentos, confirmando sua real afinidade com a resolução do problema. Os valores adotados para esses parâmetros são apresentados a seguir. Primeiramente são apresentados os parâmetros intrínsecos aos algoritmos genéticos e, posteriormente, os parâmetros relacionados com método propriamente dito.

Os parâmetros intrínsecos aos algoritmos genéticos são: tamanho da população, probabilidades de cruzamento e mutação, número máximo de iterações, limiar  $T$  para a aptidão e os coeficientes para a função de aptidão. Foram usadas populações com 100 indivíduos ( $T_{pop} = 100$ ); probabilidades de 0,6 e 0,01 para cruzamento e mutação, respectivamente; limite máximo de 30 iterações; limiar para a função de aptidão igual a 0,6 ( $T = 0,6$ ); e coeficientes  $a$ ,  $b$  e  $c$  da função de aptidão, iguais a 0,6, 0,3 e 0,1, respectivamente ( $a = 0,6$ ,  $b = 0,3$  e  $c = 0,1$ ). Ressalta-se que os valores de probabilidades de cruzamento e mutação usados são valores comumente usados em pesquisas com algoritmos genéticos.

Por outro lado, os parâmetros externos aos algoritmos genéticos são: raio  $R$  da circunferência de busca; avanço  $dR$  sobre o raio  $R$ ; e ângulo ( $\theta$ ) que delimita a área de busca. Os valores usados para  $R$  e  $dR$  são 15 e 1 *pixels* ( $R = 15$  e  $dR = 1$ ), respectivamente, e o ângulo usado foi de 150 graus ( $\theta = 150^\circ$ ).

O processo de validação é processado comparando os resultados obtidos a partir da metodologia proposta com imagens vetorizadas manualmente (imagem de referência). Para tanto, são usados os índices completeza, correção e RMSEixo. Os experimentos foram realizados com as IMAGEM 1, IMAGEM 2 e IMAGEM 3.

#### 5.3.1 Experimentos usando a IMAGEM 1

As larguras das estradas vicinais, medidas e calculadas, são as mesmas apresentadas na Tabela 2 (seção 5.1), referentes à IMAGEM 1.

Os resultados obtidos nesse experimento podem ser vistos na Figura 40.

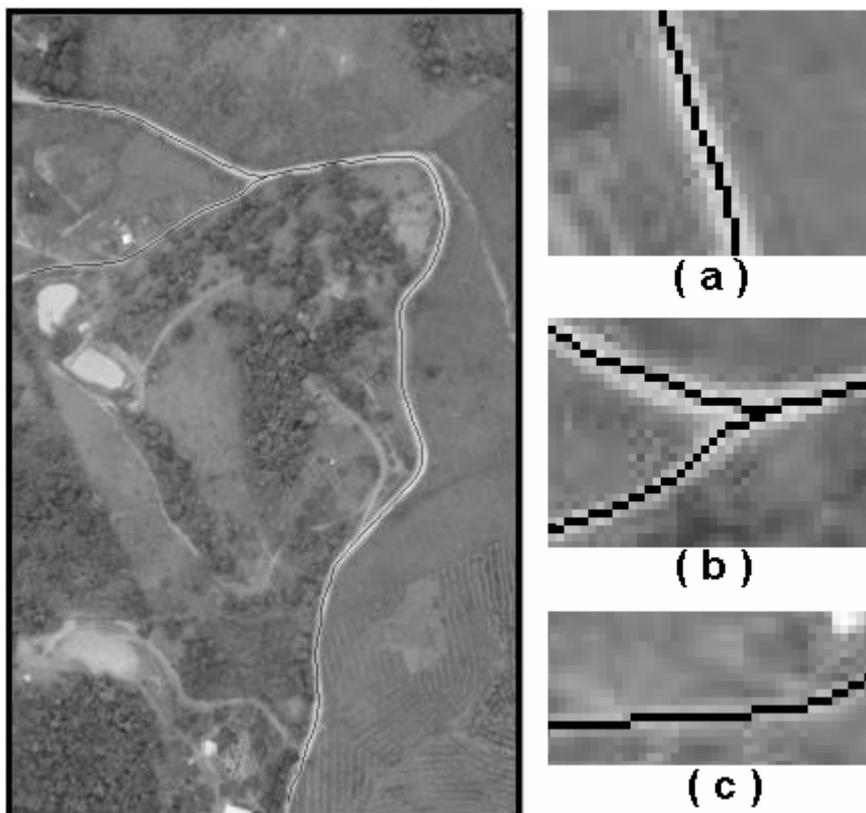


Figura 40 - Eixos detectados na IMAGEM 1 usando algoritmos genéticos

A proximidade ou semelhança dos eixos detectados (ampliações (a), (b) e (c) na Figura 40) com os eixos de referência permite afirmar que, visualmente, o resultado é aceitável. De modo semelhante aos algoritmos ótimos, os algoritmos genéticos também superaram os obstáculos existentes na IMAGEM 1. Observa-se que as vias de acesso e a presença de árvores foram ignorados.

### 5.3.2 Experimentos usando a IMAGEM 2

A Figura 41 ilustra os eixos detectados na IMAGEM2, referentes às duas principais estradas vicinais presentes.

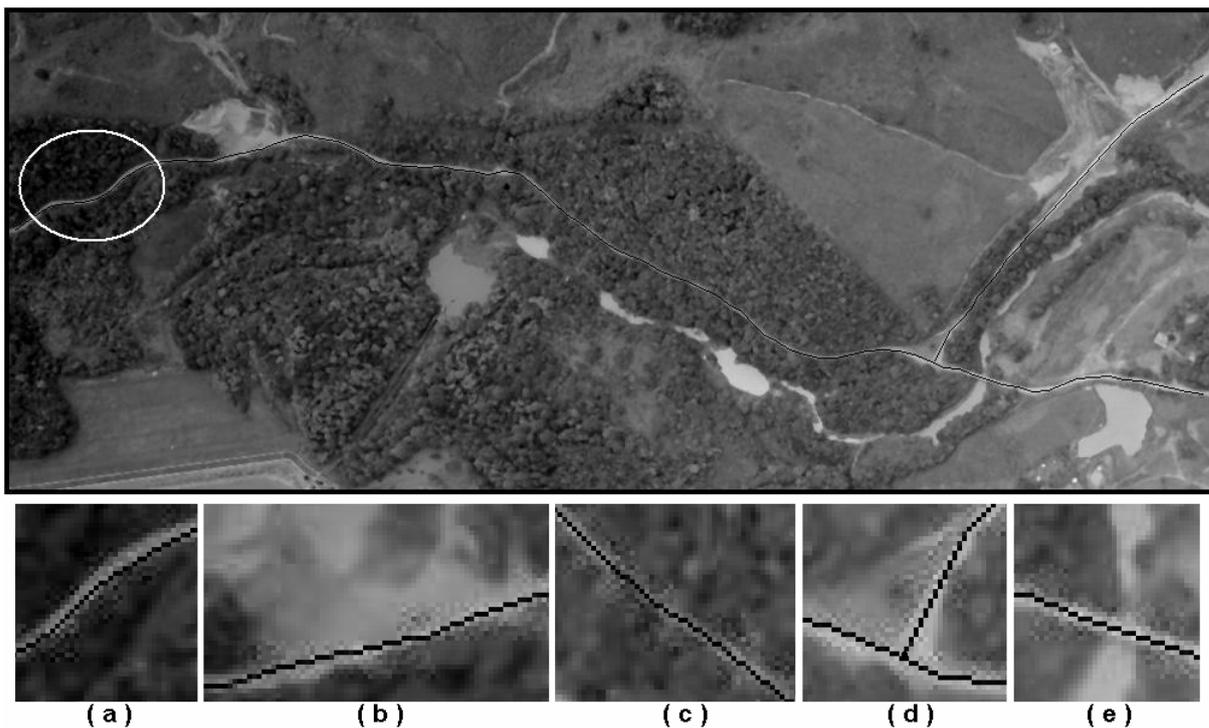


Figura 41 - Eixos detectados na IMAGEM 2 usando algoritmos genéticos

O erro que se pode perceber visualmente é destacado na área dentro da circunferência e na ampliação (a) na Figura 41. O fato de o raio  $R$  possuir tamanho fixo, durante todo o processo de busca, proporciona esse tipo de erro. Esse erro ocorre em curvas muito acentuadas. O ideal seria que o raio pudesse variar de tamanho para cada situação. Por exemplo, nesse tipo de curva, um raio  $R$  menor concordaria com melhor precisão. Os outros erros existentes nos eixos detectados são quase imperceptíveis visualmente, como mostram os recortes ampliados (b), (c), (d) e (e), na Figura 41.

### 5.3.3 Experimentos usando a IMAGEM 3

Os eixos detectados, usando o método proposto seção 4.3 e a IMAGEM 3, são delineados na Figura 42.

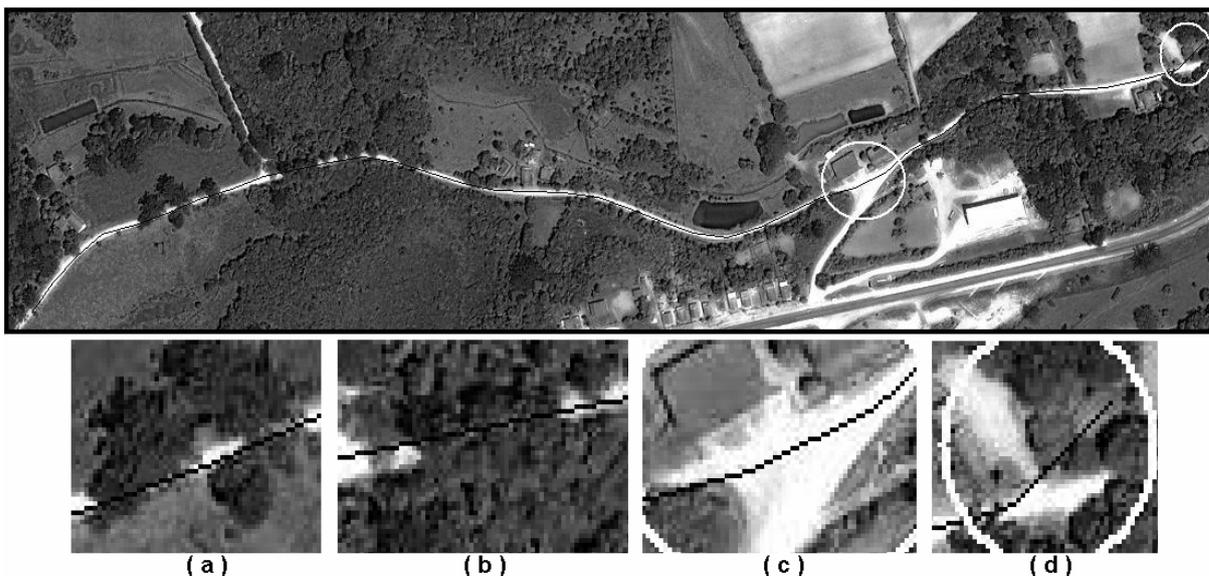


Figura 42 - Eixos detectados na IMAGEM 3 usando algoritmos genéticos

Embora a estrada presente nessa imagem apresente muitos desafios (recortes (a), (b), (c) e (d), ampliados na Figura 42), percebe-se, visualmente, que os algoritmos usados apresentaram bom desempenho. Isto é, os maiores erros, percebidos visualmente, ocorreram em áreas críticas, como mostram as áreas circuladas e nas ampliações (c) e (d), na Figura 42.

A ocorrência da falha mostrada na ampliação (d), na Figura 42, é devida à existência de uma obstrução exatamente no fim da imagem. Essa ocorrência diminui o espaço de busca e, conseqüentemente, reduz as opções de busca pelos algoritmos genéticos. Portanto, se a imagem fosse maior, em colunas, esse erro provavelmente não teria ocorrido. O erro ocorrido na outra área circulada (ampliação (c), na Figura 42) é devido ao alargamento da pista. Diferentemente dos algoritmos ótimos, que aproximaram o eixo para uma das margens, nessa mesma região os algoritmos genéticos buscaram mais o centro da pista alargada. Portanto, não se pode afirmar que esse ou aquele algoritmo tenha sido mais eficiente na solução desse problema, pois ambos os resultados podem ser corretos, dependendo do operador que analisa o resultado.

Em uma comparação geral, percebe-se que os algoritmos genéticos foram mais eficientes que os algoritmos ótimos, pois apresentaram menores erros; por exemplo, na região da ampliação (c), na Figura 39, onde os algoritmos ótimos falharam, os algoritmos genéticos não apresentaram erro.

Um estudo quantitativo, usando os índices supracitados, foi realizado para medir a qualidade dos eixos detectados em relação aos respectivos eixos de

referência. A Tabela 5 mostra os valores desses índices, medidos sobre os resultados advindos das três imagens usadas.

Tabela 5 - Qualidades dos eixos detectados usando algoritmos genéticos

Eixos Detectados	Medidas de Acurácia		
	Completeza	Correção	RMSEixo ( <i>pixels</i> )
<b>IMAGEM 1</b>	0,885	0,935	0,685
<b>IMAGEM 2</b>	0,920	0,910	0,673
<b>IMAGEM 3</b>	0,854	0,856	1,609

Diferentemente dos algoritmos ótimos, o resultado usando algoritmos genéticos com a IMAGEM 2 é superior aos resultados usando as outras duas imagens. E 92% dos eixos das estradas existentes na imagem de referência, correspondente à IMAGEM 2, foram detectados corretamente. Adicionalmente, foi registrada uma correção de 91% e uma qualidade geométrica com erro *subpixel* de 0,673.

O erro de completeza, referente à IMAGEM 1, mostra que 11,5% dos eixos de referência não foram detectados pelo método proposto. Por outro lado, a correção, nessa mesma imagem, indica que apenas 6,5% dos eixos detectados não pertencem, efetivamente, à estrada de referência. A qualidade geométrica dos eixos detectados com a IMAGEM 1 é quantificada como um erro *subpixel*. Um erro pequeno e concordante com a análise visual.

As medidas de completeza entre as Imagens 1 e 3 são similares, contudo ocorre uma discrepância considerável entre os valores de correção, resultantes dessas Imagens (7,9%). Adicionalmente, a qualidade geométrica dos eixos detectados na IMAGEM 1 é superior à qualidade medida na IMAGEM 3. A redução na qualidade geométrica, no produto gerado a partir da IMAGEM 3, deve-se à complexidade (quantidade de obstruções) e à falha ocorrida no final da estrada.

O módulo do RMSEixo calculado na IMAGEM 3 é superior a um *pixel*. A falha dos algoritmos genéticos, que mais contribuiu com esse erro, é visivelmente identificada na Figura 42, dentro da circunferência desenhada no canto superior direito dessa figura. O erro medido isoladamente nessa falha é de 8,024 *pixels*, e o desvio padrão do conjunto de erros medido ao longo de todo o eixo é de 0,695 *pixel*. Desse fato, conclui-se que esse erro discrepante, referente a essa falha, é o causador do acréscimo exagerado no valor do RMSEixo, se comparado aos erros médios medidos nos outros dois experimentos.

Observando as Tabelas 4 e 5, verifica-se que os algoritmos ótimos mostraram mais eficiência na detecção de eixos, usando as Imagens 1 e 3, porém os algoritmos genéticos foram superiores usando a IMAGEM 2. Mas, considerando que o erro referente à falha ocorrida na IMAGEM 3 possa ser corrigido, tanto os algoritmos ótimos quanto os genéticos mostraram eficácia na execução dessa tarefa, pois apresentaram erros *subpixel* na avaliação da qualidade geométrica dos eixos detectados.

#### 5.3.4 Resumo

Nessa seção é avaliada a função de aptidão proposta para os algoritmos genéticos, que possibilita a detecção de segmentos candidatos a eixo de estradas vicinais. Três imagens digitais são usadas nos experimentos. Nesse estudo, a validação dos resultados, advindos dos algoritmos propostos, foi realizada com base em imagens de referência. O julgamento da acurácia foi computado com base nos índices completeza, correção e RMSEixo. Em imagens com feições estrada que apresentam menor número de desafios, os resultados foram de magnitude *subpixel*, entretanto, em estradas que apresentam cobertura parcial ou total da pista de rolamento por obstáculos, tais como árvores, o erro, embora aceitável, foi superior ao *pixel*, em um dos casos estudados.

## 5.4 DETECÇÃO DE LINHAS USANDO TRANSFORMADA RADON

Todos os parâmetros (constantes) usados nessa seção também foram definidos empiricamente. Os valores utilizados para esses parâmetros são apresentados a seguir.

A diferença entre raios, usada no processo de seleção dos melhores segmentos semente, é igual a um quarto de  $R_1$  ( $R_1 - R_2 = R_1/4$ ); os valores dos limiares  $T$  usados nas duas funções objetivo (equações 8 e 17), foram  $T1 = 0,6$  e  $T2 = 0,75$ , respectivamente; e o tamanho das subimagens usadas foi de 15 *pixels* ( $T_j = 15$ ).

Entre os desafios apontados no processo de detecção dos eixos das estradas, presentes nas imagens usadas, foi mencionada a presença de vias de acesso ao longo das pistas de rolamento. Esse desafio não é tão significativo no método proposto na seção 4.5, pois os segmentos semente são detectados sobre toda a imagem e não somente sobre as estradas de interesse. Assim, além das estradas de interesse, outras vias de acesso podem ser detectadas, desde que tenham sido detectados segmentos semente correspondentes. Essa propriedade é uma vantagem desse método em relação aos outros propostos nessa pesquisa.

Outra peculiaridade nessa seção é o uso de duas outras imagens, IMAGEM 4 e IMAGEM 5, que, além de possuírem os mesmos obstáculos existentes nas Imagens 1, 2 e 3, possibilitam um estudo mais detalhado do método proposto. Adicionalmente, o algoritmo proposto nessa abordagem automática é avaliado com o uso de duas imagens sintéticas.

### 5.4.1 Experimento usando imagens sintéticas

Duas imagens sintéticas, SINTÉTICA 1 e SINTÉTICA 2, contendo segmentos (pista hipotética de estrada) retos, curvos e circulares são usadas para testar a metodologia proposta. A Figura 43 mostra o negativo - as feições escuras são claras na imagem original - da imagem SINTÉTICA 1.

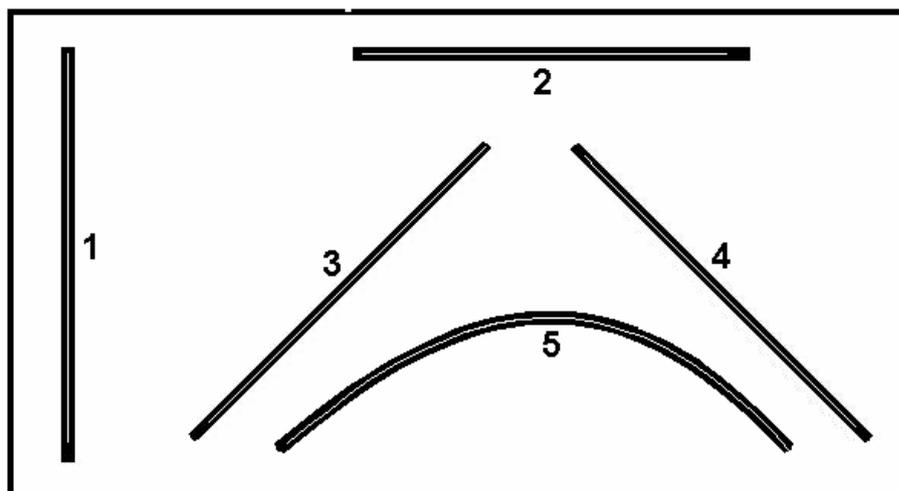


Figura 43 - Imagem SINTÉTICA 1 com os segmentos detectados

Os dois segmentos retos (1 e 2), mostrados na Figura 43, foram criados com 5 *pixels* de espessura, os demais, com 4 *pixels*. Os resultados obtidos com os segmentos retos 1 e 2 foram os esperados. Isto é, o *pixel* central, dos cinco definidos como largura do segmento, foi caracterizado como eixo da estrada. Desse modo, o eixo da estrada foi definido exatamente no centro dos segmentos. Nos outros segmentos, com quatro *pixels* de largura, especialmente nos segmentos inclinados 3 e 4, o algoritmo apresentou a mesma tendência, criando os eixos na parte inferior dos segmentos. Essa tendência pode ser explicada com base em dois fatores: na largura calculada para a estrada e no critério de decisão imposta ao algoritmo. Por exemplo, sendo a largura da estrada de 4 *pixels* e a largura calculada, automaticamente, de 3,5 *pixels*, o algoritmo terá mais de uma solução ótima (Figura 44). Nesses casos, ele optará pela primeira, devido ao critério de parada imposto, pois, ao atingir um ótimo o processo iterativo, ele é interrompido.

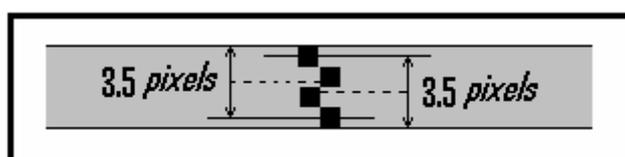


Figura 44 - *Pixels* candidatos ao eixo de estrada vicinal

A Figura 44 ilustra apenas uma das possibilidades, mas podem ocorrer outras. Por exemplo, sendo a mesma estrada da Figura 44 e a largura calculada de 4,5 *pixels*, também existirão duas soluções ótimas. Isso leva a uma reflexão acerca da mensuração da qualidade de um eixo detectado, pois, mesmo que a largura

calculada seja acurada à definição do eixo, ela está sujeita a erros, ainda que pequenos ou *subpixels*. Por exemplo, o erro dos eixos detectados nos segmentos 3, 4 e 5 pode ser nulo ou de até um *pixel*, dependendo do eixo que o operador escolher como referência. Nos segmentos 1 e 2, o erro é nulo independentemente do operador, todavia, em casos reais, os perfis de estradas vicinais estão mais próximos daqueles mostrados nos segmentos 3, 4 e 5.

A Figura 45 mostra a imagem Sint 2 e os segmentos detectados, usando a metodologia proposta.

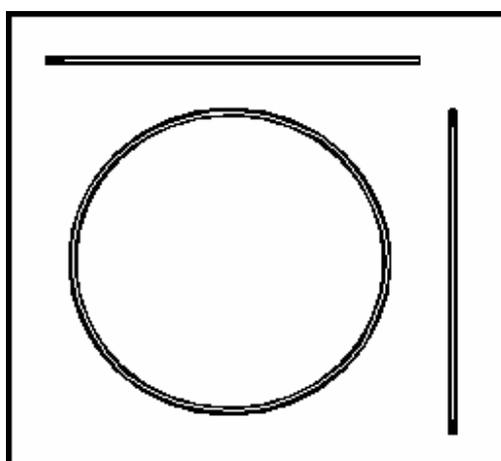


Figura 45 - Imagem SINTÉTICA 2 com os segmentos detectados

A imagem SINTÉTICA 2 apresenta, como desafio principal, um segmento (estrada hipotética) em forma de circunferência. Os dois segmentos retos são usados para verificar o ocorrido no experimento realizado com a imagem SINTÉTICA 1.

As linhas centrais dos dois segmentos retos, presentes na Figura 45, foram novamente detectados com excelente qualidade geométrica, ótima correção e com pequenos erros de completeza. O erro de completeza, presente nas extremidades dos segmentos, ocorre devido ao tamanho fixo do raio  $R$ , que não permite a detecção da linha central até a extremidade dos segmentos.

A linha central, detectada no segmento circular, apresentou boa qualidade geométrica, isto é, um erro de apenas 0,315 do *pixel*. O erro de correção, em todos os segmentos, tanto reto quanto circular, é nulo (correção igual a 1). O erro de completeza existente no conjunto total de segmentos é o mesmo medido para os segmentos retos isoladamente com magnitude igual a 0,942. Isto é, não existem erros de correção e/ou completeza no segmento circular. Esses erros modestos são

indícios de aplicabilidade da metodologia. Testes com imagens reais são realizados nas seções que seguem.

#### 5.4.2 Experimento usando a Imagem 1

As larguras calculadas nesse método podem se diferenciar daquelas apresentadas na Tabela 3, pois os segmentos semente são detectados ao longo das estradas e não, necessariamente, no seu início. A largura de uma determinada estrada, nesse experimento, é medida pela média das larguras de todos os segmentos semente detectados para esta estrada. As larguras computadas, automaticamente, para estrada 1 e 2 são 5,69 e 4,72 *pixels*, respectivamente. Os erros medidos são, portanto, 0,10 *pixel* na estrada 1 e 0,17 *pixel* na estrada 2. São, novamente, erros de magnitude *subpixel*.

Os eixos detectados com a aplicação do método usando a IMAGEM 1 podem ser vistos na Figura 46.

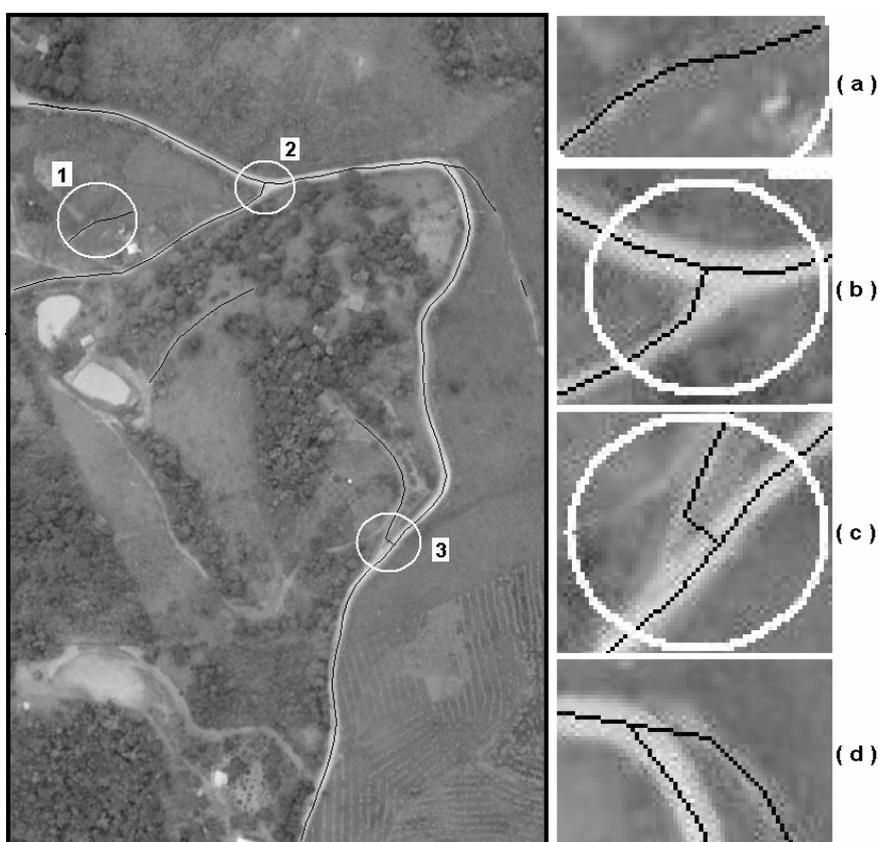


Figura 46 - Eixos detectados na IMAGEM 1 usando abordagem automática

Visualmente, os eixos detectados nas estradas 1 e 2 mostram ser acurados. A única falha que se pode observar visualmente, nesses dois eixos, é apontada pela circunferência 2 e ampliada no recorte (b), na Figura 46. Essa falha é um erro do processo de parada do algoritmo e não do método propriamente dito. Isto é, a injunção de parada, colocada ao algoritmo, é de que, no processo de detecção de um determinado eixo, ao encontrar outro eixo já detectado, procure o vértice mais próximo nesse eixo já existente e faça a conexão. Esse critério é a causa para os erros ocorridos nas áreas marcadas pelas circunferências 2 e 3, ampliações (b) e (c), na Figura 46.

Podem ser vistos na Figura 46 que foram detectados outros eixos (eixos falso-positivos, ampliações (a), (c) e (d) na Figura 46), além daqueles referentes às estradas 1 e 2. Portanto, a análise da qualidade desses eixos foi tratada em duas fases distintas. Primeiramente, a verificação dos erros foi realizada apenas com os vértices (pontos) detectados como eixos das estradas 1 e 2. Em uma segunda análise, foram considerados todos os eixos detectados. Para tanto, na segunda fase, a imagem de referência foi completada com os eixos das vias de acesso às estradas 1 e 2. Ressalta-se que se o alvo são somente as estradas vicinais principais, essas vias de acesso detectadas são erros. Contudo, podem ser bem-vindas se o objetivo é criar uma malha viária das estradas e vias existentes na região. Por exemplo, a área marcada na Figura 46, pela circunferência 1 e ampliada no recorte (a), é apenas um caminho para trajetos de animais e/ou veículos de tração animal. Portanto, dependendo do objetivo, pode ser um erro a detecção dessa feição.

A detecção de vias de acesso pode ser controlada pelo parâmetro T, limite mínimo para a função objetivo/aptidão. Quanto maior esse valor, mais conciso são os eixos detectados, ou seja, somente feições com características de estradas bem definidas, tais como largura e geometria, são detectadas.

#### 5.4.3 Experimento usando a IMAGEM 2

Os eixos detectados usando a Imagem 2 são ilustrados na Figura 47. Quatro falhas ocorridas no processo de detecção dos eixos podem ser percebidas

visualmente, nesse experimento. Essas falhas são destacadas em circunferências e ampliações, na Figura 47.

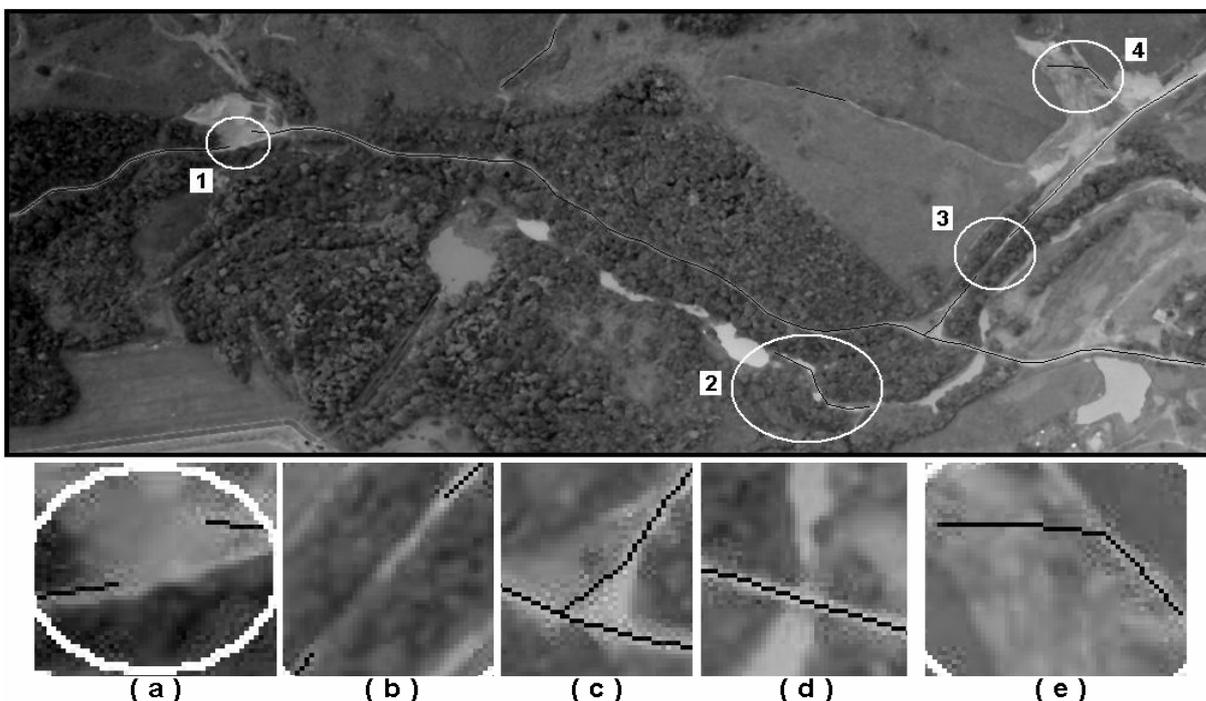


Figura 47 - Eixos detectados na IMAGEM 2 usando a abordagem automática

As circunferências 1 e 3 e as ampliações (a) e (b) mostram falhas na conexão dos eixos. A falha mostrada na circunferência 1 é causada pela similaridade radiométrica entre a feição estrada e o solo exposto. A cobertura da pista por vegetação causa erros do tipo mostrado na circunferência 3. Esses erros também podem ser controlados pelo parâmetro  $T$ , mencionado na seção anterior.

Por outro lado, os eixos detectados nas áreas marcadas pelas circunferências 2 e 4 (ampliada no recorte (e)) são erros na detecção. O erro ocorrido na área da circunferência 2 pode ser eliminado por meio de um pré-processamento, em que é eliminada a feição água. A integração de imagens digitais com outros dados, por exemplo, com dados LASER, facilita a identificação e, conseqüentemente, a eliminação dessa feição. Ressalta-se que o termo eliminar a feição água significa classificar essa feição, atribuindo um novo valor digital, por exemplo, o valor zero, a todos os *pixels* componentes dessa feição. Essa classificação permite que o método ignore tais *pixels*, uma vez que no método proposto são consideradas apenas as feições que apresentam altos valores digitais em relação à vizinhança.

Adicionalmente aos eixos referentes às estradas 1 e 2 foram detectados eixos de vias de acesso, isto é, eixos falso-positivos. Esses eixos são referentes às trilhas e/ou caminhos usados por animais (gado) para ir às pastagens, ou mesmo caminhos para tráfego com veículos de tração animal. Como discutido na seção anterior, esses eixos podem ser úteis ou considerados erros, dependendo do interesse do operador ou usuário do produto final. Apesar das falhas apontadas, os algoritmos se mostraram eficientes frente aos outros obstáculos existentes, tais como a presença de uma ponte e a variação radiométrica da feição estrada, ao longo do eixo.

Nesse experimento, foi possível também, medir as larguras das estradas 1 e 2. As larguras médias dessas estradas, obtidas automaticamente, são 3,37 e 4,16, respectivamente. Portanto, os módulos dos erros medidos são de 0,16 *pixel* na estrada 1 e de 0,12 *pixel* na estrada 2.

#### 5.4.4 Experimento usando a IMAGEM 3

A Figura 48 mostra os eixos detectados na IMAGEM 3. Observando essa figura, percebe-se que eixos extras (falso-positivos) foram detectados. Isto é, eixos diferentes daqueles da estrada principal analisada nos métodos semi-automáticos.

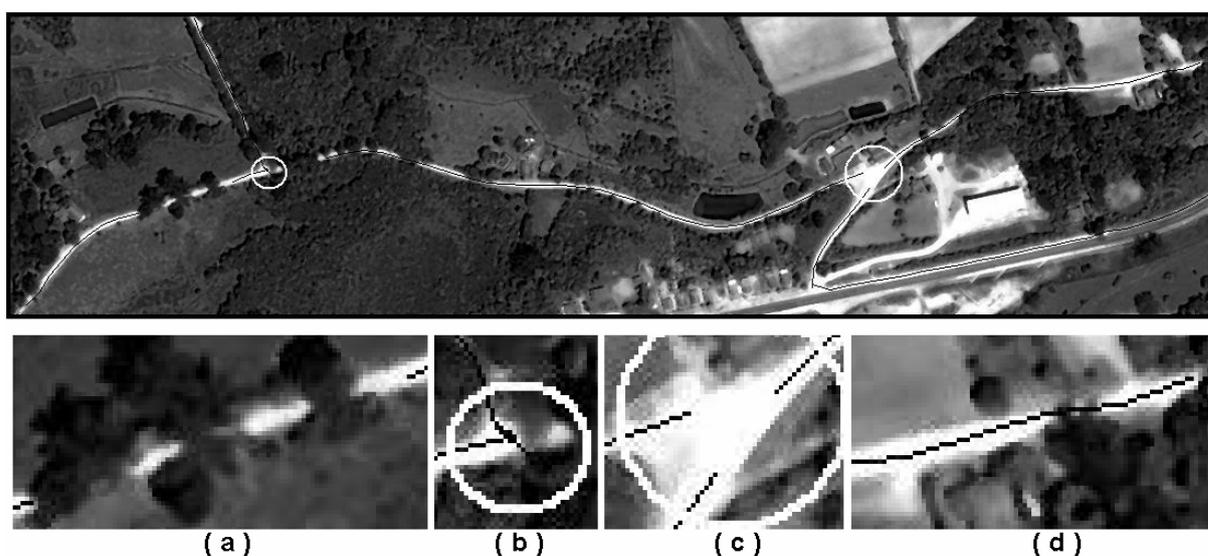


Figura 48 - Eixos detectados na IMAGEM 3 usando abordagem automática

Duas falhas visíveis podem ser vistas nas duas circunferências desenhadas e nos recortes (b) e (c), na Figura 48. Na ampliação (b), houve uma extrapolação do eixo da via de acesso em relação ao eixo da estrada vicinal principal. Contudo, nos recortes ampliados (a) e (c) ocorreu erro de completeza nos eixos. No recorte (a), a falha deve-se à obstrução da pista de rolamento por árvores e sombras; a outra falha ocorreu devido à existência de uma bifurcação (ou cruzamento) entre a estrada principal e uma via de acesso. Essa bifurcação proporcionou um alargamento da pista e, conseqüentemente, uma mudança na largura da estrada. A alteração da largura  $w$  é a principal causa do erro (completeza).

A análise quantitativa nos três experimentos foi realizada por meio dos índices completeza, correção e RMSEixo. Esses três índices são medidos em função dos tipos e quantidades de eixos detectados. No primeiro experimento, por exemplo, os erros foram medidos em função da detecção do caminho/trilha detectado (Figura 46). Portanto, considerando erro a detecção dos caminhos/trilhas, os valores de completeza, correção e RMSEixo são, respectivamente, 0,727, 0,881 e 7,830 *pixels*. Nota-se, nesse caso, que a qualidade geométrica dos eixos detectados é consideravelmente afetada, apresentando um erro de aproximadamente 8 *pixels*. Todavia, considerando os caminhos/trilhas como feições de interesse, os erros assumem as medidas de 0,725, 0,917 e 0,732, respectivamente. Embora os valores de completeza e correção continuem modestos, a qualidade geométrica é bem melhor, atingindo um erro *subpixel*. Adicionalmente, foi realizado um estudo da qualidade dos eixos detectados apenas para as estradas 1 e 2, analisadas nas outras seções. Nesse caso, os erros apresentaram módulos de 0,899, 0,923 e 0,706, respectivamente. Percebe-se, nesse caso, que tanto a qualidade geométrica quanto os erros completeza e correção apresentaram ganhos em relação aos outros dois casos.

No segundo experimento, os erros medidos, por meio dos três índices, são analisados em função do erro causado pela presença da feição água. Portanto, eliminando os segmentos detectados erroneamente, na feição água, os erros completeza, correção e RMSEixo são, respectivamente, 0,726, 0,862 e 10,072. Por outro lado, os valores desses erros medidos, somente para as estradas 1 e 2, são 0,860, 0,905 e 0,790. Nesse caso, é evidente o aumento da acurácia.

Finalmente, no terceiro experimento, os três erros medidos, considerando todos os eixos detectados, possuem magnitudes de 0,750, 0,880 e 0,953,

respectivamente. Contudo, considerando apenas o eixo detectado para a estrada principal, analisada nas outras seções, os erros são 0,787, 0,915 e 0,709. A principal contribuição para o aumento da qualidade geométrica deve-se à retirada do eixo que causa o erro, evidenciado na parte oeste da Figura 48.

A Tabela 6 evidencia os valores dos índices referentes aos eixos das principais estradas vicinais, presentes nas três imagens usadas.

Tabela 6 - Qualidade dos eixos detectados usando abordagem automática

Eixos Detectados	Medidas de Acurácia		
	Completeza	Correção	RMS
<b>IMAGEM 1</b>	0,899	0,923	0,706
<b>IMAGEM 2</b>	0,860	0,905	0,790
<b>IMAGEM 3</b>	0,787	0,915	0,709

Verifica-se na tabela 6 que a qualidade do produto final, no primeiro experimento, é superior aos resultados dos outros dois experimentos. O comprimento do eixo de referência, detectado corretamente na IMAGEM 2, é maior, proporcionalmente, que o comprimento do eixo corretamente detectado na IMAGEM 3. Entretanto, o erro de correção é maior na IMAGEM 2.

Para concluir o estudo com as Imagens 1, 2 e 3, foi realizada uma análise comparativa, em termos de qualidade geométrica, dos eixos detectados nos três métodos propostos. Os valores dos RMSEixo medidos são mostrados na Tabela 7.

Tabela 7 - Comparações entre os resultados dos métodos propostos

Eixos Detectados	RMSEixo (em <i>pixels</i> )		
	Algoritmos Ótimos	Algoritmos Genéticos	Abordagem Automática
<b>IMAGEM 1</b>	0,623	0,685	0,706
<b>IMAGEM 2</b>	0,740	0,673	0,790
<b>IMAGEM 3</b>	0,608	1,609	0,709

Os valores mostrados na Tabela 4 relatam que os algoritmos ótimos foram mais eficientes que os algoritmos genéticos no primeiro e terceiro experimentos. Exceto no terceiro experimento, usando algoritmos genéticos, a abordagem automática apresentou maiores erros em todos os experimentos. Contudo, a qualidade geométrica de todos os eixos detectados na abordagem automática é de módulo *subpixel*, com magnitude de aproximadamente 0,565, 0,632 e 0,567 metros, nos experimentos 1, 2 e 3, respectivamente. Como mencionado anteriormente, não

existe uma Norma Técnica para esse tipo de produto, portanto, não se pode inferir qualificando os resultados advindos das duas abordagens: automática e semi-automática. Como se tratar de erros com magnitude *subpixels*, em ambas as abordagens, a automatização tem a vantagem de não exigir a participação do usuário.

#### 5.4.5 Experimento usando a IMAGEM 4

Como descrito na introdução dessa seção, a IMAGEM 4 possui maior comprimento de eixos a serem detectados. A Figura 49 mostra os eixos detectados pela abordagem apresentada nessa seção.

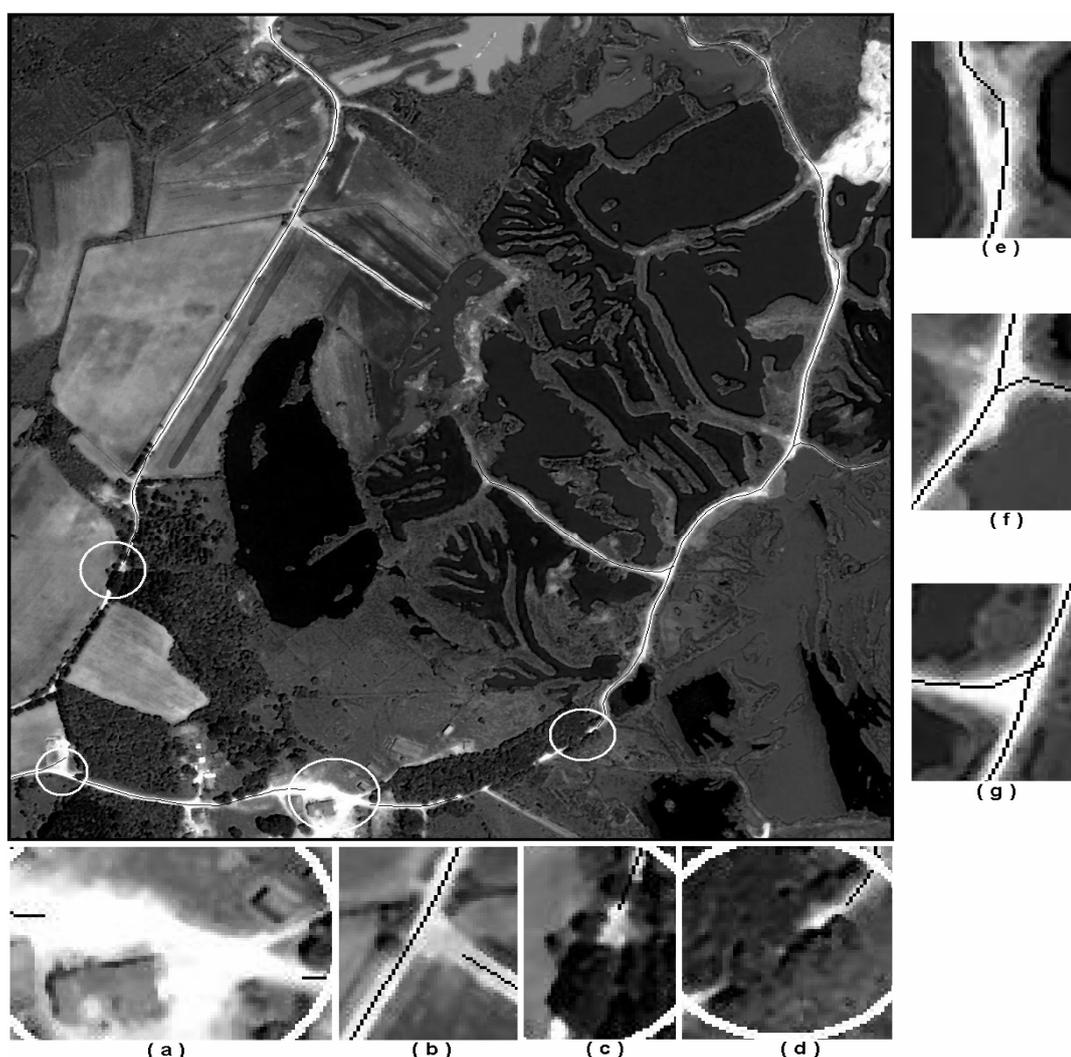


Figura 49 - Eixos detectados na IMAGEM 4 usando abordagem automática

Como nos experimentos anteriores, os eixos detectados na IMAGEM 4 são visualmente de boa qualidade. Porém, é visível a não completude dos eixos em trechos das estradas. As circunferências ilustradas e os recortes (a), (b), (c) e (d), na Figura 49, mostram as áreas em que ocorrem essas falhas. Esse tipo de falha pode ser contornado com alteração dos valores de alguns dos parâmetros usados: por exemplo, os valores de  $T$  para detecção de segmentos sementes e de  $T$  para detecção de segmentos candidatos a eixo da estrada e, principalmente, o valor de  $T_j$ . Ressalta-se que a variação (redução) dos valores de  $T$  pode possibilitar o aumento do erro de correção. O estudo com a IMAGEM 5, apresentado na próxima seção, mostra a influência do tamanho da janela ( $T_j$ ) nos resultados.

O recorte (e), ilustrado na Figura 49, mostra uma falha relativa à similaridade radiométrica, causada por uma porção de solo exposto localizada na margem da estrada. Os outros dois recortes (f) e (g) exibem a detecção de duas bifurcações entre a estrada principal e vias de acesso. Ao atingir uma bifurcação, os algoritmos têm duas opções em termos de direção, portanto, qualquer uma pode ser escolhida sem caracterizar erro de detecção.

Os valores de completude, correção e  $RMSE_{Eixo}$  medidos são 0,753, 0,898 e 1,036, respectivamente. Embora o comprimento dos eixos existentes nessa imagem seja maior, é notória a redução na acurácia em relação à acurácia obtida nos experimentos com as Imagens 1, 2 e 3. A falha que mais contribuiu para o aumento do  $RMSE_{Eixo}$  é ilustrada na circunferência desenhada na parte inferior esquerda da Figura 49, em que o algoritmo permite o desvio do eixo para uma via de acesso. As outras três circunferências mostram as áreas em que ocorreram os erros de completude.

#### 5.4.6 Experimento usando a IMAGEM 5

Nesse experimento, o foco é a verificação da influência do tamanho das subimagens geradas pelo processo de subdivisão da imagem original. Para tanto, foi escolhida uma imagem que apresentasse a feição estrada com desafios, tais como obstrução por árvores, variação radiométrica, curvas e cruzamentos.

Todos os outros parâmetros foram mantidos constantes, variando apenas o valor ou tamanho de  $T_j$ . Os tamanhos usados para  $T_j$  nessa pesquisa foram escolhidos empiricamente, porém com base em duas premissas: (a) o valor  $T_j$  não pode ser muito grande porque possibilita a existência de mais uma feição linear, e isso pode levar ao erro, uma vez que o método escolhe apenas uma delas como verdadeira; e (b) a magnitude dessa variável não pode ser muito pequena a ponto de não cobrir toda a pista de rolamento da estrada e, adicionalmente, acarretar um aumento do esforço computacional.

Tendo em vista as premissas descritas acima, com apoio em experimentos, foram escolhidos os seguintes valores para  $T_j$ : 13, 15, 17 e 19 *pixels*. Os resultados para os quatro casos podem ser vistos na Figura 50.

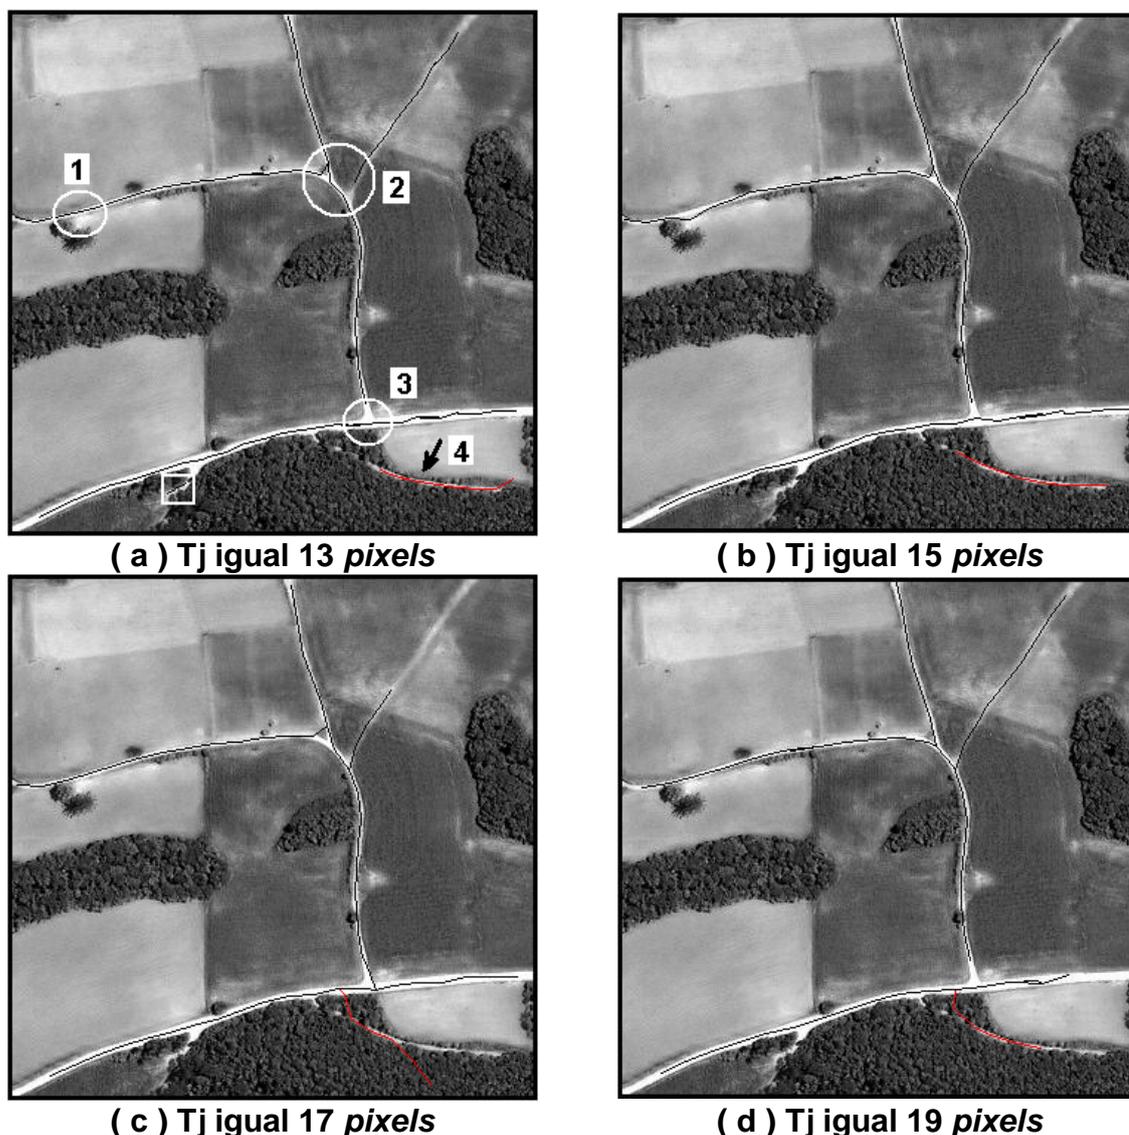


Figura 50 - Eixos detectados na IMAGEM 5 usando abordagem automática

Verificando visualmente os eixos detectados e apresentados nas Figuras 50a, 50b, 50c e 50d, podem ser percebidas variações significantes. Na Figura 50a são apontadas e numeradas quatro áreas onde são focadas as discussões. No ponto 1 ocorreu falha apenas no resultado usando Tj igual 15 *pixels*. A presença de uma mancha de solo exposto, presente na referida área, foi ignorada nos experimentos usando os demais tamanhos de Tj.

Os cruzamentos existentes no ponto 2 apresentaram falhas em três dos quatro casos analisados, sendo, portanto, o caso com Tj igual 19 *pixels*, o único resultado visualmente acurado.

No ponto 3, apenas no caso com Tj igual a 17 *pixels* é que ocorreu a conexão entre os diferentes eixos. Mas, é visível, nessa conexão, que não ocorreu uma boa qualidade geométrica. Na estrada apontada no ponto 4, não ocorreu completeza em nenhum dos casos, isto é, os eixos detectados representam apenas parte da verdadeira estrada. Visualmente, a configuração com Tj igual a 15 *pixels* apresentou o melhor resultado. Em todos os outros casos, ocorreram falhas consideráveis nos eixos detectados, principalmente na estrada apontada no ponto 4. Adicionalmente, no caso com 19 *pixels* ocorreu uma falha na detecção do eixo da estrada vicinal principal e, no caso com 13 *pixels*, foram detectados segmentos de reta que extrapolam os eixos das estradas existentes, como ilustrado no retângulo no canto inferior esquerdo da Figura 50a.

Os valores dos erros de completeza, correção e RMSEixo, medidos nos quatro casos, podem ser vistos na Tabela 8.

Tabela 8 - Qualidade dos eixos detectados com abordagem automática usando a IMAGEM 5

Eixos Detectados	Medidas de Acurácia		
	Completeza	Correção	RMS
<b>Raio = 13 <i>pixels</i></b>	0,786	0,850	0,798
<b>Raio = 15 <i>pixels</i></b>	0,781	0,887	0,706
<b>Raio = 17 <i>pixels</i></b>	0,693	0,851	1,881
<b>Raio = 19 <i>pixels</i></b>	0,732	0,900	0,891

A maior influência no RMSEixo é diretamente relacionada com detecção do eixo da estrada obstruída por árvores ou sombras de árvores, no ponto 4. Isto é,

quanto maior o desvio do eixo naquela região, maior o RMSEixo medido. O caso com  $T_j$  igual 15 *pixels* apresentou menor desvio, portanto, o menor RMSEixo.

Os resultados obtidos, em termos de completeza e correção, usando raios com 13 e 15 *pixels*, são semelhantes. Os principais erros ocorridos nessas imagens podem ser vistos nos pontos 1 e 2.

Pode-se verificar no último experimento, raio com 19 *pixels*, o melhor índice de correção em relação aos outros experimentos, entretanto, os valores dos índices completeza e RMSEixo medidos são modestos. O experimento usando o raio de 17 *pixels* apresentou os piores resultados em todos os índices.

Pode-se concluir por esse experimento que o melhor resultado é inerente ao objetivo do operador. Por exemplo, se o operador deseja obter bons resultados nos cruzamentos terá que usar valores maiores para  $T_j$  (no caso apresentado,  $T_j=19$  *pixels*), entretanto, se a acurácia geométrica geral for mais importante, ter-se-á que usar valores médios para  $T_j$ , no caso desse exemplo,  $T_j=15$  *pixels*.

#### 5.4.7 Resumo

Nessa seção, o objetivo é detectar eixos de estradas vicinais por meio de uma abordagem automática. Para tanto, são executadas, previamente, a detecção de segmentos sementes e a medida da largura das pistas de rolamento. Os segmentos semente são detectados usando a transformada Radon. Os resultados obtidos com essa transformada são mais facilmente interpretados em imagens com uma única feição linear. Buscando atender a essa premissa, antes da aplicação dessa transformada a imagem original é subdividida em recortes ou subimagens. A técnica de busca por segmentos retos é realizada em imagens digitais de alta resolução e é um processo iterativo. A validação dos resultados, advindos dos algoritmos propostos, foi realizada com base nas imagens de referência, já apresentadas. O julgamento da acurácia foi computado com base nos três índices citados na seção 4.7. De acordo com os resultados encontrados, a qualidade geométrica dos eixos detectados é satisfatória, com módulos *subpixels*. Contudo, em alguns casos o erro foi maior que um *pixel*, dependendo da quantidade e do tipo de obstruções na pista de rolamento das estradas.

## 5.5 CONTRIBUIÇÃO DA INTEGRAÇÃO DE DADOS ALTIMÉTRICOS

Os valores do parâmetro  $T$ , usados nesses experimentos, foram 0,8 e 0,56, para cada uma das funções objetivo; o tamanho da janela ( $T_j$ ) usado foi de 11 *pixels*, e os valores dos coeficientes  $a$ ,  $b$ ,  $c$  e  $f$ , da função objetivo (equação 21), foram 0,3, 0,2, 0,2 e 0,3, respectivamente; e os coeficientes  $a$  e  $b$ , da primeira função objetivo, não foram alterados. Ressalta-se que todos os parâmetros foram definidos empiricamente.

Para fins de comparação, foram realizados dois experimentos. O primeiro usando apenas a imagem digital, de acordo com a abordagem apresentada na seção 4.4 e, o segundo, usando essa mesma imagem digital, juntamente com os dados LASER, acordando com a metodologia proposta na seção 4.5. Os resultados são ilustrados nas Figuras 51 e 52.

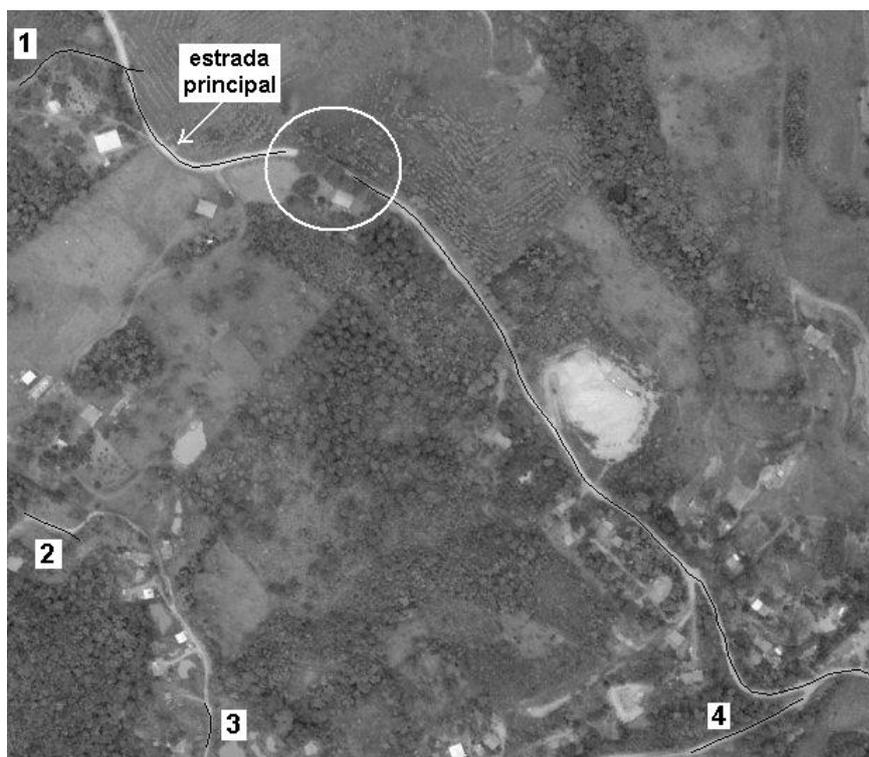


Figura 51 - Resultado usando somente imagem digital



Figura 52 - Resultado usando imagem e dado LASER

Os eixos 1 e 4, detectados usando apenas a imagem digital (Figura 51), não foram detectados usando a imagem integrada com o dado LASER. Por outro lado, os eixos 2 e 3 foram detectados em ambos os casos. O eixo 3 foi detectado com maior comprimento usando os dados integrados, contudo, o erro também foi maior. O que se pode observar é que a integração da informação dos dados LASER à imagem digital não auxilia na detecção de eixos de estradas estreitas, como são os casos dos eixos 1, 2, 3 e 4. Todavia, no processo de detecção de eixos de estradas com maior largura (estrada principal mostrada na Figura 51), a informação altimétrica do dado LASER é fundamental na superação de obstáculos como sombras e/ou coberturas da pista por árvores (circunferência branca na Figura 51).

A análise quantitativa foi realizada de duas formas: considerando todos os eixos detectados e considerando apenas o eixo da estrada principal. Os valores dos erros medidos podem ver vistos na Tabela 9.

Tabela 9 - Qualidade dos eixos detectados

	<b>Imagem Digital</b>		<b>Imagem e Dado LASER</b>	
	<b>Todos eixos</b>	<b>Eixo principal</b>	<b>Todos eixos</b>	<b>Eixo principal</b>
<b>RMSEixo</b>	1,056	0,784	1,594	0,878
<b>Completeza</b>	0,734	0,779	0,675	0,855
<b>Correção</b>	0,843	0,854	0,767	0,807

O RMSEixo calculado revela uma menor qualidade geométrica dos eixos detectados com auxílio da informação dos dados LASER, em ambos os casos. Levando em consideração apenas a imagem digital, a completeza é maior quando analisados todos os eixos, contudo, se considerado apenas o eixo da estrada principal, esse valor é ligeiramente superior usando os dados integrados. Isso confirma a afirmação feita em parágrafos anteriores de que o dado LASER não contribui na detecção de eixos de estradas estreitas.

O comprimento total de eixos detectados erroneamente, considerando ambos os casos, todos os eixos e eixo principal, é menor usando apenas a imagem digital. Isto é, a integração com o dado LASER aumentou o total de eixos detectados erroneamente.

### 5.5.1 Resumo

A integração de dados digitais, no processo de extração automática ou semi-automática de feições lineares ou não, tem sido explorada e, em consenso, recomendada como promissora. Tendo por base experimentos realizados em seções anteriores desse trabalho, é sabido que as informações presentes em uma imagem digital, isoladamente, não são suficientes para detectar eixos de estradas vicinais, em sua totalidade. Exemplos de falhas desses algoritmos estão em trechos das estradas em que existem obstruções, tais como oclusões por sombra e/ou pela própria árvore. A informação altimétrica pode ser uma saída para solucionar esse problema, dado que, no MDT (Modelo Digital do Terreno), as árvores são excluídas, permanecendo a informação da superfície da estrada. Portanto, nessa seção, é explorada a integração de dado LASER e imagem digital como *input* para a realização dessa tarefa, em uma abordagem automática. A busca por segmentos candidatos a estradas é realizada pelos algoritmos propostos na seção 4.2 do presente estudo. Adicionalmente, é proposto um modelo matemático que complementa a função objetivo proposta na mesma seção supracitada. O Modelo proposto leva em consideração conceitos como RMS, ajustamento de observações e menor distância entre ponto e plano. Os resultados mostram que é um tema

interessante. Mas, o número inexpressivo de experimentos não permitiu maiores conclusões a respeito da verdadeira contribuição do dado LASER; embora seja visível uma contribuição importante desses dados, na superação de um obstáculo ocasionado pela presença de árvores sobre a pista de rolamento da estrada analisada. A avaliação do método é realizada tanto qualitativa quanto quantitativamente. A segunda análise é realizada por meio dos índices RMSEixo, completeza e correção.

## 5.6 EXTRAÇÃO DE PISTAS DE ROLAMENTO DE ESTRADAS VICINAIS

Nessa seção, é realizada uma análise apenas visual, uma vez que discussões acerca da acurácia quantitativa dos eixos detectados já foram realizadas em seções anteriores. Portanto, o estudo realizado nessa seção é um complemento da avaliação da qualidade dos eixos detectados.

### 5.6.1 Extração de pistas de estradas a partir das IMAGENS 1, 2 e 3

As estradas extraídas na IMAGEM 1, por meio dos três métodos propostos, são ilustradas na Figura 53.

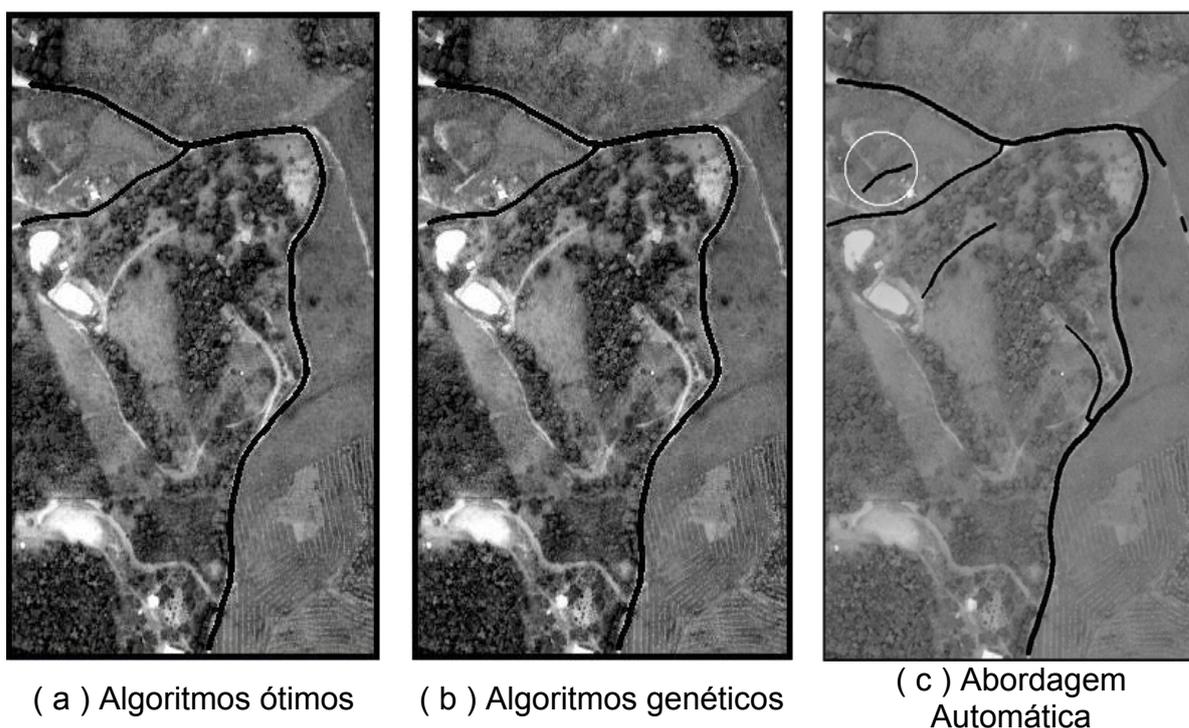


Figura 53 - Estradas extraídas usando a IMAGEM 1

Na Figura 53c é evidenciada a presença das vias de acessos detectadas na abordagem automática. Considerando as estradas 1 e 2, não são percebidas, visualmente, diferenças consideráveis entre os resultados nas três imagens.

Os produtos resultantes, usando a IMAGEM2, encontram-se na Figura 54.



( a ) Algoritmos ótimos



( b ) Algoritmos genéticos



( c ) Abordagem Automática

Figura 54 - Estradas extraídas usando a IMAGEM 2

Embora tenham ocorrido algumas falhas, as estradas extraídas são bem parecidas com as estradas de referência apresentadas anteriormente.

As estradas extraídas usando a Imagem são ilustradas na Figura 55.



( a ) Algoritmos ótimos



( b ) Algoritmos genéticos



( c ) Abordagem Automática

Figura 55 - Estradas extraídas usando a IMAGEM 3

As falhas causadas por obstáculos, tais como obstrução da pista de rolamento por árvores, usando algoritmos ótimos, são identificadas por circunferências desenhadas na Figura 55a. Por outro lado, falhas por negligência e erros por extrapolação na abordagem automática são ilustradas por circunferências na Figura 55c. Enfim, as principais falhas, usando a IMAGEM 3, foram devidas às obstruções parciais ou totais da pista de rolamento. Portanto, a pista de rolamento não foi extraída em sua totalidade.

### 5.6.2 Resumo

Nesta seção, o objetivo é a extração das pistas de estradas vicinais existentes em uma imagem digital para uma análise puramente visual. Esse processo é complementar aos métodos semi-automáticos e automáticos, usando tanto as medidas de larguras ( $w$ ) quanto os eixos detectados. O método é baseado na rotulação dos *pixels* vizinhos aos eixos detectados, tendo como limite ou margem a metade da largura ( $w/2$ ). Os resultados obtidos com os métodos semi-automáticos, em imagens que apresentam estradas com poucas obstruções, mostraram-se bastante satisfatórios. O método automático apresentou melhores resultados em imagens maiores, mesmo existindo diferentes obstáculos. Porém, os algoritmos mostraram ser sensíveis aos obstáculos que cobrem totalmente a pista de rolamento. Nos exemplos apresentados, pode ser vista uma obstrução total em trechos da pista de rolamento. Essas obstruções são causadas principalmente por árvores.

## 5.7 COMPARAÇÃO COM OUTROS MÉTODOS

Uma verificação mais apurada dos resultados é realizada por meio de uma comparação com outros métodos propostos. O fato de os experimentos terem sido realizados em áreas de estudos diferentes pode caracterizar a comparação como não efetiva, entretanto, é uma forma de avaliar, em termos de módulo ou magnitude, os erros cometidos pelo método proposto. Apenas o método automático é comparado, uma vez que os métodos usados na comparação são, também, automáticos; e a medida da qualidade geométrica é retirada da comparação, pois trata-se de medidas calculadas de forma diferente, embora retratem a mesma medida. Isto é, no presente estudo foi usado o método proposto, denominado RMSEixo. A Tabela 10 apresenta um resumo dos erros cometidos pelo método proposto. São apresentados os erros cometidos usando as Imagens 1, 2, 3, 4 e a IMAGEM 6 integrada com o dado LASER.

Tabela 10 - Qualidade dos eixos detectados com os métodos propostos

<b>Dados Usados</b>	<b>Completeza</b>	<b>Correção</b>
<b>IMAGEM 1 (aérea)</b>	0,899	0,923
<b>IMAGEM 2 (aérea)</b>	0,860	0,905
<b>IMAGEM 3 (IKONOS)</b>	0,787	0,915
<b>IMAGEM 4 (IKONOS)</b>	0,753	0,898
<b>IMAGEM 6 (aérea) + LASER</b>	0,675	0,767

### 5.7.1 Comparação com o método de Wiedemann (2003)

Wiedemann (2003) apresenta um estudo para extração de estradas no meio rural, ou seja, extração de estradas vicinais usando apenas imagens (fotos) aéreas. Portanto, os resultados de Wiedemann (2003) são comparados aos resultados obtidos com as imagens aéreas 1 e 2. Os valores de acurácia encontrados por esse autor estão apresentados na Tabela 11.

Tabela 11 - Resultados obtidos por Wiedemann (2003)

<b>Dados \ Métodos</b>	<b>Completeza</b>	<b>Correção</b>
<b>Imagem Aérea \ Método 1</b>	0,858	0,985
<b>Imagem Aérea \ Método 2</b>	0,893	0,980

Embora sejam pequenas as diferenças (>8%), os dois métodos propostos por Wiedemann (2003) apresentaram melhores resultados em termos de correção, quando comparados com os resultados obtidos pelo método proposto. Isso implica que o método proposto detectou uma quantidade maior de segmentos que não são eixos de estradas vicinais. Por outro lado, o método proposto, usando a IMAGEM 1, detectou uma maior quantidade de segmentos que coincidem, verdadeiramente, com o eixo de referência, se comparado aos dois métodos de Wiedemann (2003).

#### 5.7.2 Comparação com o método de ZHANG (2006)

No trabalho elaborado por Zhang (2006), foram usadas tanto imagens aéreas quanto cenas IKONOS. Como foram realizados vários experimentos, apenas os melhores resultados obtidos por Zhang (2006) foram extraídos para comparação com o método proposto nessa pesquisa. Assim, foram selecionados os maiores valores de completeza e correção entre os experimentos realizados com imagens aéreas e, posteriormente, entre os experimentos realizados com cenas IKONOS. A Tabela 12 apresenta os valores desses índices.

Tabela 12 - Melhores resultados obtidos por Zhang (2006)

<b>Dados Usados</b>	<b>Completeza</b>	<b>Correção</b>
<b>Imagens Aéreas</b>	0,720	0,630
<b>Cenas IKONOS</b>	0,590	0,380

Tanto em completeza quanto em correção, o método proposto foi superior ao método de Zhang (2006). Contudo, ressalta-se que as imagens usadas por Zhang (2006) apresentam trechos de vilas e/ou edificações. Esse tipo de feição é um grande desafio para métodos de detecção de estradas que têm por base parâmetros como resposta radiométrica. A maioria dos tipos de telhados apresenta resposta radiométrica similar à feição estrada.

Um fato curioso que ocorreu nos dois métodos foi o decréscimo da acurácia em função do dado usado. Em experimentos com imagens aéreas, ambos os métodos, o de Zhang (2006) e o proposto, apresentaram maiores valores para completeza e correção. Uma explicação pode ser devida à melhor resolução espacial (apesar de a imagem aérea ter sido reamostrada).

### 5.7.3 Comparação com o método de Clode et al. (2007)

Usando somente dados LASER (altimétricos e intensidade), Clode et al. (2007) propuseram um método para detecção de estradas em duas áreas distintas. Os resultados obtidos, em ambas as áreas, são apresentados na Tabela 13.

Tabela 13 - Resultados obtidos por Clode et al. (2007)

<b>Dados Usados</b>	<b>Completeza</b>	<b>Correção</b>
<b>LASER (Área 1)</b>	0,840	0,750
<b>LASER (Área 2)</b>	0,810	0,800

Apesar de ter usado somente dados LASER, os resultados obtidos por Clode et al. (2007), na área 2, foram superiores aos resultados obtidos com a metodologia proposta. Contudo, a correção medida na área 1, no experimento de Clode et al. (2007), foi inferior ao valor medido nos resultados obtidos com o método proposto.

A inferioridade do método proposto em relação ao método de Clode et al. (2007), no que tange à qualidade dos eixos detectados, não invalida o método proposto, uma vez que poucos experimentos foram efetuados.

## CAPÍTULO 6 – CONCLUSÃO

### 6.1 CONSIDERAÇÕES FINAIS

Dentro do objetivo geral dessa pesquisa, foram propostos cinco outros específicos, os quais são tratados nas considerações finais. Adicionalmente são discutidos sobre outras contribuições apresentadas nessa tese, tais como: o método proposto para mensurar larguras de estradas vicinais, em imagens digitais; o modelo proposto para avaliação de eixos de estradas detectados.

Pelo fato de não existir uma metodologia para avaliação da qualidade dessa medida (Normas Técnicas), pode-se dizer que os resultados obtidos são de boa qualidade, uma vez que os erros inerentes ao processo são menores que a unidade trabalhada, o *pixel*. Contudo, as larguras das estradas determinadas pelo método são usadas tanto no método para detectar eixos quanto no processo de extração de estradas, e pequenas variações nessa medida afetam diretamente os resultados dos referidos métodos.

Uma desvantagem do método proposto para determinar as medidas de larguras de estradas é a sensibilidade às obstruções totais ou parciais das pistas de rolamento. Todavia, como essa medida é realizada sobre os segmentos semente esse problema é contornado, pois, nos casos semi-automáticos, os segmentos semente são fornecidos pelo operador e, obviamente, são selecionados em locais estratégicos e, nos casos automáticos, os segmentos semente são selecionados pelo método proposto, em que são eleitos os melhores candidatos.

O modelo desenvolvido para avaliação da qualidade geométrica de eixos detectados é verificado por meio de experimento com dados hipotéticos, como ilustra o exemplo apresentado na seção 4.7. Os resultados são condizentes com o objetivo, pois medem exatamente o valor médio de afastamento do eixo detectado em relação ao eixo de referência, portanto, pode-se dizer que o método é promissor.

Três dos cinco objetivos específicos tratam do desenvolvimento de uma função objetivo/aptidão que seja eficiente e robusta tanto em métodos semi-automáticos quanto em automáticos, para detecção de eixos de estradas vicinais em imagens digitais.

A função objetivo, ou de aptidão proposta, é composta por três parâmetros. Um desses parâmetros analisa a correlação linear existente entre dois perfis transversais de estradas, o outro parâmetro verifica a similaridade radiométrica entre dois perfis transversais e o terceiro parâmetro mede a direção entre os segmentos detectados como eixo de estrada.

Com base na análise geométrica dos eixos detectados em imagens digitais, por meio dos erros medidos, pode-se dizer que os três parâmetros são eficientes na execução da tarefa proposta, pois apresentaram erros menores que a unidade trabalhada, o *pixel*. Entretanto, verificou-se que a função objetivo pode ainda ser melhorada com inserção de mais informações, principalmente para superar obstáculos, tais como a oclusão total da pista por outra feição. Porém, isso não invalida o método proposto, ao contrário, frente às magnitudes dos erros medidos e das dificuldades de extração da feição estrada vicinal, podem ser considerados satisfatórios os resultados encontrados.

Outro motivo para considerar os resultados satisfatórios, principalmente no que tange à qualidade geométrica, é o fato de não existir uma Norma Técnica que padronize essa medida. Portanto, produtos com erros *subpixels*, em imagens de alta resolução, podem ser produtos de boa qualidade. Ressalta-se que a qualidade de um mapa rodoviário depende da resolução da imagem usada e do projeto ao qual está inserido, por exemplo, um mapa rodoviário para fins turísticos não exige alta precisão.

A avaliação do objetivo específico, que trata do método proposto para detecção automática de segmentos semente, em imagens digitais, é inerente à qualidade dos eixos detectados; assim, como os eixos detectados apresentaram pequenos erros geométricos, isso implica que os segmentos semente selecionados são bem representativos das respectivas estradas.

É audacioso afirmar que a integração de dado LASER e imagem digital, contribui, ou não, com a detecção de eixos de estradas vicinais, tendo por base apenas nos experimentos realizados. Mas, pode ser verificado, a partir do experimento realizado, que a função objetivo proposta mostrou-se promissora. Esse é um tema que merece estudos mais aprofundados, uma vez que diversas outras situações podem ser analisadas. Por exemplo, a existência de pontes, rios e oclusões mais extensas, causadas por sombras ou árvores.

Finalmente, o processo de extração automática de pistas de rolamento de estradas vicinais, em imagens digitais, usando as larguras e eixos detectados, embora simples, permite processar a delimitação da pista de forma iterativa e não exige grande esforço computacional. Todavia, ressalta-se que a demanda computacional não foi avaliada nessa pesquisa. Uma desvantagem notória nesse processo de extração de pistas é que variações da largura, ao longo de um segmento, não são percebidas, permanecendo a largura medida no segmento semente.

Em uma análise geral verificou-se que os métodos propostos, embora tenham falhado em alguns casos, são promissores.

## 6.2 RECOMENDAÇÕES

Recomenda-se:

- a) Aplicar a metodologia proposta em imagens que tenham sido eliminados os obstáculos causadores de oclusão da pista de rolamento.
- b) A integração de dados de outras fontes é uma opção interessante para algoritmos como os genéticos, que podem avaliar várias informações ao mesmo tempo, cruzando-as e retornando informações desejadas.
- c) Usar mais intensamente os dados LASER em situações diferentes daquelas apresentadas nesse trabalho.
- d) Explorar além dos dados altimétricos, as imagens intensidade e/ou hipsométrica geradas pelo sistema LASER.
- e) Realizar outros testes com o modelo proposto para avaliação da qualidade de eixos detectados.
- f) Implementar método adaptativo para o cálculo do melhor raio R.

## REFERÊNCIA BIBLIOGRÁFICA

ALHARTHY, A.; BETHEL, J. Automated Road Extraction From Lidar Data. In: ASPRS congress, 2003, **Annual Conference Proceedings**. Unpaginated CD-ROM.

ARGIALAS, D. P.; MAVRANTZA, O. D. Comparison of Edge Detection and Hough Transform Techniques for the Extraction of Geologic Features. In: ISPRS CONGRESS, 35., 2004, Istanbul. **Proceedings**. Istanbul: ISPRS, 2004. Paper 376 (Unpaginated).

AVERBUCH, A.; DONOHO, D. L.; COIFMAN, R. R.; ISRAELI, M.; SHKOLNISKY, Y.; 2001. **Fast Slant Stack: A Notion of Radon Transform for Data in Cartesian Grid which is Rapidly Computable, Algebraically Exact, Geometrically Faithful and Invertible**. Disponível em: <http://wwwstat.stanford.edu/~donoho/Reports/2001/FastSlantStack.pdf>. Acesso em: 19/10/2007. Reports.

BACHER, U.; MAYER, H. Automatic Road Extraction From IRS Satellite Images in Agricultural and Desert Areas. In: ISPRS CONGRESS, 35., 2004, Istanbul. **Proceedings**. Istanbul: ISPRS, 2004. Paper 423 (Unpaginated).

BALTSAVIAS, E. A comparison between photogrammetry and LASER scanning. **Journal of Photogrammetry & Remote Sensing (ISPRS)**, n. 54. p. 83-94, 1999.

BASKAKOV, A.; GAGARIN, S.; KALINKEVITCH, A.; KUTUZA, B.; TEREKHOV, V. Simultaneous radiometric and radar altimetric measurements of sea microwave signatures. **Journal of Oceanic Engineering (IEEE)**. v. 9, n. 5, p. 325-328, 1984.

BAUMGARTNER, A.; STEGER, C.; MAYER, H.; ECKSTEIN, H. W.; EBNER, H. Automatic Road Extraction Based on Multi-Scale, Grouping, and Context. **Photogrammetric Engineering & Remote Sensing (PE&RS)**, v. 65, n. 7, p. 777-785. 1999.

BOLTON, S. K. **Famous Men of Science**. (traduzido por J. C. Ribeiro Penna). Ed. 19ª, São Paulo: Universitária (USP), 1944.

BOOCHS, F.; HEINZ, G. Precise Target Location Using Image Matching Technique. In: INTERNATIONAL CONFERENCE SIGNAL AND IMAGE PROCESSING (IASTED), 1999, Nassau. **Proceedings**. Nassau: IASTED, 1999.

CANDEIAS, A. L. B.; SILVA, E. A. Extração de Estradas de uma Imagem ETM+ Landsat Usando Morfologia Matemática. In: CONGRESSO BRASILEIRO DE CADASTRO TÉCNICO MULTIFINALITÁRIO (COBRAC), 2004, Florianópolis. **Anais**. Florianópolis: COBRAC/UFSC, 2004.

CANNY, J. A computational approach to edge detection. **Transactions on pattern analysis and machine intelligence (IEEE)**, p. 679-698. 1986.

CASTRO, C. A. A. **Estudo da Técnica de Anti-Pó com Emulsão de Xisto em Pavimentos para Baixo Volume de Tráfego**. 174 f. Dissertação (Mestrado em

Engenharia Civil) – Departamento de Engenharia Civil, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2003.

CENTENO, J. A. S. **Sensoriamento Remoto e Processamento de Imagens Digitais**. Curitiba: Universidade Federal do Paraná (UFPR), 2004.

CLODE, S.; KOOTSOOKOS, P.; ROTTENSTEINER, F. The Automatic Extraction of Roads from LIDAR data. In: ISPRS CONGRESS, 35., 2004, Istanbul. **Proceedings**. Istanbul: ISPRS, 2004. Paper 272 (Unpaginated).

CLODE, S.; ROTTENSTEINER, F.; KOOTSOOKOS, P.; ZELNIKER, E. Detection and Vectorization of Roads from Lidar Data. **Photogrammetric Engineering & Remote Sensing (PE&RS)**, v. 73, n. 5, p. 517-535. 2007.

COPELAND, A. C.; RAVICHANDRAN, G.; TRIVEDI, M. M. Localized Radon transformbased detection of ship wakes in SAR images. **Transactions on Geosciences Remote Sensing (IEEE)**. v. 33, n. 1, p. 35-45, 1995.

CRAMER, H.; WANIELIK, G. Road Border Detection and Tracking in non Cooperative Areas with a LASER Radar System. In: PROCEEDINGS OF GERMAN RADAR SYMPOSIUM (GRS), 2002, Bonn. **Proceedings**. Bonn: GRS, 2002.

CROSILLA, F.; BEINAT, A.; VISINTINI, D.; FICO, B.; SOSSAI, E. Likelihood and Accuracy Analyses of 3D Building Models from Airborne LASER Data. In: WORKSHOP ITALY-CANADA, 2005, Padova. **Proceedings**. Padova: Workshop, 2005.

CROSTA, A. P. **Processamento Digital de Imagens de Sensoriamento Remoto**. Campinas: IG/UNICAMP, 1993.

CRUZ, A. V. **Estradas Vicinais: Abordagem Pedológica, Geotécnica, Geométrica e de Serventia de Dois Trechos Rodoviários não Pavimentados no Campus da UFV – MG**. 133 f. Dissertação (Mestrado em Engenharia Civil) - Departamento de Engenharia Civil, Universidade Federal de Viçosa, Viçosa, 2005.

CUDAHY, T. J.; WHITBOURN, L. B.; CONNOR, P. M.; MASON, P.; PHILLIPS, R. N. Mapping Surface Mineralogy and Scattering Behavior Using Backscattered Reflectance from a Hyperspectral Midinfrared Airborne CO<sub>2</sub> LASER System (MIRACO<sub>2</sub>LAS). **Transactions on Geoscience and Remote Sensing (IEEE)**. v. 37, n. 4, p. 2019-2034, 1999.

DALMOLIN, Q. **Ajustamento por Mínimos Quadrados**. Curitiba: Imprensa Universitária (UFPR), 2004.

DAL POZ, A. P. e AGOURIS, E. Extração Semi-Automática de Rodovias Usando Programação Dinâmica. In: II WORKSHOP BRASILEIRO DE GEOINFORMÁTICA (GEOINFO), 2000, São Paulo. **Anais**. São Paulo: GEOINFO, 2000.

DAL POZ, A. P.; AGOURIS, P. Um Algoritmo de Otimização Global para a Extração de Rodovias em Imagens Digitais. **Revista Brasileira de Cartografia**. Rio de Janeiro, n. 53, p. 65-76, 2001.

DAL POZ, A. P. Extração de Feições Rodoviárias em Imagens Digitais: Metodologias Desenvolvidas pelo GP-F&VC. **Boletim de Ciências Geodésicas**. Curitiba, v. 11, n. 2, p.179-199, 2005.

DAL POZ, A. P. Extração Semi-Automática de Rodovias Através de uma Metodologia Cooperativa. **Boletim de Ciências Geodésicas**. Curitiba, v. 11, n. 2, p.179-199. 2001.

DAL POZ, A. P.; GALO, M.; FERREIRA, F. M. Metodologias Para a Avaliação Geométrica de Feições Cartográficas. In: II Colóquio Brasileiro de Ciências Geodésicas, 2001, Curitiba. **Anais**. Curitiba: CBCG/UFPR, 2001. CD-ROM.

DAL POZ, A. P.; GYFTAKIS, S.; AGOURIS, P. Semi-Automated Road Extraction: Comparison of Methodologies and Experiments. In: Annual Conference (ASPRS), 2000, Washington. **Proceedings**. Washington: ASPRS, 2000. CD-ROM.

DAL POZ, A. P. **Processo automático para reconhecer rodovias georeferenciadas de uma fotografia aérea digitalizada**. Oronto: Universidade do Maine/EUA, 2000. Relatório de Pós-Doutorado (FAPESP). 225 f.

DAL POZ, A. P.; SILVA, M. A. O. Active testing and edge analysis for road centreline extraction. In: International Archives for Photogrammetry and Remote Sensing, 2002, Amsterdã. **Proceedings**. Amsterdã: ISPRS, 2002. p. 44-47.

DNIT. Departamento Nacional de Infra-Estrutura de Transportes. Diretoria de Planejamento e Pesquisa. Coordenação Geral de Planejamento e Programação de Investimentos. **Terminologias Rodoviárias Usualmente Utilizadas**. Brasília, 2007.

EIDENBENZ, C.; KÄSER, C.; BALTSAVIAS, E. Atomi-Automated Reconstruction of Topographic Objects from Aerial Images Using Vectorized Map Information. In: IAPRS, 33., 2000, Amsterdam. **Proceedings**. Amsterdam: IAPRS, 2000.

EKER, B.; SEKER, D. Z. Semi-Automatic Road Extraction from Digital Aerial Photographs. In: ISPRS CONGRESS, 35., 2004, Istanbul. **Proceedings**. Istanbul: ISPRS, 2004. Paper 324 (Unpaginated).

FRANCESCHETTI, G.; IODICE, A.; MADDALUNO, S.; RICCIO, D. Effect of Antenna Mast Motion on X-SAR/SRTM Performance. **Transactions on Geosciences and Remote Sensing (IEEE)**. v. 38, n. 5, p. 2361-2372, 2000.

GEMAEL, C. **Introdução ao ajustamento de observações: aplicações geodésicas**. Curitiba: Universidade Federal do Paraná (UFPR), 1994.

GOLDBERG, D.E. **Genetic Algorithms in Search, Optimization and Machine Learning**. New York: Addison-Wesley, 1989.

GOMES, O. F. M.; FEITOSA, R. Q.; COUTINHO, H. L. C. Sub-Pixel Unpaved Roads Detection in Landsat Images. In: ISPRS CONGRESS, 35., 2004, Istanbul. **Proceedings**. Istanbul: ISPRS, 2004. Paper 448 (Unpaginated).

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. 2nd ed., Upper Saddle River / NJ: Prentice Hall. 2002.

HALL, O.; FALORNI, G.; BRAS, R. L. Characterization and Quantification of Data Voids in the Shuttle Radar Topography Mission Data. **Transactions on Geosciences and Remote Sensing (IEEE)**. v. 2, n. 2. p. 740-744, 2005.

HANCOCKA, J.; LANGERN, D.; HEBERTA, M.; SULLIVANB, R.; INGIMARSONB, D.; HOFFMANB, E.; METTENLEITERC, M.; FROEHLICH, C. Active LASER Radar for High-Performance Measurements. In: INTERNATIONAL CONFERENCE ON ROBOTICS & AUTOMATION (ICRA), 1998, Leuven. **Proceedings**. Leuven: ICRA, 1998. p.1465-1470.

HASEGAWA H. A Semi Automatic Road Extraction Method for Alos Satellite Imagery. In: ISPRS CONGRESS, 35., 2004, Istanbul. **Proceedings**. Istanbul: ISPRS, 2004. Paper 303 (Unpaginated).

HATGER, C.; BRENNER, C. Extraction of Road Geometry Parameters form LASER Scanning and existing Databases. In: WORKSHOP 3-D RECONSTRUCTION FROM AIRBORNE LASERSCANNER AND INSAR DATA, 34., 2003, Dresden. **Proceedings**. Dresden: International Archives Photogrammetry and Remote Sensing (IAPRS), 2003.

HATGER, C. On the Use of Airborne LASER Scanning Data to Verify and Enrich Road Network Features. In: WORKSHOP "LASER SCANNING 2005", 2005, Enschede. **Proceedings**. Enschede: ISPRS, 2005.

HATGER, C. **Road Extraction by Use of Airborne LASER Scanner Data**. Hannover: IKG.UNI, 2006. Disponível em: [www.ikg.uni-hannover.de/publikationen/publikationen/2006](http://www.ikg.uni-hannover.de/publikationen/publikationen/2006). Acesso em: 31/12/2006.

HEIPKE, C.; MAYER, H.; WIEDEMANN, C.; JAMET, O. Evaluation of automatic road extraction. In: INTERNATIONAL ARCHIVES OF PHOTOGRAMMETRY AND REMOTE SENSING (IAPRS), 32., 1997. **Proceedings**. IAPRS, 1997. p. 47-56.

HU, X.; TAO, C. V. Automatic Extraction of Main Road Centerlines from High Resolution Satellite Imagery Using Hierarchical Grouping. **Photogrammetric Engineering & Remote Sensing (PE&RS)**. v. 73, n. 9, p. 1049-1056, 2007.

JEON, B. K.; JANG, J. H.; HONG, K. S. Road Detection in Spaceborne SAR Images Using a Genetic Algorithms. **Transactions on Geoscience and Remote Sensing (IEEE)**, v. 40, n. 1, p. 22-29, 2002.

KERSTING, A. P. B.; CENTENO, J. A. S. FELSKY FILHO, C. E. Geração de Modelo Tridimensional do Teatro do Paiol a partir do Emprego da Tecnologia LASER Scanner Terrestre. In: CONGRESSO BRASILEIRO DE CADASTRO TÉCNICO

MULTIFINALITÁRIO (COBRAC), 2004, Florianópolis. **Anais**. Florianópolis: COBRAC/UFSC, 2004.

KIRCHNER, A.; HEINRICH T. Model Based Detection of the Road Boundaries with a LASER Scanner. In: INTERNATIONAL CONFERENCE ON INTELLIGENT VEHICLES (ICIV), 1998, Stuttgart. **Proceedings**. Stuttgart: ICIV, 1998.

LEGRESY, B.; REMY, F. Using the temporal variability of satellite radar altimetric observations to map surface properties of the Antarctic ice sheet. **Journal of Glaciology**. v. 44, n. 147, p.197-206, 1998.

LICHTI, D. D.; GORDON, S. J.; STEWART, M. P.; FRANKE, J.; TSAKIRI, M. Comparison of Digital Photogrammetry and LASER Scanning. In: INTERNATIONAL WORKSHOP ON SCANNING CULTURAL HERITAGE RECORDING, 2002, Corfu. **Proceedings**. Corfu: CIPA WG 6, 2002. p. 39-44.

LILLESAND, T. M.; KIEFER, R. W. **Remote Sensing and Image Interpretation**. New York: John Wiley & Sons, 2000.

LIU, H.; LI, J.; CHAPMAN, M. A. Automated Road Extraction from Satellite Imagery Using Hybrid Genetic Algorithms and Cluster Analysis. **Journal of Environmental Informatics**. p. 40-47, 2003.

LOPES, H. S. Algoritmos Genéticos em Projetos de Engenharia: Aplicações e Perspectivas Futuras. In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE (SBAI), 1999, São Paulo. **Anais**. São Paulo: SBAI, 1999. p. 64-74.

LUTTON, E.; MARTINEZ, P. A Genetic Algorithm for the Detection of 2D Geometric Primitives in Images. In: 2th INTERNATIONAL CONFERENCE ON PATTERN RECOGNITION (IAPR), 1., 1994, Jerusalem. **Proceedings**. Jerusalem: IAPR, 1994. p. 526-528.

MARTINS, M. A. R.; FELIX, D.; KERSTING, A. P. B. Análise do Padrão de Exatidão Cartográfica (PEC) para Dados Provenientes do Sistema LASER - ALTM 2050. In: CONGRESSO BRASILEIRO DE CADASTRO TÉCNICO MULTIFINALITÁRIO (COBRAC), 2004, Florianópolis. **Anais**. Florianópolis: COBRAC/UFSC, 2004.

MAYER, H.; STEGER, C. Scale-Space Events and Their Link to Abstraction for Road Extraction. **Journal of Photogrammetry and Remote Sensing (ISPRS)**. v. 53, p. 62-75, 1998.

MENDES, T. S. G.; FAZAN, A. J.; DAL POZ, A. P. Delineamento de estradas vicinais usando técnicas de correlação de imagem. **Boletim de Ciências Geodésicas**. Curitiba, v. 10, n. 2, p. 159-176, 2004.

MICHALEWICZ, Z. **Genetic Algorithms + Data Structures = Evolution Programs**. New York: Springer, 1999.

MIKHAIL, E. M. and Ackermann, F. **Observations and Least Squares**. New York: IEP/Dun-Donnelly Publisher, 1976.

MIRMEHDI, M.; PALMER, P. L.; KITTLER, J. Robust Line Segment Extraction Using Genetic Algorithms. In: 6th INTERNATIONAL CONFERENCE ON IMAGE PROCESSING AND ITS APPLICATIONS. 1997. **Proceedings**. IEEE Publications, 1997. p.141-145.

MITCHELL, M. **An Introduction to Genetic Algorithms**. Cambridge: Mit Press, 1997.

MOHAMMADZADEH, A.; TAVAKOLI, A.; VALADAN ZOEJ, M. J. Automatic Linear Feature Extraction of Iranian Roads from High Resolution Multi-Spectral Satellite Imagery. In: ISPRS CONGRESS, 35., 2004, Istanbul. **Proceedings**. Istanbul: ISPRS, 2004. Paper 371 (Unpaginated).

MOREIRA, M. A. **Fundamentos de Sensoriamento Remoto e Metodologia de Aplicação**. Viçosa: Universidade Federal de Viçosa (UFV), 2003.

MURPHY, L. M. Linear feature detection and enhancement in noisy images via the Radon transform. **Pattern Recognition Letters**. n. 4, p. 279-284, 1986.

NOVO, E. M. L. M. **Sensoriamento Remoto - Princípios e Aplicações**. São Paulo: Edgard Blucher Ltda, 1992.

OLIVEIRA, R. M. S. **Extração de Rodovias Usando Snakes**. 78 f. Dissertação (Mestrado em Ciências Cartográficas) - Faculdade de Ciências e Tecnologia, Universidade Estadual do Estado de São Paulo, Presidente Prudente, 2003.

OLIVEIRA, J. A.; DUTRA, L. V.; RENNÓ, C. D. Aplicação de Métodos de Extração e Seleção de Atributos para Classificação de Regiões. In: XII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2005, Goiânia. **Anais**. Goiânia: SBSR/INPE, 2005. p. 4201-4208.

PARADELLA, W. R.; SANTOS, A. R.; VENEZIANI, P.; CUNHA, E. S. P. Radares Imageadores nas Geociências: Estado da Arte e Perspectivas. **Revista Brasileira de Cartografia**. Rio de Janeiro, v. 1, n. 57, p. 53-62, 2005.

PAULINO, W. R. **Biologia Atual (Genética-Evolução-Ecologia)**. São Paulo: Ática S.A, 1995.

PEREZ-JIMENEZ, A. J.; PEREZ-CORTES, J. C. Genetic Algorithms for Linear Feature Extraction. **Pattern Recognition Letters (ELSEVIER)**. p. 1508-1514, 2006.

PERKINS, S.; THEILER, J.; BRUMBY, S. P.; HARVEY, N. R.; PORTER, R. GENIE: A Hybrid Genetic Algorithm for Feature Classification in Multi-Spectral Images. In: SPIE, 4120., 2000. **Proceedings**. SPIE, 2000. p. 52-62.

POON, J.; FRASER, C. S.; CHUNSUN, Z.; LI, Z.; GRUEN, A. Quality Assessment of Digital Surface Models Generated from IKONOS Imagery. **The Photogrammetric Record**. v. 20, n. 110, p. 162-171, 2005.

RICHARDS, J. A.; JIA, X. **Remote Sensing Digital Image Analysis – an Introduction**. Austrália: Springer, 1998.

RIETDORF, A.; GIELSDORF, F.; GRUENDIG, L. A Concept for the Calibration of Terrestrial LASER Scanners. In: INGENIO AND FIG REGIONAL CENTRAL AND EASTERN EUROPEAN CONFERENCE ON ENGINEERING SURVEYING, 2004, Bratislava. **Proceedings**. Bratislava: INGENIO, 2004.

ROCHA, E. M. F. da; BARROS, R. S. de; CRUZ, C. B. M. Uso de Modelos Digitais de Elevação de Imagens de Radar para Extração de Feições Topográficas – Um Estudo de Caso Maciço da Tijuca, Vertente Baía da Guanabara. In: XII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2005, Goiânia. **Anais**. Goiânia: SBSR/INPE, 2005. p. 4469-4471.

RODRÍGUEZ, E.; MORRIS, C. S.; BELZ, J. E.; CHAPIN, E. C.; MARTIN, J. M.; DAFFER, W.; HENSLEY, S. **An Assessment of the SRTM Topographic Products**. California: Jet Propulsion Laboratory (JPL), 2005. Technical Report.

SANTOS, D. R.; TOMMASELLI, A. M. G. Extração Semi-Automática de Edificações com Análise do MDE. **Boletim de Ciências Geodésicas**. Curitiba, v. 8, n. 1, p. 25-45, 2002.

SANTOS, J. C.; OLIVEIRA, J. R. F.; DUTRA, L. V. Uso de Algoritmos Genéticos na Seleção de Atributos para Classificação de Regiões. In: VII SIMPÓSIO BRASILEIRO DE GEOINFORMÁTICA (SBG), 2005, Campos do Jordão. **Anais**. Campos do Jordão: SBG, 2005.

SILVA, C. R. **Uso de Algoritmos Genéticos como Redutor de Dimensionalidade na Classificação de Imagens Hiperespectrais**. 85 f. Dissertação (Mestrado em Ciências Geodésicas) – Departamento de Geomática, Universidade Federal do Paraná, Curitiba, 2006.

SILVA, J. F. C.; BARBOSA, R. L.; GALLIS, R. B. A.; PEREIRA, L. M. Avaliação da Qualidade da Detecção de Bordas em uma Seqüência de Imagens de Ruas e Rodovias. **Revista Brasileira de Cartografia**. Rio de Janeiro, v. 2, n. 56, p. 96-103, 2004.

SILVA, M. A. O.; DAL POZ, A. P. Detecção e Reconstrução Automática de Junções de Rodovia em Imagens Digitais de Cenas Rurais. **Boletim de Ciências Geodésicas**. Curitiba, v. 9, n. 2, p.263-281, 2003.

STEGER, C. An Unbiased Detector of Curvilinear Structures. In: TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE (TPAMI), 20., 1998. **Proceedings**. TPAMI/IEEE, 1998. p. 113-125.

SUNA, G.; RANSONB, K. J.; KHARUKC, V. I.; KOVACS, K. Validation of surface height from shuttle radar topography mission using shuttle LASER altimeter. **Remote Sensing of Environment**. v. 88, p. 401-411, 2003.

SWAIN, P. H.; DAVIS, M. S. **Remote Sensing the Quantitative Approach**. New York: McGraw-Hill, 1978.

TOCH, C. K. Direct Platform Orientation os Multisensor data Acquisition Systems. In: SYMPOSIUM ON GIS - BETWEEN VISIONS AND APPLICATIONS, 1998, Stuttgart. **Proceedings**. Stuttgart: ISPRS, 1998. p.629-634.

TOFT, P. **The Radon Transform - Theory and Implementation**. 326 f. Thesis (Ph.D. in Mathematical Modelling) - Department of Mathematical Modelling, Technical University of Denmark, Denmark, 1996.

TORRE, V.; POGGIO, T. On Edge Detection. In: TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE, 8., 1986. **Proceedings**. IEEE, 1986. p.147-163.

TRUONG, N.; AGASSOUNON, W. Utilizing Biomimetic Image Processing to Rapidly Detect Rollover Threats. In: 25th ARMY SCIENCE CONFERENCE, TRANSFORMATIONAL ARMY SCIENCE & TECHNOLOGY (TAST), 2006, Orlando. **Proceedings**. Orlando: TAST, 2006.

VALADAN ZOEJ, M. J.; MOKHTARZADE, M. Road Detection From High Resolution Satellite Images Using Artificial Neural Networks. In: ISPRS CONGRESS, 35., 2004, Istanbul. **Proceedings**. Istanbul: ISPRS, 2004. Paper 104 (Unpaginated).

VALANIS, A.; TSAKIRI, M. Automatic Target Identification for LASER Scanners. Geo-Imagery Bridging Continents. In: XXth ISPRS CONGRESS, 35., 2004, Istanbul. **Proceedings**. Istanbul: ISPRS, 2004.

VALE, G. M. **Extração Semi-Automática do Eixo de Rodovia em Imagens de Média e Alta Resolução Usando Programação Dinâmica**. 115 f. Dissertação (Mestrado em Ciências Cartográficas) - Faculdade de Ciências e Tecnologia, Universidade Estadual do Estado de São Paulo, Presidente Prudente, 2003.

VENTURAS, S.; FLAOUNAS, I. **Study of Radon Transformation and Application of its Inverse to NMR**. Athenas, 2005. Disponível em: [http://cgi.di.uoa.gr/~ergal/mobio/05/proj2/Flaounas\\_Venturas\\_Final.doc](http://cgi.di.uoa.gr/~ergal/mobio/05/proj2/Flaounas_Venturas_Final.doc). Acesso em: 19/10/2007.

VENTURI, J. J. **Álgebra Vetorial e Geometria Analítica**. Curitiba: Universidade Federal do Paraná (UFPR), 1991.

VOSELMAN, G.; KNECHT, J. Road Tracing by Profile Matching and Kalman Filtering. In: ASCONA WORKSHOP ON AUTOMATIC EXTRACTION OF MAN-MADE OBJECTS FROM AERIAL AND SPACE IMAGES, 1995, Birkhäuser. **Proceedings**. Birkhäuser: Ascona, 1995. p. 255-264.

YOUNAN, N. H.; PONNALA, K.; ALAPATI, N. Edge Detection In Multispectral Imagery Via Maximum Entropy. In: 31st. INTERNATIONAL SYMPOSIUM ON REMOTE SENSING OF ENVIRONMENT (ISRSE) - Global Monitoring for Sustainability and Security, 2005, Saint Petersburg. **Proceedings**. Saint Petersburg: ISRSE, 2005.

WANG, L.; QIN, Q.; DU, S.; CHEN, D.; TAO, J. Road Extraction from Remote Sensing Image Based on Multi-resolution Analysis. In: 31st. INTERNATIONAL SYMPOSIUM ON REMOTE SENSING OF ENVIRONMENT (ISRSE) - Global Monitoring for Sustainability and Security, 2005, Saint Petersburg. **Proceedings**. Saint Petersburg: ISRSE, 2005.

WANG, Y. K.; FAN, K. C. Applying Genetic Algorithms on Pattern Recognition: An Analysis and Survey. In: TRANSACTIONS ON GEOSCIENCES AND REMOTE SENSING (TGRS), 1996. **Proceedings**. IEEE/ TGRS, 1996. p. 740-744.

WESSEL, B.; 2004. Road Network Extraction from SAR Imagery Supported by Context Information. In: ISPRS CONGRESS, 35., 2004, Istanbul. **Proceedings**. Istanbul: ISPRS, 2004. Paper 295 (Unpaginated).

WIEDEMANN, C. 2003. **External Evaluation of Road Networks**. ISPRS Archives, Vol. XXXIV, Part 3/W8, Munich, 17.-19. Sept.

WIEDEMANN, C.; HINZ, S. Automatic Extraction and Evaluation of Road Networks from Satellite Imagery. In: INTERNATIONAL ARCHIVES OF PHOTOGRAMMETRY AND REMOTE SENSING, 32., 1999. **Proceedings**. IAPRS, 1999. p. 95-100.

WILSON, M. B.; DICKSON, S. Poppet: A Robust Boundary Detection and Tracking Algorithm. In: BRITISH MACHINE VISION CONFERENCE, 1999. **Proceedings**. BMVC, 1999. p. 352-361.

WU, C. H. **Automated Identification of Scanned Contour Information for Digital Elevation Models**. 121 f. Thesis (Doctorate in Surveying Engineering) - University of Maine, Orono, 1993.

WUTKE, J. D **Métodos para Avaliação de um Sistema LASER Scanner Terrestre**. 95 f. Dissertação (Mestrado em Ciências Geodésicas) - Setor de Ciências da Terra, Universidade Federal do Paraná, Curitiba, 2006.

ZANIN, R. B. **Metodologia Automática para Extração de Cruzamentos de Rodovias em Imagens de Alta Resolução**. 121 f. Dissertação (Mestrado em Ciências Cartográficas) - Faculdade de Ciências e Tecnologia, Universidade Estadual do Estado de São Paulo, Presidente Prudente, 2004.

ZHANG, Q. **Automated Road Network Extraction from High Spatial Resolution Multi-Spectral Imagery**. 156 f. Thesis (Doctorate in Geomatics Engineering) - Department of Geomatics Engineering, University of Calgary, Calgary, 2006.

# Livros Grátis

( <http://www.livrosgratis.com.br> )

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)  
[Baixar livros de Literatura de Cordel](#)  
[Baixar livros de Literatura Infantil](#)  
[Baixar livros de Matemática](#)  
[Baixar livros de Medicina](#)  
[Baixar livros de Medicina Veterinária](#)  
[Baixar livros de Meio Ambiente](#)  
[Baixar livros de Meteorologia](#)  
[Baixar Monografias e TCC](#)  
[Baixar livros Multidisciplinar](#)  
[Baixar livros de Música](#)  
[Baixar livros de Psicologia](#)  
[Baixar livros de Química](#)  
[Baixar livros de Saúde Coletiva](#)  
[Baixar livros de Serviço Social](#)  
[Baixar livros de Sociologia](#)  
[Baixar livros de Teologia](#)  
[Baixar livros de Trabalho](#)  
[Baixar livros de Turismo](#)