



UNIVERSIDADE ESTADUAL PAULISTA
Faculdade de Ciências e Tecnologia
CAMPUS DE PRESIDENTE PRUDENTE

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS CARTOGRÁFICAS

AIRTON MARCO POLIDORIO

**DETECÇÃO DE ELEMENTOS DA PAISAGEM
URBANA EM IMAGENS AÉREAS
MULTIESPECTRAIS**

A faint, stylized graphic of a globe with several overlapping, light-colored orbital or elliptical lines around it, centered behind the title text.

PRESIDENTE PRUDENTE

2007



UNIVERSIDADE ESTADUAL PAULISTA
Faculdade de Ciências e Tecnologia
CAMPUS DE PRESIDENTE PRUDENTE

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS CARTOGRÁFICAS

AIRTON MARCO POLIDORIO

**DETECÇÃO DE ELEMENTOS DA PAISAGEM
URBANA EM IMAGENS AÉREAS
MULTIESPECTRAIS**

Tese apresentada ao PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS CARTOGRÁFICAS da Faculdade de Ciências e Tecnologia da UNESP, como parte dos requisitos exigidos para obtenção do título de Doutor em Ciências Cartográficas.

Orientadores:

Prof. Dr. Nilton Nobuhiro Imai

Prof. Dr. Antonio Maria Garcia Tommaselli

PRESIDENTE PRUDENTE

2007

P825d Polidorio, Airton Marco.
Detecção de elementos da paisagem urbana em imagens aéreas multiespectrais / Airton Marco Polidorio. – Presidente Prudente : [s.n.], 2007
178 f. : il.

Tese (doutorado) - Universidade Estadual Paulista, Faculdade de Ciências e Tecnologia

Orientador: Nilton Nobuhiro Imai
Co-Orientador: Antonio Maria Garcia Tommaselli
Bancas: José Alberto Quintanilha, Flávio Bortolozzi, Maria de Lourdes Bueno Trindade Galo e Júlio Hasegawa

1. Cartografia. 2. Fotogrametria. 3. Sensoriamento Remoto. 4. Processamento de Imagens - Técnicas digitais. 5. Morfologia Matemática. 6. Sistemas de Informação Geográfica. I. Polidorio, Airton Marco. II. Imai, Nilton Nobuhiro. III. Tommaselli, Antonio Maria Garcia VI. Título.

CDD (18.ed.) 623.71

Ficha catalográfica elaborada pelo Serviço Técnico de Biblioteca e Documentação
UNESP – FCT – Campus de Presidente Prudente

DEDICATÓRIA

Não sei se somos teimosos em persistir ou se vocês nos deixaram muito cedo. Só sei que a saudade é grande demais. Aos meus irmãos Antonio Carlos Polidório (1957* – 2002⁺) e Sueli Aparecida Polidório (1961* – 2003⁺), *in memoriam*.

AGRADECIMENTOS

Deus seja louvado.

O autor deseja externar seus sinceros agradecimentos:

- Aos funcionários da UNESP, em especial ao pessoal da Secretaria da Pós-Graduação e ao pessoal do Departamento de Cartografia;
- Ao pessoal do Departamento de Informática da Universidade Estadual de Maringá;
- Aos professores do Programa de Pós-Graduação em Ciências Cartográficas da UNESP;
- Aos colegas pós-graduandos da FCT/UNESP;
- À CAPES pelo apoio concedido através de uma bolsa PICDT;
- Às empresas: IGN – Institut Géographique National, DLR – Deutshes Zentrum fur Luft-und Raumfahrt, Digimapas, Engemap – Engenharia e Mapeamento; Multiespectral, ESTEIO – Engenharia de Aerolevantamentos, Leica Geosystem, Vexcel Corporation e Intergraph's Z/I Imaging pela concessão dos dados usados neste trabalho.

Reservo agradecimentos especiais para meu irmão de fé Dante pelo incentivo e apoio. Para Clélia Franco pela amizade, pela colaboração e pela empreitada que juntos assumimos. Para o amigo do peito Franklin César Flores pelas inúmeras discussões sobre Morfologia Matemática, Processamento de Imagens, pelos cinco trabalhos que juntos publicamos, pelas cervejas e momentos de conversa fiada.

Aos amigos e parceiros de todas as horas, professor Imai e professor Tommaselli, com os quais tive a honra e o privilégio de desenvolver este e outros trabalhos. Por não encontrar palavras adequadas de agradecimento ao tratamento e dedicação que me dispensaram, deixo para vocês o meu mais humilde agradecimento. Obrigado!

Para meus pais. Obrigado!

Para meus filhos Daniel e Augusto e minha esposa Luisa, antes devo lhes pedir desculpas pelos momentos de ausência, de nervosismo e de baixo-astrol que lhes “proporcionei”. Amo vocês! Obrigado!

RESUMO

Atividades inerentes à Fotogrametria e ao Sensoriamento Remoto que utilizam dados extraídos de imagens aéreas estão em constante desenvolvimento, seja pela inserção de novas tecnologias relacionadas com a aquisição desses dados, seja pelo estabelecimento de novos conceitos e métodos que permitem computá-los, transformando-os em informação. Essa transformação, dados-informação, é feita por vários processos entre os quais, alguns foram automatizados e outros necessitam da supervisão e da interação com um operador humano para realizá-la. Um dos fatores que impede a completa automação desses processos é a falta de conhecimento contextual prévio sobre a natureza dos dados. A detecção e a discriminação de elementos específicos em dados de imageamento aéreo constituem uma forma de adquirir esse conhecimento contextual. Este trabalho aborda esse problema de detectar e discriminar elementos específicos em dados de imageamento aéreo de regiões urbanas, especificamente: sombras, vegetação verde, corpos d'água, rodovias pavimentadas e telhados de edificações, bem como discriminar a natureza da elevação desses elementos, de forma que seja possível inferir se determinado elemento tem elevação própria, ou se está ao nível da superfície do terreno. Para detectar esses elementos, este trabalho propõe novas métricas, na forma de índices de realce, para tratar os elementos de interesse. Os resultados produzidos por esses índices são usados na detecção e discriminação desses elementos que compõem a paisagem urbana. Este trabalho explora diversos conjuntos de dados como: imagens coloridas, imagens infravermelhas e dados de elevação. Os dados de imageamento usados foram adquiridos por oito sensores construídos com o uso de diferentes tecnologias. Essas aquisições foram feitas em ambientes e condições atmosféricas diversificadas e, a maior parte desses dados corresponde a regiões urbanas densas, situadas sobre relevo acidentado. Para propor soluções aos problemas abordados, este trabalho integra várias áreas do conhecimento humano, principalmente: Fotogrametria, Sensoriamento Remoto, Processamento Digital de Imagens e Morfologia Matemática.

Palavras-chave: Fotogrametria; Sensoriamento Remoto; Processamento de Imagens; Detecção de Elementos; Paisagem Urbana Aérea.

ABSTRACT

Inherent activities to Photogrammetry and Remote Sensing that use data acquired by aerial images are in constant development, due the useful of new hardware to acquire such data, or due the establishment of new concepts and methods that allow computing those data, transforming them in information. That transformation, data-to-information, is done by several processes. Some of these processes were automated and others still need the supervision and the interaction with a human operator to accomplish that transformation. A factor that obstruct the complete automation those processes is the lack of previous context-knowledge about the nature of those data. The detection and the discrimination of specific elements in aerial imaging data constitute a way to acquire that context-knowledge. This work approaches the problem related with the automatic detection and discrimination of specific elements in aerial imaging data of urban areas, specifically: shadows; green vegetation; water bodies, paved-roads and roofs buildings, besides determining the nature of the elevation of those elements, in order to allow infer if a specific element has own elevation, or it is been at the level of the terrain surface. In order, to detect those elements, this work proposes new metrics, designed as enhancements indexes, to treat the elements of interest. The results produced by those indexes are used by process to improve the detection and discrimination those elements that compose aerial urban scenery. This work explores several groups of data as: colored images, infrared images and elevation data. The imaging data of used in this work were acquired for eight sensors assembled by the use of different technologies. Those acquisitions were made in divesified environments and atmospheric conditions. The most of those data corresponds to dense urban areas, located on a place with complex topography. In order, to propose solutions to the approached problems, this work integrates several areas of the human knowledge, mainly: Photogrammetry, Remote Sensing, Digital Image Processing and Mathematical Morphology.

Keywords: Photogrammetry; Remote Sensing; Image Processing; Elements Detection; Aerial Urban Scenery.

SUMÁRIO

CAPÍTULO I	16
INTRODUÇÃO	16
1.1 MOTIVAÇÃO E JUSTIFICATIVA.....	17
1.2 OBJETIVOS.....	21
1.3 DADOS USADOS NOS EXPERIMENTOS E ESTUDOS DE CASOS	23
1.4 ESTRUTURA DESTE TRABALHO	24
CAPÍTULO II	26
ESTADO DA ARTE: DETECÇÃO DE ELEMENTOS EM IMAGENS AÉREAS	26
2.1 VEGETAÇÃO	27
2.2 SOMBRA.....	32
2.3 EDIFICAÇÕES.....	38
2.4 EXTRAÇÃO DO MDT ATRAVÉS DO MDS	49
2.5 CORPOS D'ÁGUA.....	55
2.6 RODOVIAS	60
2.7 MÉTRICAS DE AVALIAÇÃO DA QUALIDADE DA DETECÇÃO	61
CAPÍTULO III	63
MATERIAIS E MÉTODOS	63
3.1 MATERIAIS	63
3.2 CARACTERÍSTICAS DOS DADOS	64
3.3 COMPLEXIDADE DE CONTEXTO NOS DADOS USADOS	69
3.4 METODOLOGIA	71
3.4.1 <i>Detecção de Elementos em Imagens Coloridas</i>	72
3.4.2 <i>Detecção de Elementos em Imagens Coloridas e Infravermelhas</i>	74
3.4.3 <i>Detecção de Telhados de Edificações e Normalização do MDS</i>	75
3.5 FUNÇÃO DE TRANSFORMAÇÃO DE DIMENSÃO	76
CAPÍTULO IV	78
DESENVOLVIMENTO METODOLÓGICO E ESTUDOS DE CASOS	78
4.1 DETECÇÃO DE ELEMENTOS DA PAISAGEM URBANA USANDO IMAGENS COLORIDAS.....	78
4.1.1 <i>Extração de Atributos</i>	78
4.1.2 <i>Pré-segmentação de Sombras e Vegetação</i>	82
4.1.3 <i>Segmentação e Discriminação de Vegetação</i>	84
4.1.4 <i>Segmentação e Discriminação de Sombras</i>	85
4.1.5 <i>Outros Resultados</i>	89
4.1.6 <i>Análise dos Resultados</i>	94
4.2 DETECÇÃO DE ELEMENTOS EM IMAGENS INFRAVERMELHAS E COLORIDAS.....	97
4.2.1 <i>Extração de Atributos</i>	99
4.2.1.1 <i>sSI – Índice Espectral de Sombras</i>	100
4.2.1.2 <i>nRI – Índice Normalizado de Rodovias</i>	100
4.2.1.3 <i>mWI – Índice Espectral de Água Máximo</i>	103
4.2.2 <i>Análise e Visualização do Comportamento dos Índices</i>	104
4.2.3 <i>Discriminação e Detecção dos Elementos de Interesse</i>	109
4.2.3.1 <i>Detecção e Discriminação de Corpos d'água</i>	110
4.2.3.2 <i>Detecção e Discriminação de Sombras</i>	114
4.2.3.3 <i>Detecção de Marcadores de Rodovias</i>	115
4.2.3.4 <i>Detecção e Discriminação de Vegetação</i>	118
4.2.4 <i>Outros Resultados</i>	120
4.2.4.1 <i>Imagens IGN</i>	121
4.2.4.2 <i>Imagens HRSC-AX</i>	123
4.2.5 <i>Análise dos Resultados</i>	125
4.3 NORMALIZAÇÃO DO MDS E DETECÇÃO DE TELHADOS.....	130

4.3.1	<i>Os Marcadores</i>	131
4.3.2	<i>O Uso de Pontos de Sombras como Marcadores Externos</i>	131
4.3.3	<i>Normalização do MDS</i>	134
4.3.3.1	<i>Análise de Comportamento dos Pontos do MDS</i>	134
4.3.3.2	<i>Detecção das Regiões de Transição Sobre o MDS</i>	135
4.3.3.3	<i>Detecção de Pontos Críticos Sobre o MDS</i>	137
4.3.3.4	<i>Normalização do MDS</i>	138
4.3.3.5	<i>Determinação da Natureza da Elevação dos Pontos do MDS</i>	141
4.3.3.6	<i>Análise dos Resultados</i>	143
4.3.4	<i>Detecção de Telhados de Edificações</i>	144
4.3.4.1	<i>Tratamento de Pontos Oriundos de Corpos d'Água e Rodovias</i>	145
4.3.4.2	<i>Tratamento de Pontos Oriundos de Sombras</i>	145
4.3.4.3	<i>Tratamento de Pontos Oriundos de Vegetação</i>	145
4.3.4.4	<i>Tratamento de Pontos Oriundos do MDS</i>	146
4.3.4.5	<i>Tratamento Final dos Marcadores</i>	147
4.3.4.6	<i>Aplicação da Segmentação Morfológica Watershed com Marcadores</i>	151
4.3.4.7	<i>Análise dos Resultados</i>	155
CAPÍTULO V		158
CONSIDERAÇÕES FINAIS		158
5.1	PROPOSTAS PARA TRABALHOS FUTUROS	159
5.2	CONCLUSÕES.....	162
REFERÊNCIAS BIBLIOGRÁFICAS		165

LISTA DE FIGURAS

FIGURA 1.1 EXEMPLO DE RECONSTRUÇÃO DE TELHADOS DE EDIFICAÇÕES. ADAPTADO DE TAILLANDIER E DERICHE (2004).....	17
FIGURA 1.2 EXEMPLO DE VARIABILIDADE NOS ATRIBUTOS DOS TELHADOS DE EDIFICAÇÕES.....	21
FIGURA 2.1 DETECÇÃO DE COPAS DE ÁRVORES POR CORRELAÇÃO DE IMAGENS. (A) PADRÃO DE REFERÊNCIA. (B) IMAGEM ORIGINAL (INFRAVERMELHA). (C) RESULTADO ALCANÇADO. ADAPTADO DE STITELER (2000).	28
FIGURA 2.2 DETECÇÃO DE COPAS DE ÁRVORES POR CORRELAÇÃO DE IMAGENS. (A) PADRÃO DE REFERÊNCIA 13x13 SUAVIZADO. (B) IMAGEM ORIGINAL (INFRAVERMELHA FALSA-COR). (C) RESULTADO ALCANÇADO. ADAPTADO DE QUACKENBUSH <i>ET AL.</i> (2000).	28
FIGURA 2.3 DETECÇÃO DE COPAS DE ÁRVORES POR PROCESSAMENTO DE MDS. (A) MDS ORIGINAL. (B) RESULTADO ALCANÇADO MOSTRADO SOBRE A IMAGEM INFRAVERMELHA. ADAPTADO DE MAYER (2000).	29
FIGURA 2.4 DETECÇÃO E CLASSIFICAÇÃO DE ESPÉCIES DE ÁRVORES. (A) IMAGEM RGB ORIGINAL. (B) MARCADORES DEFINIDOS PELOS MÍNIMOS REGIONAIS. (C) RESULTADO DA SEGMENTAÇÃO <i>WATERSHED</i> COM UNIÃO DE REGIÕES ADJACENTES SIMILARES. (D) RESULTADO DA CLASSIFICAÇÃO. ADAPTADO DE KANDA <i>ET AL.</i> (2004).	30
FIGURA 2.5 ILUSTRAÇÃO DOS EFEITOS ATMOSFÉRICOS SOBRE UMA ÁREA INTENSAMENTE SOMBREADA.	33
FIGURA 2.6 DETECÇÃO E RESTAURAÇÃO DE ÁREAS SOMBREADAS. ADAPTADO DE TSAI (2006).	37
FIGURA 2.7 DETECÇÃO DE REGIÕES SOMBREADAS PELO FILTRO DA MÉDIA MÓVEL NUMA IMAGEM INFRAVERMELHA (ADS40). OS RESULTADOS EM VERMELHO (TELHADOS ESCUROS) E EM AZUL (CORPOS D'ÁGUA) SÃO FALSO-POSITIVOS. ADAPTADO DE MANDHAVAN <i>ET AL.</i> (2004).....	37
FIGURA 2.8 RESULTADO DA DETECÇÃO DE CANDIDATOS A EDIFICAÇÕES PRODUZIDAS PELA ESTRATÉGIA DE NIEDERÖST. ADAPTADO DE NIEDERÖST (2000).	40
FIGURA 2.9 RESULTADOS PRODUZIDOS PELA TÉCNICA INTRODUZIDA POR QIU. ADAPTADO DE QIU <i>ET AL.</i> (2004).	42
FIGURA 2.10 DETECÇÃO DE EDIFICAÇÕES USANDO DADOS LIDAR. (A) E (B) IMAGENS DERIVADAS DOS DADOS DO PRIMEIRO E ÚLTIMO RETORNO, RESPECTIVAMENTE (FALSA-COR). (C) RESULTADO DO PRIMEIRO MENOS O ÚLTIMO RETORNO. (D) RESULTADO DA FILTRAGEM LOCAL. (E) MDS MODIFICADO E NORMALIZADO. ADAPTADO DE ALHARTHY E BETHEL (2002).	44
FIGURA 2.11 IMAGENS DE DADOS LIDAR ADQUIRIDOS PELO SENSOR OPTTECH ALTM 1210. PRIMEIRO (INTENSIDADE), SEGUNDO (REFLECTÂNCIA) E ÚLTIMO (INTENSIDADE) RETORNO, RESPECTIVAMENTE. ADAPTADO DE ELBERINK E MAAS (2000).	45
FIGURA 2.12 FUSÃO DE DADOS ENTRE IMAGENS LIDAR E MULTIESPECTRAL PARA DETECTAR EDIFICAÇÕES. (A) IMAGEM PANCROMÁTICA. (B) IMAGEM DO MDE EXTRAÍDA DE DADOS LIDAR (PRIMEIRO RETORNO) (C) DETALHE DO nMDS. (D) DETALHE DO nMDS SUBTRAÍDO DA VEGETAÇÃO DETECTADA. ADAPTADO DE VÖGTLE E STEINLE (2000).	45
FIGURA 2.13 FUSÃO DE DADOS ENTRE IMAGENS LIDAR E MULTIESPECTRAL PARA DETECTAR EDIFICAÇÕES. (A) IMAGEM IKONOS PSM INFRAVERMELHA FALSA-COR. (B) MDS LIDAR FALSA-COR. (C) RESULTADO DA MODELAGEM GEOMÉTRICA POR POLÍGONOS CONVEXOS. (D) RESULTADO FINAL. ADAPTADO DE SOHN (2004).	47
FIGURA 2.14 TIPOS DE ERROS COMETIDOS NA DETECÇÃO DE ELEVAÇÕES DEVIDO À PRECISÃO DE COBERTURA DO MDS. ADAPTADO DE SCHIEWE (2000).	49
FIGURA 2.15 ILUSTRAÇÃO DO PROCESSO DE GERAÇÃO DO nMDS.	50
FIGURA 2.16 EXEMPLO DE NORMALIZAÇÃO DO MDS. (A) IMAGEM ADQUIRIDA NA FAIXA DO INFRAVERMELHO PRÓXIMO PELA CÂMARA HRSC-AX. (B) MDS CORRESPONDENTE EXTRAÍDO DAS IMAGENS ESTÉREO-FOTOMÉTRICAS (HRSC-AX). (C) MDT EXTRAÍDO DO MDS. (D) nMDS GERADO.	53
FIGURA 2.17 EXEMPLOS DE APLICAÇÃO DO FILTRO MORFOLÓGICO DE ABERTURA SOBRE UM MDS COM SUPERFÍCIE DE RELEVO NÃO SUAVE PARA DERIVAR O nMDS. (A) MDS ORIGINAL. (B) ABERTURA DO MDS POR UM ELEMENTO ESTRUTURANTE RETANGULAR 7x7. (C) ABERTURA DO MDS POR UM ELEMENTO ESTRUTURANTE RETANGULAR 101x101.	53
FIGURA 2.18 COMPORTAMENTO ESPECTRAL DA ÁGUA LIMPA, SOLO EXPOSTO SECO E VEGETAÇÃO VERDE. ADAPTADO DE LILLESAND E KIEFER (2000).	56
FIGURA 2.19 IMAGEM ORIGINAL LANDSAT TM – COMPOSIÇÃO COLORIDA R3G2B1. (B) <i>NDWI</i> PROPOSTO POR GAO (1996). (C) <i>NDWI</i> PROPOSTO POR McFEETERS (1998). (D) <i>WWI</i> PROPOSTO POR POLIDORIO <i>ET AL.</i> (2004). (E) <i>NDVI</i> PROPOSTO POR ROUSE <i>ET AL.</i> (1973). (F) RESULTADO DA SOMA COM SATURAÇÃO (B4 + B5).	58

FIGURA 2.20 RESULTADO DA DETECÇÃO DE NUVENS, ÁREAS SOMBREADAS E CORPOS D'ÁGUA EM IMAGENS LANDSAT (R3G2B1). ADAPTADO DE POLIDORIO <i>ET AL.</i> (2005A).....	59
FIGURA 2.21 RESULTADO DA CORREÇÃO RADIOMÉTRICA EM IMAGEM CBERS (R3G2B1). ADAPTADO DE POLIDORIO <i>ET AL.</i> (2005B).....	59
FIGURA 2.22 AUMENTO DE CONTRASTE ENTRE ELEMENTOS ARTIFICIAIS E NATURAIS EM IMAGENS COLORIDAS DIGITALIZADAS. (A) IMAGEM COLORIDA ORIGINAL. (B) IMAGEM PRODUZIDA POR VALORES <i>DOA</i> . (C) IMAGEM PRODUZIDA POR VALORES <i>NANDA</i>	59
FIGURA 3.1 IMAGEM COLORIDA ADQUIRIDA PELA CÂMARA IGN. PRESENÇA DE RUÍDO NAS BORDAS DE TRANSIÇÃO ALTAS.....	66
FIGURA 3.2 PROBLEMAS COM O IMAGEAMENTO DE ALVOS MÓVEIS E PELA DIFERENÇA DO ÂNGULO DE VISADA DOS SENSORES EM RELAÇÃO AO SISTEMA DE IMAGEAMENTO DA CÂMARA HRSC-AX.....	66
FIGURA 3.3 PROBLEMAS DE REGISTRO DOS DADOS DE IMAGEAMENTO E ACURÁCIA DO MDS.....	68
FIGURA 3.4 DISTORÇÃO NA FORMA GEOMÉTRICA DE ALGUMAS EDIFICAÇÕES, PROVOCANDO DESLOCAMENTO E INSERÇÃO DE BORDAS (IMAGEM PANCROMÁTICA – HRSC-AX).....	69
FIGURA 3.5 IMAGEM COLORIDA (IGN) QUE ILUSTRA A COMPLEXIDADE DA CENA E DIFICULDADE PARA DETECTAR SOMBRAS E VEGETAÇÃO.....	70
FIGURA 3.6 COMPLEXIDADE INERENTE ÀS REGIÕES URBANAS DENSAS. IMAGEM PANCROMÁTICA ORTORRETIFICADA HRSC-AX COM GSD DE 50CM. VISTA PARCIAL (600x600M) DA REGIÃO URBANA DE SALVADOR.....	70
FIGURA 3.7 COMPLEXIDADE DO RELEVO. (A) MDS PARCIAL DA CIDADE DE SALVADOR (3x3KM) EXTRAÍDO DAS IMAGENS ESTÉREO-FOTOMÉTRICAS ADQUIRIDAS PELA CÂMARA HRSC-AX COM GSD DE 50CM. (B) DETALHE DO MDS (600x600M). (C) MDT CORRESPONDENTE AO DETALHE DO MDS.....	71
FIGURA 3.8 FLUXOGRAMA BÁSICO PARA DETECÇÃO E DISCRIMINAÇÃO DE SOMBRAS E VEGETAÇÃO USANDO IMAGENS COLORIDAS.....	73
FIGURA 3.9 FLUXOGRAMA BÁSICO PARA DETECÇÃO E DISCRIMINAÇÃO DE SOMBRAS, VEGETAÇÃO, CORPOS D'ÁGUA E MARCAS DE RODOVIAS USANDO IMAGENS COLORIDAS (RGB) E INFRAVERMELHAS.....	74
FIGURA 3.10 FLUXOGRAMA BÁSICO PARA DETECÇÃO DE TELHADOS DE EDIFICAÇÕES E NORMALIZAÇÃO DO MDS.....	76
FIGURA 4.1 EXEMPLO DE APLICAÇÃO DOS ÍNDICES. (A) IMAGEM COLORIDA ORIGINAL (IGN). (B) IMAGEM COLORIDA PADRONIZADA POR EQUALIZAÇÃO. (C) IMAGEM <i>DOA</i> . (D) IMAGEM <i>NANDA</i> . (E) IMAGEM <i>nSI</i> . (F) IMAGEM TEMÁTICA: VERMELHO (VEGETAÇÃO); AZUL E AMARELO (SOMBRAS).....	80
FIGURA 4.2 COMPORTAMENTO DOS ÍNDICES SOBRE CLASSES DE ALVOS (RESULTADOS APRESENTADOS COM ALARGAMENTO LINEAR DO HISTOGRAMA - H^S).....	83
FIGURA 4.3 HISTOGRAMA BI-MODAL COM 10 CLASSES DOS VALORES NORMALIZADOS DE $Nanda^N$ E A RESPECTIVA SEGMENTAÇÃO DAS CLASSES QUE CONTÊM CANDIDATOS À SOMBRA E VEGETAÇÃO.....	83
FIGURA 4.4 RESULTADOS OBTIDOS COM O MÉTODO PROPOSTO PARA SEGMENTAÇÃO E DISCRIMINAÇÃO DE VEGETAÇÃO E SOMBRAS. (A) IMAGEM COLORIDA ORIGINAL (HRSC-AX). (B) RESULTADO PRODUZIDO SEM OTIMIZAÇÃO DO PROCESSO DE SEGMENTAÇÃO DE SOMBRAS. (C) RESULTADO OBTIDO PELO PROCESSO DE SEGMENTAÇÃO DE SOMBRAS OTIMIZADO.....	88
FIGURA 4.5 FLUXOGRAMA DO PROCESSO DE OTIMIZAÇÃO DO VALOR DE LIMIAR USADO NA SEGMENTAÇÃO DE SOMBRAS.....	89
FIGURA 4.6 IMAGEM COLORIDA ORIGINAL (ADS40) E IMAGEM APRESENTANDO OS RESULTADOS PRODUZIDOS PELO MÉTODO PROPOSTO. SOMBRAS EM AZUL E VEGETAÇÃO EM VERMELHO.....	90
FIGURA 4.7 IMAGEM COLORIDA ORIGINAL (KODAK 14N) E IMAGEM APRESENTANDO OS RESULTADOS PRODUZIDOS PELO MÉTODO PROPOSTO. SOMBRAS EM AZUL E VEGETAÇÃO EM VERMELHO.....	90
FIGURA 4.8 IMAGEM COLORIDA ORIGINAL (RC-10) E IMAGEM APRESENTANDO OS RESULTADOS PRODUZIDOS PELO MÉTODO PROPOSTO. SOMBRAS EM AZUL E VEGETAÇÃO EM VERMELHO.....	91
FIGURA 4.9 IMAGEM COLORIDA ORIGINAL (DMC) E IMAGEM APRESENTANDO OS RESULTADOS PRODUZIDOS PELO MÉTODO PROPOSTO. SOMBRAS EM AZUL E VEGETAÇÃO EM VERMELHO.....	91
FIGURA 4.10 IMAGEM COLORIDA ORIGINAL (ULTRACAM) E IMAGEM APRESENTANDO OS RESULTADOS PRODUZIDOS PELO MÉTODO PROPOSTO. SOMBRAS EM AZUL E VEGETAÇÃO EM VERMELHO.....	92
FIGURA 4.11 IMAGEM COLORIDA ORIGINAL (RMKTOP 15) E IMAGEM APRESENTANDO OS RESULTADOS PRODUZIDOS PELO MÉTODO PROPOSTO. SOMBRAS EM AZUL E VEGETAÇÃO EM VERMELHO.....	93
FIGURA 4.12 (A) IMAGEM COLORIDA ORIGINAL (IGN). (B) RESULTADOS DA SEGMENTAÇÃO DE VEGETAÇÃO (VERMELHO) E SOMBRAS (AZUL) PELO MÉTODO DESTA TRABALHO. (C) RESULTADOS OBTIDOS PELO MÉTODO PROPOSTO POR TSAI (2006) (EM VERMELHO E EM AZUL) PARA DETECÇÃO DE SOMBRAS. OS RESULTADOS EM AZUL FORAM PRODUZIDOS PELO MÉTODO DESTA TRABALHO.....	96

FIGURA 4.13 IMAGEM RGB ORIGINAL (ADS40) E IMAGEM DOS RESULTADOS PRODUZIDOS PELO MÉTODO PROPOSTO. SOMBRAS EM AZUL E VEGETAÇÃO EM VERMELHO.....	96
FIGURA 4.14 ILUSTRAÇÃO DO AUMENTO DE CONTRASTE ENTRE ELEMENTOS CLAROS E ESCUROS COM A EQUALIZAÇÃO DA IMAGEM <i>NIR</i> . (IMAGEM <i>NIR</i> ORIGINAL ADQUIRIDA PELA CÂMARA IGN).....	100
FIGURA 4.15 PADRÕES DAS RESPOSTAS DOS ÍNDICES SOBRE OS ELEMENTOS DE INTERESSE: VEGETAÇÃO, SOLO EXPOSTO, TELHADOS DE EDIFICAÇÕES, RODOVIAS, REGIÕES SOMBREADAS E CORPOS D'ÁGUA: <i>NIR</i> (LINHA PRETA), <i>NDVI</i> (LINHA VERDE), <i>nSI</i> (LINHA AZUL), <i>sSI</i> (LINHA PONTILHADA AZUL), <i>WWI</i> (LINHA VERMELHA) E <i>RWSI</i> (LINHA PONTILHADA VERMELHA).	102
FIGURA 4.16 RELAÇÃO DE DISTÂNCIA ENTRE $h^S (NDVI + nSI)$ – LINHA AZUL – E $h^S (RWSI)$ – LINHA VERMELHA PONTILHADA.	103
FIGURA 4.17 IMAGEM <i>NIR</i> COM HISTOGRAMA EQUALIZADO.	106
FIGURA 4.18 REALCE DE VEGETAÇÃO VERDE. (A) IMAGEM COLORIDA ORIGINAL. (B) IMAGEM <i>NDVI</i>	106
FIGURA 4.19 REALCE DE SOMBRAS. (A) IMAGEM ORIGINAL. (B) IMAGEM <i>sSI</i> . (B) IMAGEM <i>nSI</i>	107
FIGURA 4.20 REALCE DE CORPOS D'ÁGUA. (A) IMAGEM ORIGINAL. (B) IMAGEM <i>WWI</i> . (C) IMAGEM <i>mWI</i>	108
FIGURA 4.21 REALCE DE CORPOS D'ÁGUA, SOMBRAS E RODOVIAS. (A) IMAGEM ORIGINAL. (B) IMAGEM <i>RWSI</i> . (C) IMAGEM <i>nRI</i>	109
FIGURA 4.22 (A) IMAGEM ORIGINAL IGN. (B) IMAGEM TEMÁTICA: CORTE SUPERIOR A 30% DO VALOR MÁXIMO OBSERVADO NO ÍNDICE <i>mWI</i> (EM VERMELHO E AZUL). RESTRIÇÃO DO MATIZ DOS ALVOS (EM AMARELO E AZUL). INTERSECÇÃO ENTRE OS RESULTADOS DO CORTE E DA RESTRIÇÃO DO MATIZ (EM AZUL). (C) RESULTADO DA SEGMENTAÇÃO DE CORPOS D'ÁGUA USANDO SOMENTE O PARÂMETRO DE DIFICULDADE <i>K</i> COMO RESTRIÇÃO.	113
FIGURA 4.23 RESULTADO FINAL DA SEGMENTAÇÃO DE CORPOS D'ÁGUA.....	113
FIGURA 4.24 CÓPIA DA FIGURA 4.15, A QUAL MOSTRA O COMPORTAMENTO DAS RESPOSTAS DOS ÍNDICES SOBRE ELEMENTOS ESPECÍFICOS.	114
FIGURA 4.25 RESULTADO FINAL DA SEGMENTAÇÃO DE SOMBRAS. (A) IMAGEM ORIGINAL. (B) IMAGEM TEMÁTICA.	116
FIGURA 4.26 RESULTADOS DA DETECÇÃO DE MARCADORES DE RODOVIA. (A) IMAGEM ORIGINAL (IGN). (B) RESULTADO DO REALCE PELA COMPOSIÇÃO DOS ÍNDICES (<i>rd</i>). (C) MARCADORES DE RODOVIAS DETECTADOS (REGIÕES EM AMARELO E VERMELHO). AS REGIÕES EM AMARELO CORRESPONDEM À CONFUSÃO ENTRE CORPOS D'ÁGUA E RODOVIAS.	117
FIGURA 4.27 RESULTADO DA DISCRIMINAÇÃO DE VEGETAÇÃO. (A) IMAGEM ORIGINAL (IGN). (B) RESULTADO DO CORTE DE 80% DO VALOR MÁXIMO SOBRE O <i>NDVI</i> (UNIÃO DAS ÁREAS EM VERMELHO E AZUL). ÁREAS EM AZUL É O RESULTADO DA INTERSECÇÃO ENTRE O RESULTADO DESTES CORTE SOBRE O <i>NDVI</i> COM O RESULTADO DE DISCRIMINAÇÃO DE SOMBRAS DA FIGURA 4.26B. (C) RESULTADO DA DISCRIMINAÇÃO DA VEGETAÇÃO PELO MÉTODO PROPOSTO.	120
FIGURA 4.28 IMAGEM IGN ORIGINAL E IMAGEM TEMÁTICA CORRESPONDENTE. VERDE - VIAS PÚBLICAS ASFALTADAS. AZUL – SOMBRAS. VERMELHO – VEGETAÇÃO. AMARELO – CORPOS D'ÁGUA.....	121
FIGURA 4.29 IMAGEM IGN ORIGINAL E IMAGEM TEMÁTICA CORRESPONDENTE. VERDE - VIAS PÚBLICAS ASFALTADAS. AZUL – SOMBRAS. VERMELHO – VEGETAÇÃO. AMARELO – CORPOS D'ÁGUA.....	121
FIGURA 4.30 IMAGEM IGN ORIGINAL E IMAGEM TEMÁTICA CORRESPONDENTE. VERDE - VIAS PÚBLICAS ASFALTADAS. AZUL – SOMBRAS. VERMELHO – VEGETAÇÃO. AMARELO – CORPOS D'ÁGUA.....	122
FIGURA 4.31 IMAGEM HRSC-AX ORIGINAL E IMAGEM TEMÁTICA CORRESPONDENTE. VERDE - VIAS PÚBLICAS ASFALTADAS. AZUL – SOMBRAS. VERMELHO – VEGETAÇÃO. AMARELO – CORPOS D'ÁGUA.....	123
FIGURA 4.32 IMAGEM HRSC-AX ORIGINAL E IMAGEM TEMÁTICA CORRESPONDENTE VERDE - VIAS PÚBLICAS ASFALTADAS. AZUL – SOMBRAS. VERMELHO – VEGETAÇÃO. AMARELO – CORPOS D'ÁGUA.....	124
FIGURA 4.33 IMAGEM HRSC-AX ORIGINAL E IMAGEM TEMÁTICA CORRESPONDENTE. VERDE - VIAS PÚBLICAS E RODOVIAS ASFALTADAS. AZUL – SOMBRAS. VERMELHO – VEGETAÇÃO. AMARELO – CORPOS D'ÁGUA.	125
FIGURA 4.34 PROBLEMAS DE REGISTROS ENTRE AS IMAGENS R, G E B ADQUIRIDAS PELA CÂMARA HRSC-AX..	126
FIGURA 4.35 PROBLEMAS DE REGISTROS DE ALVOS QUE SE MOVEM (SUPERFÍCIE DO CORPO D'ÁGUA) ENTRE AS IMAGENS R, G E B ADQUIRIDAS PELA CÂMARA HRSC-AX.	126
FIGURA 4.36 ELIMINAÇÃO DE MARCAÇÕES ERRADAS SOBRE RODOVIAS. (A) MARCADORES SEGMENTADOS PELO MÉTODO PROPOSTO SEM A EXCLUSÃO DE ÁREAS SOMBREADAS. (B) RESULTADOS DA APLICAÇÃO DO OPERADOR MORFOLÓGICO DE ABERTURA. (C) ELIMINAÇÃO DE ÁREAS CONECTADAS EQUIVALENTES A 2000 PIXELS (OU 80M ² PARA GSD DE 20CM) COM APLICAÇÃO DO FILTRO MORFOLÓGICO <i>AREAOPEN</i> . (D) RESULTADO PROMOVIDO PELO FECHAMENTO SEGUIDO DE RESTRIÇÃO DE ÁREA.	128
FIGURA 4.37 (A) EXEMPLO DE SOMBRA PRÓPRIA E SOMBRA PROJETADA SOBRE TELHADO. (B) PROBLEMA DE EXTRAÇÃO DO MDS SOBRE REGIÕES SOMBREADAS.	133
FIGURA 4.38 PROBLEMAS COM A PRECISÃO DO MDS. (A) ILUSTRAÇÃO DA EXTENSÃO DO MDS COBRINDO DUAS ELEVÇÕES SEPARADAS POR UMA DISTÂNCIA DE 7M. (B) MDS CORRESPONDENTE.	133
FIGURA 4.39 ILUSTRAÇÃO DA SUAUIZAÇÃO DO MDS EM REGIÕES PRÓXIMAS ÀS ELEVÇÕES BRUSCAS.....	135

FIGURA 4.40	PADRÃO DO EFEITO DE SUAVIZAÇÃO DO MDS NAS VIZINHANÇAS DE ELEVAÇÕES. (A) MDS ORIGINAL. (B) DETALHE DO MDS REALÇADO PARA VISUALIZAÇÃO DO EFEITO DA SUAVIZAÇÃO.....	135
FIGURA 4.41	DETECÇÃO DAS REGIÕES DE TRANSIÇÃO. (A) MDS ORIGINAL. (B) MDS EQUALIZADO PARA MELHOR VISUALIZAÇÃO DAS REGIÕES DE TRANSIÇÃO. (C) MDS FILTRADO PELOS FILTROS DA ORDEM DE MÍNIMO (7x7) E DE MÁXIMO (9x9) – IMAGEM REALÇADA PARA EFEITO DE VISUALIZAÇÃO. (D) REGIÕES DE TRANSIÇÃO (EM VERMELHO) DETECTADAS PELO USO DO PSEUDOGRADIENTE. PONTOS CRÍTICOS DETECTADOS (EM AMARELO).	137
FIGURA 4.42	NORMALIZAÇÃO DO MDS. (A) MDT GERADO PELA INTERPOLAÇÃO DOS PONTOS CRÍTICOS. (B) MDS FILTRADO PELOS FILTROS DA ORDEM DE MÍNIMO E DE MÁXIMO. (C) NORMALIZAÇÃO DO MDS FILTRADO. (D) <i>TopHat</i> POR ABERTURA DE ÁREA. (E) <i>TopHat</i> POR FECHAMENTO DE ÁREA (IMAGEM REALÇADA PARA MELHOR VISUALIZAÇÃO DOS RESÍDUOS). (F) NMDS CRÍTICO OTIMIZADO.	140
FIGURA 4.43	DETERMINAÇÃO DA NATUREZA DOS PONTOS DO MDS. (A) MDS ORIGINAL. (B) IMAGEM TEMÁTICA SOBRE A NATUREZA DOS PONTOS. PONTOS ELEVADOS (AZUL); PONTOS NÃO ELEVADOS (VERMELHO) E PONTOS DE NATUREZA DESCONHECIDA (CINZA). (C) IMAGEM RGB CORRESPONDENTE.....	142
FIGURA 4.44	DETERMINAÇÃO DA NATUREZA DA ELEVAÇÃO DOS PONTOS DO MDS. PONTOS ELEVADOS (AZUL). PONTOS AO NÍVEL DO TERRENO (VERMELHO). PONTOS DE NATUREZA DESCONHECIDA (CINZA).....	144
FIGURA 4.45	EXEMPLO DO RESULTADO FINAL DO TRATAMENTO DOS MARCADORES INTERNOS (VERMELHO) E EXTERNOS (AZUL).....	150
FIGURA 4.46	SIMULAÇÃO DA SEGMENTAÇÃO <i>WATERSHED</i> COM MARCADORES PELO CONCEITO DE INUNDAÇÃO..	152
FIGURA 4.47	FILTRAGEM DA IMAGEM PANCROMÁTICA (HRSC-AX). (A) IMAGEM ORIGINAL. (B) IMAGEM FILTRADA $F_{\Phi}^{\Gamma}(PAN)$	153
FIGURA 4.48	SEGMENTAÇÃO DE TELHADOS DE EDIFICAÇÕES. RESULTADOS OBTIDOS COM A METODOLOGIA PROPOSTA. (A) IMAGEM RGB ORIGINAL. (B) MDS ORIGINAL. (C) RESULTADOS OBTIDOS (REGIÕES EM VERMELHO E AMARELO).	154
FIGURA 4.49	PADRÃO DE REFERÊNCIA OBTIDO ATRAVÉS DE FOTOINTERPRETAÇÃO CONTENDO DEMARCAÇÕES DOS TELHADOS.	156

LISTA DE TABELAS

TABELA 2.1 RELAÇÕES DO COEFICIENTE KAPPA COM O DESEMPENHO DA CLASSIFICAÇÃO.....	62
TABELA 4.1 COEFICIENTES DE CORRELAÇÃO ENTRE OS COMPONENTES <i>R</i> , <i>G</i> , <i>B</i> E IMAGEM <i>NIR</i>	97
TABELA 4.2 MATRIZ DE CONFUSÃO DOS RESULTADOS DE DETECÇÃO DE TELHADOS	155
TABELA 4.3 ÍNDICES DE ERRO DE INCLUSÃO E OMISSÃO.	156

LISTA DE SIGLAS E SÍMBOLOS

- δ_B – Operador morfológico dilatação
DLR – Deutsches Zentrum für Luft-und Raumfahrt
DoA – *Degree of Artificiality*
DN – Digital Number
DOS – Dark Object Subtraction
 ε_B – Operador morfológico erosão
 ε_B^∞ – Operador morfológico binário de última erosão
 ϕ_B – Operador morfológico fechamento
 Φ_a^{area} – Filtro morfológico conexo de fechamento por área
 γ_B – Operador morfológico abertura
 Γ_a^{area} – Filtro morfológico conexo de abertura por área
GSD – Ground Sample Distance
 $h^s(X)$ – Alargamento linear do histograma de X
HSI – Sistema de cor Hue, Saturation e Intensity
HSV – Sistema de cor Hue, Saturation e Value
IGN – Institut Géographique National
 κ – Coeficiente de concordância Kappa
LIDAR – LIght Detection And Ranging
 M – conjunto de pontos marcador interno e externo
 M_i^{Int} – conjunto de pontos marcador interno de índice i
 M_i^{Ext} – conjunto de pontos marcador externo de índice i
MDS – Modelo Digital de Superfície
MDS^F – Modelo Digital de Superfície filtrado
MDT – Modelo Digital de Terreno
 MDT^{CRT} – Modelo Digital de Terreno crítico
mWI – *maximum Water Index*
 $nMDS_{om}^{CRT}$ – Modelo Digital de Terreno crítico otimizado
 $nMDS_+^{CRT}$ – valores positivos do Modelo Digital de Terreno crítico
NandA – *Natural and Artificial features*
 $NandA^N$ – valores produzidos pelo índice *NandA* normalizados para o intervalo [-1, 1]
NIR – *Near Infrared Response*
nMDS – Modelo Digital de Superfície normalizado
NDVI – *Normalized Difference Vegetation Index*
NDWI – *Normalized Diference Water Index*
nRI – *normalized Road Index*
nSI – *normalized Shadow Index*
PG – pseudogradiante
PC – pontos críticos
 P_s^E – pontos de superfícies elevadas
 P_s^T – pontos de superfícies no nível do terreno
PSM – Pan-Sharpened Multi-spectral
RGB – Sistema de cor Red, Green e Blue

R^T – regiões de transição

RWSI – *Road-Water-Shadow Index*

SAR – Synthetic Aperture Radar

SIG – Sistema de Informação Geográfica

SOM – Self-Organizing Maps

sSI – *Spectral Shadow Index*

$TH_{a_1}^\Gamma$ – Operador residual *TopHat* por abertura de área

$TH_{a_2}^\Phi$ – Operador residual *TopHat* por fechamento de área

TIN – Triangular Irregular Network

WWI – *Weighted Water Index*

$A_p(B, M)$ – Função de transformação de valores bidimensionais para unidimensionais de M em correspondência com a matriz B composta por valores binários (0s e 1s)

CAPÍTULO I

INTRODUÇÃO

Entre os grandes problemas de interesse para as Geociências destaca-se a extração automática de elementos que compõem a paisagem urbana (edificações, corpos d'água, vegetação, rodovias, sombras, solo exposto, etc.) através do processamento digital de imagens aéreas e dados de elevação.

Segundo Grün (2000), a completa extração desses elementos consiste em tratá-los adequadamente por processos divididos em três etapas: detecção, reconstrução e descrição. Este trabalho segue essa linha de definição dada por Grün, mas focaliza apenas a etapa de detecção.

A **detecção** (GRÜN, 2000) se refere ao processo de localizar um, ou mais, elemento particular, contido em uma imagem junto com outros elementos (indesejados). A detecção de elementos específicos não implica em definir completamente as suas respectivas linhas de contornos, entretanto, o conhecimento dessas linhas é necessário para reconstruir, geometricamente, as feições desses elementos de forma coerente com as suas respectivas disposições no espaço-objeto. Assim, para detectar um elemento específico no espaço-imagem, é suficiente apontar, mesmo que parcialmente, para a sua localização nesse espaço.

A **reconstrução** (GRÜN, 2000) é o processo que possibilita dispor, de maneira coerente, a geometria de um elemento específico no espaço-objeto usando atributos extraídos do espaço-imagem (como: linhas de contorno e dados de altimetria). A simples detecção de um elemento nem sempre permite extrair os atributos necessários para reconstruí-lo. Os resultados obtidos pelo processo de detecção, em grande parte dos casos, precisam ser refinados para tornar o processo de reconstrução capaz de estabelecer os relacionamentos geométricos desse elemento com a entidade correspondente no espaço-objeto. Esse refinamento pode ser tão complexo quanto a própria detecção. Exemplos de casos de reconstrução de telhados de edificações são apresentados na Figura 1.1



Figura 1.1 Exemplo de reconstrução de telhados de edificações. Adaptado de Taillandier e Deriche (2004).

A **descrição** (GRÜN, 2000) se refere ao processo que designa elementos identificadores (conhecimento) relativos à entidade reconstruída, por exemplo, no caso de uma edificação, descrever o seu tipo: prédio-de-apartamento; escola; igreja; fábrica; etc.

Essa seqüência de processos composta pelas etapas detecção-reconstrução-descrição descritas por Grün, (2000) pode definir uma estratégia de processamento, entretanto, esse caminho tem complexidade crescente.

1.1 MOTIVAÇÃO E JUSTIFICATIVA

A construção de modelos virtuais de cidades é um problema que está sendo pesquisado cada vez mais. Esse produto tem uma grande demanda por parte de uma variedade de usuários. Um modelo virtual de cidade pode ser utilizado em atividades como: planejamento urbano, cartografia, arquitetura, planejamento ambiental, telecomunicação, navegação, segurança nacional, administração civil e turismo.

A complexidade do problema relacionado com a detecção de elementos de interesse em dados de imageamento aéreo, aliada à necessidade emergente em se obter bons resultados conduz, em muitos casos, para o uso de soluções semi-automáticas, as quais permitem a interação e o controle do usuário em várias fases do processo (GRÜN, 2000). Essa abordagem é adotada devido à inviabilidade de tratar adequadamente esses problemas de forma automática. Apesar de eficientes, o uso de sistemas semi-automáticos requer mão-de-obra especializada, demandam muito tempo para concluir um projeto e, portanto, podem aumentar os custos envolvidos. Ou seja, para determinados projetos, essa abordagem semi-automática pode não se traduzir em ganhos significativos.

Santos (2002) relata que 55% do tempo necessário para realizar uma restituição fotogramétrica digital de edificações, num projeto cadastral, foi gasto pelo operador do sistema para detectá-las adequadamente. Opitz (1999) afirma que o maior gargalo na produção e manutenção de um banco de dados geoespacial está na extração de elementos de cartas e de imagens (pontos, linhas, polígonos, atributos descritivos desses elementos, etc.). Estima, ainda, que 60 a 80% do custo total envolvido com o processo de desenvolvimento de uma aplicação SIG (Sistema de Informação Geográfica) estão diretamente relacionados com a detecção de elementos adequados.

A reconstrução e a descrição de um elemento de interesse é um processo de alta complexidade que exige a obtenção de conhecimento de alto nível, como: 1) conhecer os detalhes que compõem esse elemento; 2) conhecer como esses detalhes se inter-relacionam e; 3) conhecer os respectivos propósitos de uso desses detalhes. A detecção, à primeira vista, é um processo mais grosseiro, pois se resume em apontar para a localização do elemento de interesse. Entretanto, detectar um elemento específico pode envolver operações tão complexas quanto aquelas usadas na sua completa extração, como, por exemplo, detectar telhados de edificações, os quais possuem atributos como: forma geométrica, dimensões, cor e textura variáveis. A qualidade da extração é diretamente dependente da capacidade de detecção. Quanto mais precisa for a detecção de um elemento, maior e melhor é o nível de detalhes que pode ser obtido e, com isso, mais precisos são os processos de reconstrução e de descrição.

Considerando a estratégia detectar-reconstruir-descrever, a detecção pode ser vista como uma das fases de pré-processamento dos dados, cujos resultados podem ser usados em processos posteriores (como: fotogramétricos, de sensoriamento remoto e de sistemas de informação geográfica). A detecção também permite estabelecer um nível mais elevado de conhecimento relativo aos dados de imageamento. Esse conhecimento pode ser utilizado para desenvolver novas técnicas ou melhorar o desempenho e a eficácia de técnicas clássicas, tanto no âmbito do tratamento computacional como no ganho de qualidade nos resultados. Como exemplo, se são conhecidas, no espaço-imagem, as localizações de árvores, solo exposto, vegetação rasteira, corpos d'água, rodovias, edificações elevadas e sombras em um conjunto estéreo-par de imagens então, podem ser desenvolvidas estratégias diferentes para abordar cada um desses elementos para gerar um Modelo Digital de Terreno ou Elevação com precisão superior ao que seria obtido sem o uso adequado desse conhecimento prévio.

Na fase de detecção, propriedades como atributos de cor, extraídos das imagens, e dados MDS (Modelo Digital de Superfície), extraídos de dados 3D, mostram-se particularmente valiosos (NIEDERÖST, 2000) e são usados para separar, num primeiro

momento, elementos artificiais dos naturais, para facilitar a distinção entre edificações e outros objetos antrópicos, como estradas, pontes, etc. Uma taxa de relativo sucesso na detecção tem sido documentada. Entretanto, estruturas urbanas complexas resistem severamente a essa abordagem.

Fotogrametria é a fonte primária para a geração de produtos cartográficos e SIG. Atualmente, com o uso de novas tecnologias como SAR (*Synthetic Aperture Radar*) e LIDAR (*Light Detection And Ranging*), além das modernas câmaras fotogramétricas digitais multiespectrais, novas possibilidades na geração de produtos correlatos com essas áreas estão sendo exploradas. Entretanto, o uso dessas novas tecnologias exige, em alguns casos, a reavaliação de métodos existentes e o desenvolvimento de outros novos. Mas, por outro lado, o alto custo de investimento relacionado com essas novas tecnologias, além de exigirem a aplicação de um outro nível de abstração e de conhecimento dos usuários, não viabiliza, por enquanto, o uso extensivo e combinado dessas tecnologias na maioria dos projetos fotogramétricos.

Os custos elevados associados com a aquisição dessas novas tecnologias, além da necessidade de recursos humanos especializado, retardam a mudança do atual paradigma da fotogrametria analógico/digital para o completamente digital, abarcando todas as fases do processo – aquisição dos dados, processamento, geração e distribuição dos produtos. Esse momento de impasse está dando uma sobrevida às câmaras fotogramétricas baseadas em filmes fotográficos. Contudo, o início da mudança para esse novo paradigma já ocorreu em países mais ricos como EUA, Japão e alguns europeus. Espera-se que essas novas tecnologias consigam alcançar um nível de automação dos processos muito superior que os atuais. Com isso, o ganho em produtividade compensaria os custos de investimentos, baixando a relação custo/benefício, além de haver a possibilidade de, ao longo do tempo, se reduzir os custos de produção desses novos equipamentos.

De outra forma, a tecnologia computacional continua a se desenvolver a passos largos. A cada dia novas técnicas e avanços tecnológicos são incorporados aos sistemas computacionais (hardware e software), deixando-os com maior poder de processamento e, geralmente, com baixa relação de custo-benefício. Esse aumento na capacidade computacional permite vislumbrar novos horizontes na geração automática de produtos fotogramétricos. Entretanto, somente o uso combinado desses recursos computacionais com as novas tecnologias aplicadas em Fotogrametria pode estabelecer um novo nível de automação dos processos.

A maioria das câmaras fotogramétricas digitais (como: IGN, HRSC-AX,

DMC, ADS40 e Ultracam) têm capacidade de adquirir imagens em quatro bandas espectrais (bandas: azul, verde, vermelha e infravermelha – relativas às faixas do espectro eletromagnético). Isto representa uma forma diferente de abordar os problemas, pois há um aumento na resolução espectral em relação aos produtos pancromáticos, ou mesmo coloridos, tradicionalmente usados em Fotogrametria. Essa ampliação na resolução espectral em dados de imageamento aumenta a capacidade de discriminação de alvos baseadas nas diferenças de comportamento espectral.

Se esses novos tipos de dados de imageamento permitirem a detecção de elementos específicos, como: solo exposto; corpos d'água; áreas sombreadas; vias urbanas e rodovias entre outros elementos, um nível mais elevado de automação dos processos fotogramétricos pode ser conseguido.

Entretanto, detectar elementos-chave no espaço-imagem para tornar isto possível não é uma tarefa trivial. A aplicação de técnicas clássicas de processamento de imagens e reconhecimento de padrões, em muitos casos, não apresenta resultados completos, pois a quantidade e a diversidade de padrões que podem estar envolvidos numa mesma cena tornam complexas demais a sua solução, como por exemplo: os variados tipos de vegetação e de solo exposto; corpos d'água com diferentes propriedades ópticas; a instabilidade da resposta espectral das áreas sombreadas e a presença de diferentes elementos artificiais (residências, ruas, pontes, etc. – com diferentes geometrias, texturas, cores e propósitos de uso), as quais geram, cada uma ao seu modo, variações consideráveis na cena.

Algumas variações que elevam a complexidade da solução do problema “detectar elementos da paisagem urbana” podem ser vistas na Figura 1.2. Por exemplo, pode ser observado que entre os telhados das edificações existem variações de atributos como texturas, formas geométricas e brilhos. Esses elementos possuem atributos intrínsecos, exceto a denominação “telhados de edificações”. A complexidade desse problema é ainda maior, pois, como se pode ver na Figura 1.2, esses atributos de telhado de edificação variam na própria edificação.



Figura 1.2 Exemplo de variabilidade nos atributos dos telhados de edificações.

1.2 OBJETIVOS

Propõe-se neste trabalho o desenvolvimento de técnicas determinísticas para detectar e discriminar um conjunto de elementos que compõem a paisagem urbana presentes em imagens aéreas multiespectrais adquiridas com alta resolução espacial.

Para detectar esses elementos de interesse são propostos métodos de realce, na forma de índices que usam dados radiométricos e dados de cor para realçar a presença (ou ausência) de elementos específicos. O realce desses elementos específicos permite extrair e mensurar atributos relativos a esses elementos, os quais, por sua vez, permitem as suas respectivas detecções e discriminações.

A detecção e a discriminação desses elementos permitem extrair conhecimento contextual das imagens. Esse conhecimento pode ser usado para modelar outros processos relacionados com o processamento de imagens aéreas de regiões urbanas (como fotogramétricos, cartográficos, sistemas de informações geográficas, etc).

Este trabalho propõe métodos para fazer essa detecção e discriminação de alguns elementos comumente presentes na paisagem de regiões urbanas. A capacidade de detecção desses métodos é limitada pelo conjunto de dados disponível, da seguinte forma:

- (1) Se, somente imagens coloridas normais estão disponíveis, então o método proposto é capaz de detectar e discriminar áreas sombreadas e áreas cobertas por vegetação verde.
- (2) Se imagens multiespectrais, relativas ao visível e ao infravermelho

próximo do espectro eletromagnético, estiverem disponíveis, então o método proposto é capaz de detectar e discriminar áreas sombreadas, áreas cobertas por vegetação verde, corpos d'água e rodovias/estradas/vias públicas pavimentadas com asfalto.

- (3) Se imagens multiespectrais e um Modelo Digital de Superfície correspondente estiverem disponíveis, então, além dos elementos citados anteriormente, o método proposto é capaz de normalizar o Modelo Digital de Superfície e detectar telhados de edificações.

Nesse contexto, os objetivos gerais deste trabalho são:

- Extrair conhecimento contextual das imagens aéreas de paisagens urbanas através da detecção e da discriminação de alguns elementos que compõem essas paisagens.
- Realçar, detectar e discriminar alguns elementos, presentes em diferentes paisagens urbanas, registrados em imagens multiespectrais adquiridas por diferentes sensores.
- Subsidiar o processo de reconstrução desses elementos da paisagem urbana.
- Subsidiar o desenvolvimento de novos métodos, ou promover melhorias nos métodos atuais, relacionados com a geração de produtos inerentes à Fotogrametria, à Cartografia, ao Sensoriamento Remoto e aos Sistemas de Informação Geográfica que usam conhecimento contextual extraído de dados de imageamento aéreo de regiões urbanas.

Os objetivos específicos deste trabalho são:

- Propor índices capazes de realçar sombras e vegetação verde presentes em imagens coloridas (RGB) que permitam inferir sobre esses elementos.
- Propor técnicas determinísticas para detectar sombras e vegetação verde em imagens coloridas.
- Propor índices capazes de realçar sombras, corpos d'água e rodovias pavimentadas com asfalto presentes em imagens coloridas e infravermelhas correspondentes que permitam inferir sobre esses elementos.

- Propor técnicas determinísticas para detectar sombras, vegetação verde, corpos d'água e rodovias pavimentadas com asfalto em imagens coloridas e infravermelhas.
- Propor uma técnica determinística para normalizar o Modelo Digital de Superfície de uma região urbana.
- Propor uma técnica determinística para detectar telhados de edificação usando dados extraídos do Modelo Digital de Superfície normalizado e elementos da paisagem urbana detectados com o uso de imagens multiespectrais.

1.3 DADOS USADOS NOS EXPERIMENTOS E ESTUDOS DE CASOS

Este trabalho usa quatro conjuntos de dados de imageamento para realizar experimentos de realce e de detecção dos elementos da paisagem urbana de interesse deste trabalho.

O primeiro conjunto é composto de imagens coloridas tradicionais (RGB) adquiridas com o uso de câmeras fotogramétricas baseadas em filmes, como as câmaras RC-10 e RMKTOP 15. Os dados adquiridos pela câmara RC-10 são da área urbana da cidade de Presidente Prudente, extremo oeste do estado de São Paulo, em uma missão fotogramétrica realizada pelo Departamento de Cartografia da FCT/UNESP campus de Presidente Prudente. Os dados adquiridos pela câmara RMKTOP 15 são da área urbana da cidade de Poços de Caldas, interior sul do Estado de Minas Gerais, em uma missão fotogramétrica realizada pela empresa ESTEIO – Engenharia de Aerolevanteamento, Curitiba (Estado do Paraná).

O Segundo conjunto é composto de imagens coloridas adquiridas com o uso das câmaras digitais Kodak-14N, IGN, ADS40, Ultracam e DMC. Os dados adquiridos pela câmara Kodak-14N são da área urbana da cidade de Presidente Prudente, extremo oeste do Estado de São Paulo, em uma missão fotogramétrica realizada pela empresa Multiespectral em parceria com a empresa Photon e o Departamento de Cartografia da FCT/UNESP campus de Presidente Prudente. Os dados adquiridos pela câmara IGN são de uma área urbana desconhecida (disponíveis em http://isprs.ign.fr/packages/packages_en.htm), em uma missão fotogramétrica realizada pelo Institut Géographique National (IGN) - França. Os dados adquiridos pelas câmaras ADS40, Ultracam e DMC são de áreas urbanas desconhecidas e foram disponibilizados como material de propaganda (disponível em CD-ROM) pelas

empresas Leica Geosystems, Vexcel Corporation e Intergraph's Z/I Imaging, respectivamente.

O terceiro conjunto é composto de imagens coloridas e infravermelhas adquiridas com o uso da câmara digital IGN de uma área urbana desconhecida, as quais foram gentilmente cedidas pelo Institut Géographique National (IGN) – França para serem usadas neste trabalho.

O quarto conjunto é composto de imagens adquiridas em cinco bandas espectrais (azul, verde, vermelho, infravermelha e pancromática – relativo às faixas do espectro eletromagnético) pela câmara HRSC-AX, desenvolvida pelo Deutsches Zentrum für Luft-und Raumfahrt (DLR), acompanhado do respectivo MDS da área urbana da cidade de Salvador, extremo sudeste do Estado da Bahia, em uma missão fotogramétrica realizada pela empresa brasileira DIGIMAPAS.

Todas as imagens foram disponibilizadas no formato TIFF (exceto as imagens adquiridas pela câmara DMC, as quais foram disponibilizadas no formato de arquivo JPEG), sendo que algumas estão georreferenciadas. As imagens IGN foram adquiridas com GSD (*Ground Sample Distance*) de 25cm, as demais com GSD de 20cm. Apesar de algumas câmaras terem a capacidade de adquirir imagens com uma resolução radiométrica maior que 8bits/pixel, todas as imagens usadas neste trabalho são de 8bits.

O MDS de Salvador, processado a partir das imagens da câmara HRSC-AX, foi gerado pela empresa DIGIMAPAS com GSD de 50cm e, disponibilizado em grade regular preenchida com tons de cinza (pixels) amostrados em 16bits/pixel, e cobre uma área de 3000×3000 metros da região urbana de Salvador.

1.4 ESTRUTURA DESTE TRABALHO

Este trabalho está organizado em cinco Capítulos, inclusive este. No Capítulo II é feito um levantamento do estado da arte envolvendo o problema de detecção e extração de elementos em dados de imageamento aéreo.

No Capítulo III são apresentadas as bases da metodologia proposta neste trabalho para atingir os objetivos propostos. Também são apresentados estudos e constatações relativas à precisão e acurácia dos dados usados neste trabalho.

No Capítulo IV são apresentados detalhes dos procedimentos propostos neste trabalho, os resultados produzidos por suas respectivas aplicações e são feitas análises desses resultados.

No Capítulo V são feitas as considerações finais deste trabalho, envolvendo

os resultados obtidos e propostas de melhoria e de continuidade no desenvolvimento de soluções dos problemas relacionados no contexto deste trabalho.

CAPÍTULO II

ESTADO DA ARTE: DETECÇÃO DE ELEMENTOS EM IMAGENS AÉREAS

O atual desenvolvimento tecnológico de sistemas sensores (como, as novas câmaras fotogramétricas digitais, sistemas de radar e sistemas de varredura laser) está promovendo um novo nível de automação dos processos cartográficos, fotogramétricos e de sensoriamento remoto. Entretanto, a completa automação desses processos ainda é utópica, pois, mesmo com o atual desenvolvimento tecnológico, ainda é necessária a intervenção do homem na maioria desses processos, para dar precisão e completude aos resultados produzidos.

Um dos principais problemas que impede a completa automação desses processos está relacionado com a detecção e extração automática de elementos específicos. Muitos trabalhos já foram realizados objetivando detectar e extrair automaticamente rodovias, rios, telhados de edificações, tipos de vegetação, etc. Apesar de todo o progresso, esses problemas resistem severamente a uma solução automática completa.

McKeown *et al.* (2000) fazem uma análise da complexidade do problema de detectar e extrair elementos em imagens aéreas, abordando a detecção e a extração de edificações, a qual é colocada da seguinte forma: *“Edificações estão entre os elementos cartográficos mais complexos de se detectar e extrair, devido à ampla variedade de formas e aparências complexas (...). A detecção e extração de edificações são influenciadas tanto pela complexidade da própria edificação como pela complexidade da cena que a contém. Na extração, delinear corretamente uma edificação isolada é muito mais fácil do que delinear-la diretamente da imagem original. Isto se deve em parte aos efeitos de imageamento como oclusão e interferências por sombras e; ao aumento do grau de desordem no espaço de busca. Este aumento no nível de dificuldade promove inferências de numerosas formulações de falsas hipóteses e, pode ainda, mascarar hipóteses verdadeiras”*. Shufelt (1999) formulou um conjunto de métricas para descrever o grau de complexidade envolvida numa cena.

Considerando que o problema da detecção de elementos presentes em dados de imageamento aéreo (principalmente de regiões urbanas) é muito estudado, mas ainda não completamente resolvido e, em concordância com os objetivos deste trabalho, faz-se neste

Capítulo um levantamento do estado da arte relacionado com detecção de elementos específicos em dados de imageamento aéreo e dados LIDAR adquiridos com alta resolução espacial.

2.1 VEGETAÇÃO

Conforme Causey *et al.* (2005), o avanço tecnológico de desenvolvimento de sensores habilitou Sensoriamento Remoto com a capacidade de estudar e acompanhar o desenvolvimento de sistemas complexos do meio-ambiente. Os atuais sensores digitais com capacidade de adquirir dados com elevada resolução espacial (sub-metro) e alta resolução radiométrica, igual ou superior a 8bits/banda, permitem, por exemplo, acompanhar o desenvolvimento individual de árvores presentes em uma região urbana (ou áreas de florestas). Sistemas de varredura laser obtêm dados altimétricos e de intensidade dos alvos que cobrem o terreno que podem ser usados para estimar altura e área (ou volume) do dossel das árvores. Câmaras digitais capazes de adquirir imagens nas faixas espectrais correspondentes ao azul, verde, vermelho e infravermelho próximo facilitam o processo de detecção de vegetação em ambientes complexos, como regiões urbanas, bem como analisar parâmetros de estado de saúde dessa vegetação detectada através da computação do *NDVI*¹ (*Normalized Difference Vegetation Index*) e parâmetros biofísicos que relacionam a biomassa e a absorção de dióxido de carbono. A seguir são apresentados alguns trabalhos relacionados com a detecção de árvores.

Stiteler (2000) apresentou uma técnica de correlação de imagens por área para detectar copas de árvores em imagens aéreas, ortorretificadas, adquiridas com GSD (*Ground Sample Distance*) de 1 metro na faixa do infravermelho próximo. A medida de correlação apresentada (*template matching*) é feita, automaticamente, usando técnicas de algoritmos genéticos. O padrão de referência (*template*) usado, uma imagem de 9×9 pixels contendo valores de brilho amostrados de copas de árvores e um exemplo da aplicação está ilustrado na Figura 2.1. Quackenbush *et al.* (2000) utilizaram o mesmo conjunto de imagens e o mesmo método geral usado por Stiteler (Figura 2.2).

No trabalho de Quackenbush foram usados oito padrões de referências suavizados com tamanhos variando de 5×5 até 13×13 derivados da Figura 2.2a. A medida de correlação, para mensurar a similaridade entre as diferentes áreas da imagem com cada um

¹ $NDVI = \frac{NIR - R}{NIR + R}$

dos oito padrões de referência, é obtida pelo coeficiente de correlação linear. Uma análise posterior dos valores de correlação obtidos em cada área permite determinar se são copas de árvores ou não. A Figura 2.2c mostra o resultado obtido.

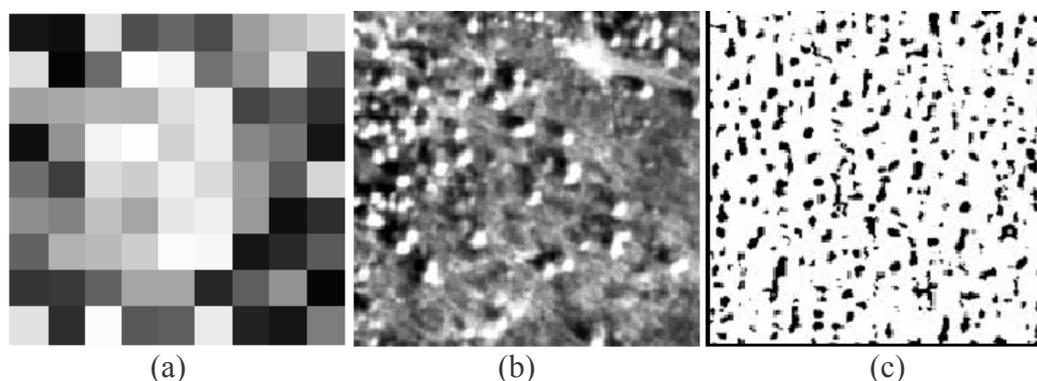


Figura 2.1 Detecção de copas de árvores por correlação de imagens. (a) Padrão de referência. (b) Imagem original (infravermelha). (c) Resultado alcançado. Adaptado de Stiteler (2000).

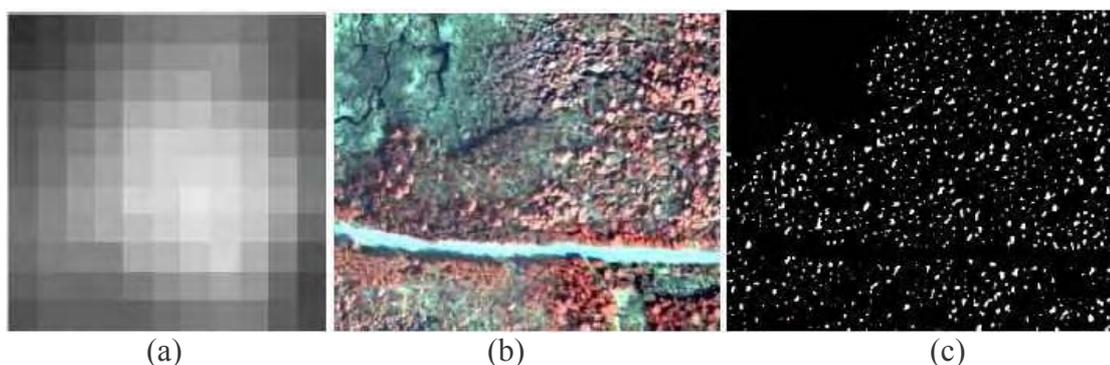


Figura 2.2 Detecção de copas de árvores por correlação de imagens. (a) Padrão de referência 13×13 suavizado. (b) Imagem original (infravermelha falsa-cor). (c) Resultado alcançado. Adaptado de Quackenbush *et al.* (2000).

Andersen *et al.* (2002) usaram imagens obtidas com dados LIDAR, adquiridos pelo sistema de varredura laser Saab TopEye, para detectar copas de árvores através de uma abordagem Bayesiana aplicada ao reconhecimento de objetos. Nesse caso, foi incorporado nesta abordagem um modelo de probabilidade *a priori*, estruturado numa cadeia de Markov, para organizar um conhecimento prévio sobre o comportamento dos alvos no espaço-objeto e no espaço-imagem e então, baseando-se nas configurações das distribuições dos objetos observados na imagem, foram feitas as inferências que possibilitaram detectar as copas de árvores.

Uma proposta interessante para esse problema é apresentada em Mayer (2000). Nesse trabalho foram usados dados (imagem) de um MDS derivado de imagens estéreo-fotométricas adquiridas pela câmara HRSC-A, elaborado pelo DLR com GSD de 50cm, apresentado na imagem da Figura 2.3a, onde pode ser observado que a área de teste

possui muita oscilação no relevo. Apesar dessa proposta necessitar da interação humana no processo para especificar alguns parâmetros e para avaliar o resultado obtido, ela se difere daquelas apresentadas anteriormente por considerar a influência da superfície do relevo coberto pelas árvores.

O método consiste na normalização do MDS (Seção 2.4) para eliminar a influência do relevo da superfície do terreno sobre a altura das árvores distribuídas sobre essa superfície. O MDS é normalizado ao ser subtraído do MDT correspondente. Essa operação resulta numa superfície de terreno horizontalmente plana. Assim, todos os elementos elevados, árvores no caso, têm origem num mesmo plano da superfície do terreno.

O MDT é derivado através de uma técnica de processamento do MDS, proposta pelo autor, composta de vários passos, os quais dependem da especificação de alguns parâmetros, como: a máxima distância que separa duas árvores vizinhas, dimensões de filtros morfológicos e valores de limiar. A Figura 2.3b apresenta os resultados alcançados.

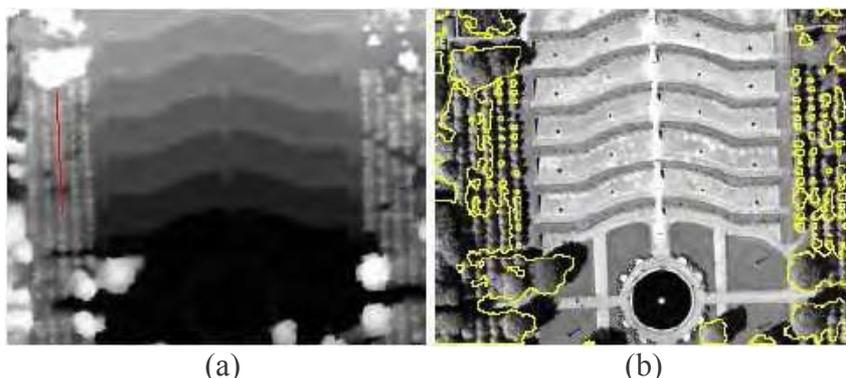


Figura 2.3 Detecção de copas de árvores por processamento de MDS. (a) MDS original. (b) Resultado alcançado mostrado sobre a imagem infravermelha. Adaptado de Mayer (2000).

Uma outra estratégia foi elaborada por Kraus e Rieger (1999) para detectar copas de árvores em áreas de florestas densas da Áustria usando dados temporais adquiridos pelo sensor de varredura laser e imageamento passivo ScaLARS (*Scanning Laser Altitude and Reflectance Sensor*). Dados do primeiro e do último pulso obtidos no final do período de inverno foram usados para extrair pontos sobre a superfície do terreno para derivar um MDT correspondente, uma vez que neste período do ano as árvores perdem parte de sua folhagem, permitindo uma maior penetração dos feixes laser incidentes, cujos retornos são registrados pelo sensor como dados no último retorno. No final do verão, um conjunto de novos dados foi adquirido. Os dados registrados no primeiro pulso dos dados adquiridos no verão foram então subtraídos do MDT, extraído com os dados adquiridos no inverno, para normalizar a superfície do terreno coberto pela vegetação densa. Com a superfície normalizada, as áreas cobertas por árvores puderam ser detectadas.

Kanda *et. al.* (2004) propuseram uma metodologia para detectar e classificar espécies de árvores, usando dados de imagens de região florestadas da região de Toyama – Japão, adquiridas com resolução espacial entre 7 e 10cm, pelo uso da câmara de vídeo SONY DCRTRV20 e por uma câmara equipada com filtro infravermelho, montadas em um helicóptero. A imagem correspondente à banda vermelha, depois de suavizada por um filtro passa-baixas, foi segmentada usando o operador *watershed* (BEUCHER e MEYER, 1992; DOUGHERTY, 1992; HEIJMANS, 1994; D'ORNELLAS, 2001)², aplicado sobre o gradiente dessa imagem com marcadores colocados sobre os mínimos regionais que correspondem aos centros das áreas sombreadas e aos centros das copas de árvores (Figura 2.4b). Duas ou mais regiões contíguas delimitadas pelas linhas de partição de águas obtidas com a aplicação do operador *watershed* com valor de brilho médio similares foram unidas (Figura 2.4c). Após esse processamento, essas regiões segmentadas foram submetidas a um processo de classificação supervisionada (máxima-verossimilhança) (Figura 2.4d) para determinar o tipo da árvore. Os atributos usados por esse processo de classificação foram: valores de textura (extraídos pelo método da matriz de co-ocorrência); valores do índice *NDVI* e; valores de brilho extraído do componente intensidade da imagem colorida.

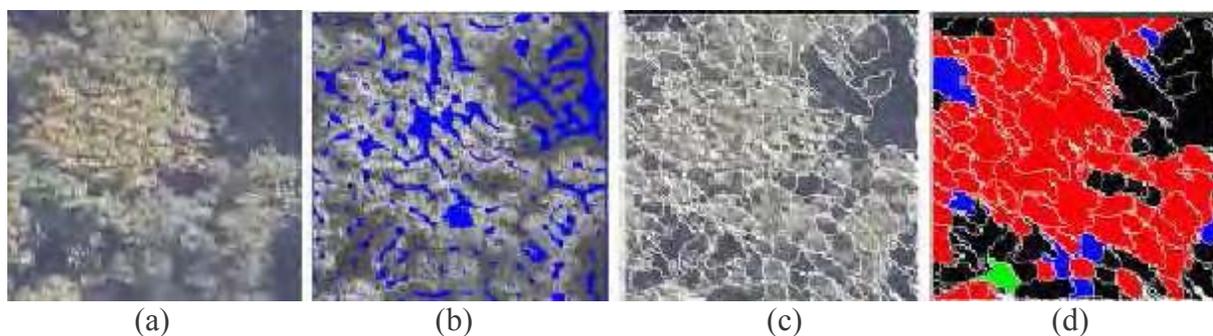


Figura 2.4 Detecção e classificação de espécies de árvores. (a) Imagem RGB original. (b) Marcadores definidos pelos mínimos regionais. (c) Resultado da segmentação *watershed* com união de regiões adjacentes similares. (d) Resultado da classificação. Adaptado de Kanda *et al.* (2004).

Muitos pesquisadores têm a vegetação como um problema a ser contornado para conseguir atingir os seus objetivos. Neste caso, a vegetação passa a ser um incômodo e o que se deseja é eliminar o máximo possível desse elemento do processo, não importando se é rasteira (grama, arbustos, etc.) ou elevada (árvores).

Quando se dispõe de imagens coloridas adquiridas no espectro visível e no infravermelho próximo esse problema é mais facilmente resolvido com a limiarização do

² Linhas de partição de águas.

NDVI. Geralmente, não é aplicado um critério bem definido para especificar esse valor de limiar, o qual depende da sensibilidade dos sensores usados para capturar a energia radiante refletida pelos alvos; da resolução espacial envolvida na aquisição da imagem; da resolução radiométrica do sensor e; da distância (altura) do sensor (devido à degradação promovida pelos efeitos atmosféricos). Por exemplo, Khoshelham (2004) usou 0,35 como valor de limiar aplicado sobre o *NDVI* obtido através do uso de imagens aéreas adquiridas com 50 cm de resolução espacial (não informa qual sensor). Sohn (2004) usou 0,80 aplicado ao *NDVI* para imagens adquiridas pelo satélite Ikonos com GSD de 1m – PSM (*Pan-Sharpned Multi-spectral*). Vögtle e Steinle (2000) também usaram o *NDVI*, mas não informam o valor de limiar usado. Schiewe (2000) usou o valor 0,15 sobre o *NDVI* computado com imagens da câmara HRSC-A adquiridas com GSD de 16cm.

Uma abordagem mais razoável é apresentada por Causey *et al.* (2005) que determinaram o valor de limiar através da análise do histograma produzido pelo *NDVI*, confiando que o *NDVI* sempre produzirá um histograma bi-modal e, que a parcela direita deste está associada somente com a vegetação verde.

Quando não se dispõe de uma imagem adquirida na faixa do infravermelho próximo, detectar a vegetação é um processo mais complicado. Esse é caso de Niederöst (2000), Gruen e Baltsavias (1997) que utilizaram a mesma estratégia para detectar vegetação em imagens coloridas adquiridas com GSD de 45cm de resolução espacial por câmaras fotogramétricas baseadas em filme, o qual foi posteriormente digitalizado (28micron). Além dos componentes *R* e *G* extraídos da imagem colorida (RGB)³ ainda, foram usados os seguintes atributos: (1) saturação das cores (extraído do sistema de cor HSI); (2) Informação de textura proposta por Braun (1999); (3) os componentes *L** (*brightness*) e *a** (*redness-greenness*) extraídos do sistema de cor CIELAB e; valores produzidos pelo índice *DoA* – *Degree of Artificiality* – Equação 2.1. Todos esses atributos foram submetidos ao algoritmo de agrupamento K-médias (*K-means clustering*) (REIS, 1997), para formar três classes: uma composta por pixels associados com vegetação; outra composta por pixels associados com regiões sombreadas e; uma terceira com pixels associados com outros alvos.

³ O termo componente é relativo à decomposição de uma imagem colorida qualquer considerando o sistema de cor RGB. Neste trabalho, a referência aos componentes RGB de uma imagem tem um significado mais restrito e se refere à decomposição das bandas espectrais *R*, *G* e *B* adquiridas nas faixas do espectro eletromagnético visível. Alguns sensores adquirem diretamente imagens coloridas RGB (IGN, DMC, Ultracam, etc.). Os sensores das câmaras HRSC-AX e ADS40 adquirem imagens relativas a cada faixa (*R*, *G* e *B*) do espectro eletromagnético visível. Neste caso, a denominação de bandas espectrais é mais correta que componentes da imagem colorida RGB. Mas, neste trabalho, para efeito de simplificação, todas são tratadas como componentes RGB ou, simplesmente, como imagens coloridas normais.

$$DoA = \frac{G - R}{G + R} \quad (2.1)$$

O índice *DoA* explora a diferença entre valores de brilho observados para vegetação verde registrados no componente verde (*G*) e no vermelho (*R*) do sistema RGB. A vegetação verde absorve mais energia relativa à faixa vermelha do espectro eletromagnético do que da faixa relativa ao verde. Assim, os valores de brilho registrados para vegetação verde no componente *G* são um pouco maiores que os respectivos valores registrados no componente *R*. Desta forma, o índice *DoA* consegue realçar a vegetação verde.

2.2 SOMBRAS

Considerando os sistemas de aquisição de imagens do tipo passivo, sombras são criadas pela oclusão da luz direta incidente sobre uma superfície por objetos que se elevam sobre essa superfície. O resultado dessa oclusão produz dois tipos de sombras: (a) sombras próprias, correspondentes ao(s) lado(s) do próprio objeto que promove a oclusão da luz incidente e que não são iluminados e; (b) sombras projetadas, correspondentes à projeção do próprio objeto que promove a oclusão da luz incidente sobre a superfície sobre a qual ele está elevado e/ou sobre outros objetos contidos nesta superfície. As sombras são classificadas em duas categorias: *umbra* e *penumbra*. *Umbra* corresponde às áreas sombreadas na qual a luz incidente foi totalmente bloqueada e, *penumbra* corresponde às áreas sombreadas na qual a luz incidente foi parcialmente bloqueada ou, fontes de luzes secundárias de baixa intensidade a iluminam (Figura 2.5) (DARE, 2005; POLIDORIO *et al.*, 2003b).

Para sistemas de imageamento passivo, sombras projetadas criam interferências na cena que podem promover: (a) degradação da resposta espectral dos alvos afetados; (b) conexão entre diferentes alvos, que na cena estão espacialmente separados; (c) distorção na forma geométrica dos elementos e; (d) perda total de um elemento.

Nem sempre a presença de sombras é prejudicial, por exemplo, Raviv *et al.* (1989) propuseram um método de reconstrução tridimensional de objetos fazendo relações geométricas entre as sombras projetadas, o ângulo de incidência da luz (ângulo de elevação solar) e a posição do objeto na imagem. Na fotointerpretação, sombras permitem inferir se determinados objetos são tridimensionais ou não.

Além dessas degradações, as áreas sombreadas realçam alguns efeitos atmosféricos que são capturados pelos sensores como se fossem respostas radiométricas dos alvos sombreados (efeito aditivo). Quando uma área completamente sombreada (*umbra*) é imageada, o sensor captura a energia proveniente desses efeitos atmosféricos e não a ausência

de resposta radiométrica dos alvos que estão sobre essa área. Uma ilustração das possibilidades de atuação dos efeitos atmosféricos sobre uma área intensamente sombreada é mostrada na Figura 2.5.

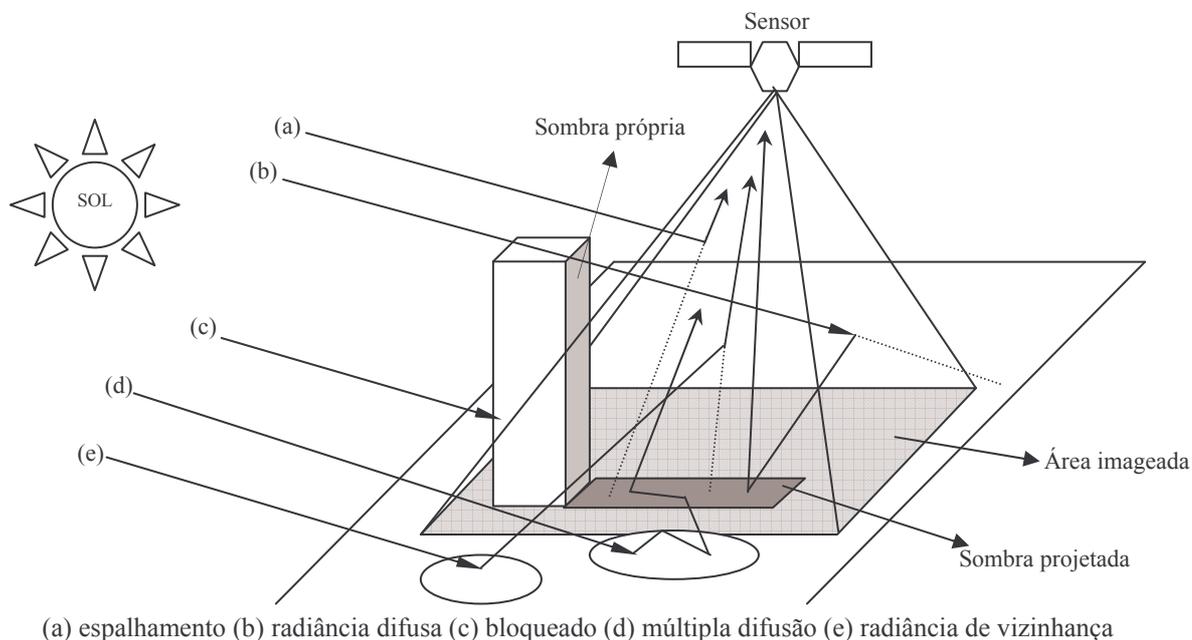


Figura 2.5 Ilustração dos efeitos atmosféricos sobre uma área intensamente sombreada.

A maior contribuição de radiação em uma área sombreada tipo *umbra* é dada pelo componente de espalhamento (linha 'a' da Figura 2.5). Polidorio *et al.* (2003b) mostraram que as regiões intensamente sombreadas possuem baixa intensidade luminosa, devido ao bloqueio da luz incidente, e são saturadas com cores correspondentes ao violeta e azul do espectro eletromagnético visível, devido ao espalhamento atmosférico de Rayleigh, pois, nesse caso de imageamento de áreas intensamente sombreadas a energia que chega ao sensor é proveniente da própria onda eletromagnética espalhada e não o resultado da interação da irradiação solar com um alvo específico. Como as ondas de menor comprimento têm maior probabilidade de serem espalhadas, e no espectro visível as ondas relativas à cor azul têm o menor comprimento de onda, as regiões intensamente sombreadas são mais saturadas por cores dessa faixa de energia eletromagnética.

Pela atuação dos fenômenos atmosféricos mostrados na Figura 2.5 pode-se concluir que a existência de *umbras* em imagens aéreas é praticamente impossível. No mínimo o sensor deve capturar a energia proveniente desses fenômenos. Na Seção 4.2.2 deste trabalho é apresentado o comportamento radiométrico de áreas sombreadas.

Para imagens adquiridas de plataformas orbitais, esse comportamento se apresenta mais estável. Entretanto, para imagens adquiridas de menores altitudes, como

sensores a bordo de aeronaves, com resolução espacial submétrica, nas quais um maior número de detalhes pode ser distinguido, as sombras apresentam um comportamento instável, por depender, principalmente, da natureza das superfícies onde elas são projetadas e das fontes de luzes secundárias que a iluminam indiretamente.

Um estudo sobre propriedades espectrais e geométricas de sombras é feito por Salvador *et al.* (2004) que propuseram ainda um método automático de segmentação de sombras projetadas que explora essas propriedades em imagens coloridas (estáticas e seqüência de vídeo). O método se baseia numa análise descendente (de um esquema de geração de hipóteses e testes) organizada em três níveis: (1) gerar hipótese de sombra para qualquer região que escurecer uma superfície; (2) validar as regiões detectadas como sombras usando propriedades geométricas e de invariância de cor das sombras e; (3) confirmar ou rejeitar a hipótese inicial para cada região detectada.

Santos *et al.* (2006) propuseram um filtro espacial passa-altas de alto reforço (GONZALEZ e WOOD, 1992) para detectar regiões sombreadas em uma imagem aérea em tons de cinza, adquiridas com a câmara Sony DSC-717. A filtragem da imagem original é feita por convolução. O filtro é uma janela 3×3 que tem associado ao elemento central o valor 4 e os demais $-1/8$. Entretanto, para esse filtro produzir resultados efetivos deve haver um contraste elevado entre a região sombreada e a região circunvizinha.

Wang e Madani (2005) apresentaram um método automático de detecção de pontos de sombras em imagens pancromáticas adquiridas pela câmara DMC da Z/I, usando também os respectivos MDSs dessas imagens, com o objetivo de melhorar o processo automático de aerotriangulação. Esse método é baseado no modelo de pontos de sombra e usa propriedades radiométricas (extraídas da imagem pancromática) e geométricas (extraídas do MDS). A propriedade radiométrica leva em consideração que os pixels das bordas das sombras têm um padrão distinto de alto contraste em relação aos vizinhos que não são sombras, os quais são detectados pela limiarização da magnitude do gradiente (computado em quatro direções). A propriedade geométrica considera que a superfície que envolve uma região sombreada (no MDS) não é uma superfície suavizada e que os pontos dentro dessa região têm elevação menor que a elevação que projetou essa sombra então, deve ser encontrada na região circunvizinha dessa sombra uma área onde, nitidamente, o terreno muda de inclinação, usando um MDS local, computado por correspondência entre imagens (estéreo-par). Então, todas as regiões que possuem essas duas propriedades são consideradas sombreadas.

Uma proposta, baseada em análises de valores espectrais e informações de

contexto extraídas de regiões sombreadas e de suas respectivas vizinhanças, é feita em Massalabi *et al.* (2004). Essa proposta é aplicada em imagens multiespectrais adquiridas pelos sensores do satélite Ikonos. Os autores propuseram ainda um método de restauração das propriedades radiométricas dos elementos que foram cobertos por sombras. Esse método é aplicado à imagem pancromática e usa os resultados obtidos por um método de detecção. O método de detecção consiste em: (1) detectar todas as regiões com potencial de serem sombras (feito por valor de limiar, considerando que sombras são escuras); (2) para cada área obtida, calcular os seus atributos espectrais (média e desvio padrão); (3) seus atributos de forma (comprimento, largura, área, fator de compactação e orientação) e; (4) obter informações contextuais (vizinhança). Para cada região potencial detectada é feita uma análise local de histograma e dos atributos de forma para refinar o processo de detecção, discriminando sombras próprias, sombras projetadas e penumbras. A orientação de cada lado da região segmentada é comparada com a direção do azimute solar. Se a diferença entre ambas for pequena, a chance de essa região estar sombreada aumenta senão, é descartada. As regiões “sobreviventes” são confirmadas como sombras após uma análise de forma geométrica de suas respectivas vizinhanças, localizadas na direção Sol-sombra, sentido Sol.

Polidorio *et al.* (2003b) apresentaram um modelo para detectar sombras em imagens aéreas e orbitais coloridas. Esse modelo é explicado pelos baixos valores de brilho (I) promovido pelo bloqueio da incidência direta da luz e pela alta saturação (S) provocada pelo espalhamento atmosférico de Rayleigh, o qual satura as regiões sombreadas com as cores violeta e azul. Explorando o sistema de cor HSI, através da operação $I - S \leq k$, onde k é um valor de limiar, que permite detectar sombras. Essa técnica frequentemente confunde vegetação verde-escura, corpos d’água e outros elementos de baixa radiância com sombras.

Tsai (2003) apresentou um método para detectar e restaurar regiões sombreadas em imagens aéreas em tons de cinza. A imagem original é recursivamente particionada em sub-imagens em uma estrutura *quadtree* até que o histograma de cada sub-imagem tenha uma distribuição bi-modal. Segundo o autor, cada sub-imagem conterá sombras na parte escura da imagem e, não-sombras na parte clara. Então, usando uma função de maximização de custos proposta por Otsu (1979), obtêm-se valores de limiar adaptativos para cada sub-imagem capaz de separar as duas classes. Usando o algoritmo de crescimento de regiões, adotando como sementes o ponto mais escuro de cada sub-imagem, as regiões de sombras vizinhas são conectadas.

Tsai (2006) propõe um novo método de segmentação de sombras em imagens aéreas RGB, explorando atributos de cor disponibilizados pelos componentes H

(matiz) e V (intensidade) em vários sistemas de cor nos quais as informações de cor e intensidade luminosa não são acopladas entre si (HSI, HSV, HCV, YIQ e YC_bC_r). Para segmentar as regiões sombreadas o autor propôs um índice de realce de sombras chamado razão espectral, dado por $(H+1)/(V+1)$. Esse índice explora as propriedades da sombra modeladas por Polidorio *et al.* (2003b): baixa intensidade luminosa e; alta saturação com as cores violeta e azul. No sistema de cor HSI as cores azuladas produzem os valores de matizes mais elevados assim, a razão espectral proposta por Tsai promove um realce significativo para essas cores, bem como para o verde escuro e para o cinza escuro.

A segmentação das regiões sombreadas é feita aplicando um valor ótimo de limiar obtido pela técnica proposta por Otsu (1979). Tsai (2006) faz um estudo comparativo entre alguns métodos propostos e, também, propõe um método para restaurar regiões sombreadas em imagens RGB. Um exemplo dos resultados produzidos pelo método de detecção e restauração de regiões sombreadas proposto por Tsai (2006) é apresentado na Figura 2.6.

Dare (2005) propôs uma técnica para detectar regiões sombreadas em imagens pancromáticas com alta resolução radiométrica (11bits) adquiridas pelos sensores dos satélites Ikonos e Quickbird de regiões urbanas densas. Dos 2048 níveis de cinza possíveis nessas imagens, o autor constatou que os pixels das regiões sombreadas ocupam o intervalo $[0, 255]$, ou seja, todos os pixels que têm valor de brilho maior que 255 são descartados do processo de detecção. Essa operação e o fato de que são imagens de regiões urbanas densas fez o autor presumir que os valores resultantes dessa operação estejam sempre distribuídos em um histograma bi-modal e, que a parte esquerda desse histograma está associado com pixels de sombra, ou corpos d'água e, dessa forma, um valor ótimo de limiar pode ser encontrado. Para discriminar corpos d'água e regiões sombreadas, cada região conexa foi rotulada e calculada medidas estatísticas (média e variância) sobre os valores de brilho dos pixels que compõem cada uma dessas regiões. A variância e a média para corpos d'água são menores que as que são observadas em regiões sombreadas. O uso adequado dessa constatação permite discriminar entre esses dois elementos. No entanto, o autor não especifica como se sabe quando corpos d'água estão presentes na imagem para adotar essa estratégia de discriminação. Um outro problema se tem quando um corpo d'água e uma região sombreada estão conectados entre si. Como eles formam uma única região, não há como separá-los com a estratégia proposta.



Figura 2.6 Detecção e restauração de áreas sombreadas. Adaptado de Tsai (2006).

Usando imagens aéreas adquiridas pela câmara ADS40 (os testes foram efetuados usando imagens pancromática e infravermelha), Mandhavan *et al.* (2004) propuseram um método não paramétrico para detectar e restaurar regiões sombreadas, usando a média móvel (FUKUNAGA e HOSTETLER,1975) para filtrar e segmentar as regiões sombreadas. O menor valor produzido pela média móvel sobre os valores de brilho é usado para detectar as regiões sombreadas (Figura 2.7).

Filtros espaciais lineares do tipo auto-reforço (GONZALEZ e WOOD, 1992) como aquele usado por Santos *et al.* (2006) e não lineares (MYLER e WEEKS, 1993) do tipo média móvel, média geométrica, média harmônica, etc. aplicados numa imagem em tons de cinza para detectar áreas sombreadas alcançam resultados muito próximos e geralmente, confundem corpos d'água, superfícies escuras e vegetação (exceto na imagem infravermelha) com regiões sombreadas. Filtros desse tipo realçam regiões sombreadas e simplificam o contexto da imagem. Entretanto, somente com uso dessas ferramentas e desses atributos, em muitos casos, não é suficiente para produzir resultados satisfatórios, devido ao fato das regiões sombreadas apresentarem comportamento radiométrico não-constante. Um resultado produzido pela aplicação do filtro da média móvel é mostrado na Figura 2.7.

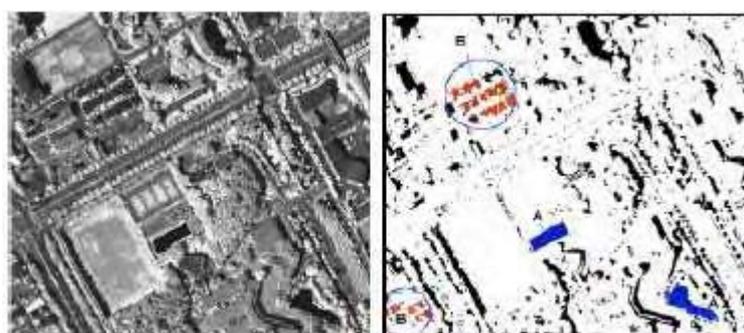


Figura 2.7 Detecção de regiões sombreadas pelo filtro da média móvel numa imagem infravermelha (ADS40). Os resultados em vermelho (telhados escuros) e em azul (corpos d'água) são falso-positivos. Adaptado de Mandhavan *et al.* (2004).

Usando dados de imagens coloridas adquiridas pela câmara ADS40 e do respectivo MDS, Li *et al.* (2004) propuseram uma metodologia automática para detectar e restaurar sombras projetadas. As sombras projetadas são computadas através do MDS e do ângulo de elevação solar por traçado de raios (*ray tracing*), uma técnica muito aplicada em computação gráfica (PEROCHE, 1993), usando o modelo geométrico da ADS40, para construir um mapa de visibilidade (FELGUEIRAS e CÂMARA, 2001) do qual são extraídas as regiões de sombras projetadas. Um refinamento posterior é feito usando medidas estatísticas sobre a imagem em tons de cinza.

Susuki *et al.* (2000) apresentaram um método que trata as frequências espaciais das componentes RGB separadamente através de um modelo probabilístico para detectar sombras.

Huang *et al.* (2004) apresentou uma modelagem, no espaço-imagem, capaz de descrever sombras, baseada no modelo de iluminação de Phong (PHONG, 1975) e empregou valores de limiar no matiz (H), no matiz-azul e na diferença entre o matiz-verde e matiz-azul, nesta seqüência, para detectar regiões sombreadas.

2.3 EDIFICAÇÕES

A geração de modelos virtuais de cidades é uma atividade de pesquisa recente (há poucos anos passados), a qual começou a envolver e a reunir pesquisadores das mais diversas áreas: Processamento de Imagens; Fotogrametria; Sensoriamento Remoto; Sistemas de Informação Geográfica; Cartografia; etc., por existir uma grande demanda em torno desse produto pelos mais variados tipos usuários. Uma cidade virtual é utilizada em: turismo, arquitetura, cartografia, planejamento e controle urbano; planejamento e controle ambiental; telecomunicações; defesa civil; uso para fins militares; estimativa de censo demográfico; navegação assistida; etc.

Entre os grandes desafios para se construir uma cidade virtual, está a modelagem de edificações. Para modelar uma edificação, usando imagens, é necessário: detectá-la; reconstruí-la e; por fim descrevê-la (conforme as definições de Grün (2000) – Seção 1.1). Essa ordem de atividades pode determinar uma forma de se abordar esse problema, entretanto, esse caminho é de complexidade crescente. Pesquisadores como Förstner (1999) têm afirmado que somente com o uso pleno dos recursos e técnicas de Fotogrametria é que problemas dessa natureza podem ser resolvidos de uma forma economicamente viável. Entretanto, mesmo com o uso das tecnologias mais avançadas e o constante desenvolvimento e aprimoramento dos procedimentos e técnicas em Fotogrametria,

o problema detectar e extrair edificações presentes em imagens de áreas urbanas ainda é considerado como um dos maiores problemas de Visão Computacional e Fotogrametria (ELAKSHER *et al.*, 2002).

No contexto deste problema, os dados de elevação se mostram como peças fundamentais nas abordagens de sua solução, especialmente o MDS. A maior contribuição extraída de um MDS está na obtenção de elevações candidatas que estejam associadas com uma edificação.

O MDS pode ser derivado por processos tradicionais da Fotogrametria (por correlação de imagens) ou através de dados adquiridos pelos modernos sensores de varredura laser. Entretanto, existe uma correlação direta entre a precisão usada para representar o MDS e o sucesso obtido na detecção automática das edificações (MA, 2004).

Detectar edificações é um processo que permite diferenciar pontos que estão sobre edificações com pontos que estão sobre outros elementos (principalmente pontos que estão sobre árvores e partes elevadas do relevo). Considerando o MDS, esse processo pode envolver a computação e a comparação de tamanhos de regiões, análise de formas geométricas e medições de variação nos dados de elevação. Dados de imageamento, especialmente multiespectrais, são particularmente úteis neste processo, pois eles permitem obter atributos que ajudam na compreensão do contexto da cena, como os dados de refletância, que podem ser usados em processos de agrupamentos e discriminação de alvos envolvidos no processo (ELBERINK e MASS, 2000).

Segundo Ma (2004) a partir de 1980, quando foi inserido o sistema de varredura laser, a comunidade fotogramétrica começou a usar com maior frequência dados adquiridos por sistemas LIDAR, em abordagens de detecção e extração de edificações, em detrimento aos dados MDS derivados de imagens fotogramétricas, devido a sua maior precisão. Entretanto, a partir de 2000 as modernas câmaras fotogramétricas digitais foram inseridas no mercado. Dotadas com maior poder de imageamento que as câmaras tradicionais pela incorporação de sistemas de georreferenciamento e de navegação inercial, pela possibilidade de cobertura do terreno com 100% de sobreposição em três imagens adquiridas em diferentes ângulos de visada (como as câmaras HRSC-A, HRSC-AX e AXW e ADS40), resolução radiométrica maior que 8bits/banda (como as câmaras DMC, Ultracam e ADS40) e com maior resolução espectral cobrindo as faixas do espectro visível e infravermelho próximo, tais câmaras estão possibilitando a extração de MDSs com qualidade superior que aqueles extraídos das imagens adquiridas por câmaras e processos fotogramétricos tradicionais. Atualmente, já existem sensores que incorporam diversas tecnologias, como o

FALCON II da Toposys que, além de obter imagens multiespectrais ainda, incorpora um sensor de imageamento ativo de varredura laser.

No seu trabalho de detecção e extração de edificações, Niederöst (2000) usou imagens ortorretificadas RGB com GSD de 45cm, um MDS correspondente extraído dessas imagens e o MDT correspondente extraído pela digitalização de cartas topográficas (escala 1:25.000), fornecidas pelo governo Suíço (Swiss Federal Institute of Topography), com precisão altimétrica de 1,5m para as regiões de platô. Usou também dados cadastrais (2D) não atualizados de edificações, contendo: localizações, orientações e formas geométricas aproximadas dessas edificações.

Esse conjunto de dados foi usado para detectar edificações considerando a seguinte estratégia: (a) os dados cadastrais das edificações foram usados para obter uma aproximação inicial de cada edificação; (b) O MDS e o MDT foram usados para normalizar a superfície do terreno (nMDS – ver Seção 2.4) do qual são extraídas regiões candidatas para edificações (usando um valor de limiar h) e; (c) da ortoimagem RGB foram extraídos atributos radiométricos, de cor e de textura para detectar árvores e regiões sombreadas e atributos de bordas (intensidade e direção do gradiente).

Os dados cadastrais foram usados para confirmar a existência de edificações registradas (se não houve alterações nas áreas construídas). Atributos extraídos da ortofoto: saturação, textura, componentes do sistema de cor CIELAB e valores produzidos pelo índice de artificialidade DoA (Equação 2.1), foram usados para detectar regiões sombreadas e regiões cobertas por vegetação, usando o algoritmo de agrupamento K-médias. As regiões de vegetação e sombras detectadas foram usadas para eliminar falsos candidatos à edificação, as quais foram detectadas pela limiarização do nMDS. Um exemplo de candidatos à edificação obtidos com o uso desta estratégia é apresentado na Figura 2.8.



Figura 2.8 Resultado da detecção de candidatos a edificações produzidas pela estratégia de Niederöst. Adaptado de Niederöst (2000).

Após eliminar todos os candidatos à edificação que tinham registro correspondente nos dados cadastrais, foi aplicada uma técnica baseada em restrições

geométricas (a edificação deve ser um quadrilátero) sobre as linhas de bordas do gradiente (Sobel) da imagem. As linhas de cada candidato são envolvidas por uma janela quadrada. Várias transformações aplicadas à janela (escala, rotação e translação) e a extração de medidas (chamadas *score*) das linhas do gradiente envolvidas pela janela são usadas para determinar se cada candidato é, ou não, uma edificação. Na imagem mostrada na Figura 2.8 existem 141 edificações (NIEDERÖST, 2000) entre as quais 117 (82%) faziam parte dos dados cadastrais. Das 24 novas edificações existentes (sem cadastro), o método proposto detectou 9 (38% de taxa de sucesso).

O trabalho apresentado por Niederöst (2000) ilustra a dificuldade em se propor métodos que obtenham resultados de elevada acurácia na detecção de edificações. Zimmermann (2000), Grün (2000), Eidenbenz *et al.* (2000), Gruen (1998), Gruen e Baltsavias (1997) e Gülch (1997), praticamente, adotaram essas mesmas estratégias, procedimentos, dados e materiais para resolver problemas relacionados com a detecção e a extração de edificações. Os resultados obtidos foram equivalentes aos que foram alcançados por Niederöst (2000).

A adoção de ‘estratégias’ desse tipo nem sempre conduz para bons resultados. Resultados negativos mostram que adaptar uma estratégia de processamento voltada para particularidades de uma determinada cena não funciona, além de introduzir outras implicações, como: em função dessas estratégias particulares, as imagens são adquiridas em altitude elevada, diminuindo a escala da foto, para provocar o benefício do ‘desaparecimento’ de pequenos detalhes que destoam da esperada homogeneidade na cor e na textura de diferentes alvos. Por outro lado, ocorrem eventuais perdas de detalhes geométricos desses mesmos alvos os quais são igualmente importantes para o processo que esses autores desenvolveram. Segundo Fradkin *et al.* (1999), abordagens desse tipo sempre conduzem para resultados não confiáveis, que requerem o uso de um passo de verificação adicional e, constantemente, falham em áreas urbanas densas. Deve-se também considerar que agrupamento e/ou análises de homogeneidade de atributos e de fatores de forma, ou geométricos, são altamente dependentes da qualidade dos dados, além de serem alternativas complicadas, não são capazes de cobrir todas as possibilidades de variação estrutural existente entre os diversos modelos arquitetônicos de edificações. Um método restrito também é apresentado em Qiu *et al.* (2004).

Qiu *et al.* (2004) propuseram um algoritmo para detectar edificações, baseado em múltiplos atributos extraídos das imagens multiespectrais, adquirida pelos sensores do satélite Quickbird (composição colorida verdadeira), com imposição de restrições

como considerar que: edificações têm formato retangular; não haver oclusões significativas e; serem radiometricamente homogêneas (cor e textura). Os atributos usados foram: dados de cor e textura (os autores assumem que os telhados das edificações são construídos com limitados tipos de materiais e, portanto, as cores e texturas também são limitadas) e dados de segmentos de linhas retas extraídos pela transformada de Hough (os autores propuseram neste trabalho um detector de bordas aplicado a imagens coloridas chamado EMD – *The Earth Mover's Distance*). Os segmentos de retas detectados que, potencialmente, formam retângulos são escolhidos e, análises posteriores de medidas extraídas de cada retângulo formado são usadas para determinar a pertinência de uma edificação (largura e comprimento do retângulo, medidas estatísticas de homogeneidade de textura e cor associadas com o interior do retângulo). Figura 2.9 mostra resultados obtidos.



Figura 2.9 Resultados produzidos pela técnica introduzida por Qiu. Adaptado de Qiu *et al.* (2004).

Fadkin *et al.* (1999) apresentaram uma abordagem pouco tradicional baseada no uso de múltiplas imagens coloridas (adquiridas em ângulos estéreos) de aéreas urbanas densas. Vários modelos de elevação foram extraídos das possíveis combinações de estéreo-par entre essas múltiplas imagens usando atributos de cor para fazer a correspondência entre imagens. Através da aplicação de restrições geométricas, medidas de similaridade e propriedades espaciais aplicadas aos pontos 3D (MDSs) e restrições de atributos de cores, aplicadas nas imagens coloridas, as fachadas das edificações são detectadas e extraídas. Esses dados de fachada são utilizados, posteriormente, como importante atributo para detectar cada edificação.

Cord *et al.* (1999) usaram ortoimagens aéreas monocromáticas com GSD de 8cm e o respectivo MDS, extraído por correlação de imagens, para detectar edificações aplicando uma abordagem hierárquica. Essa abordagem se baseia no agrupamento de pixels

do MDS em três classes: vegetação; edificações e; artefatos (principalmente aqueles que estão no nível da superfície do terreno). A segmentação altimétrica do MDS é feita usando um critério de altitude entre dois pixels vizinhos, se a diferença for menor que h , então eles são agrupados numa mesma região plana (definido pela média dos pixels integrantes) assim, várias regiões rotuladas são formadas. A condição para formar a classe de artefatos é assumir que todo o terreno tem superfície horizontalmente plana. Como no contexto global não é possível assumir a validade dessa condição então, a imagem foi subdividida em várias outras (cada sub-imagem corresponde a $160\text{m} \times 160\text{m}$ – no caso, cada sub-imagem tem 2000×2000 pixels) para minimizar as variações globais do relevo (espera-se que localmente as transições do relevo sejam mais suaves). Entre todas as regiões rotuladas existentes em uma sub-imagem, aquela com menor altura média (m) define a base de limiarização de altura entre pixels elevados e não-elevados. Todos os valores de altura maiores que $m + t$ (t é um valor de limiar de altura) é considerado uma elevação sobre o terreno. Nesse ponto, as elevações sobre o terreno ou são edificações ou árvores. Para separar esses dois elementos, é feita uma análise da oscilação dos valores altimétricos nas regiões rotuladas vizinhas. Se existir muita oscilação é uma árvore, se for mais comportado é uma edificação.

Alharthy e Bethel (2002) usaram imagens derivadas de dados LIDAR adquiridos pelo sensor Optech ALTM 1210, explorando as propriedades das intensidades do primeiro e do último retorno para detectar edificações (Figuras 2.10a e 2.10b). A operação “primeiro retorno subtraída do último retorno” foi usada para detectar a parte da vegetação que o feixe divergente laser consegue penetrar e, assim localizar as regiões onde elas estão presentes – Figura 2.10c.

Entretanto, essa operação também realça as bordas de elementos elevados rígidos (edificações - causadas por múltiplos retornos). Essa discrepância é eliminada pelas linhas do gradiente da imagem do último retorno (associado com um valor de limiar). A vegetação remanescente, no último retorno, é eliminada por uma filtragem local (uma vez que são conhecidas as regiões onde elas estão presentes) – Figura 2.10d. Esse processo de filtragem resulta num MDS modificado no qual, somente dados das superfícies do terreno e das edificações estão representadas. Esse MDS modificado é usado para extrair o MDT correspondente, aplicando o algoritmo de crescimento de região, o qual é usado para normalizar o próprio MDS modificado (Figura 2.10e). O resultado obtido permite detectar edificações, ao se usar um pequeno valor de limiar.

Elberink e Maas (2000) Fazem um estudo das possibilidades de uso de dados LIDAR para determinação do MDT e para detectar elementos (vegetação, edificações e

rodovias) usando dados de retorno de três pulsos laser: o primeiro, o intermediário (reflectância) e o último retorno (Figura 2.11). O método usado para detectar os elementos de interesse consiste na aplicação do algoritmo de agrupamento K-médias, usando como atributo uma medida de textura anisotrópica (para explorar o comportamento mais suave de dados de altura de edificações em contraste com o comportamento de altura de árvores) extraída dos dados de altura pelo método da matriz de co-ocorrência e medida de contraste inter-pixel. Nesse trabalho são apresentados estudos e resultados obtidos com o uso de dados adquiridos com dois sistemas sensores: Optech ALTM 1210 e FLI-MAP.

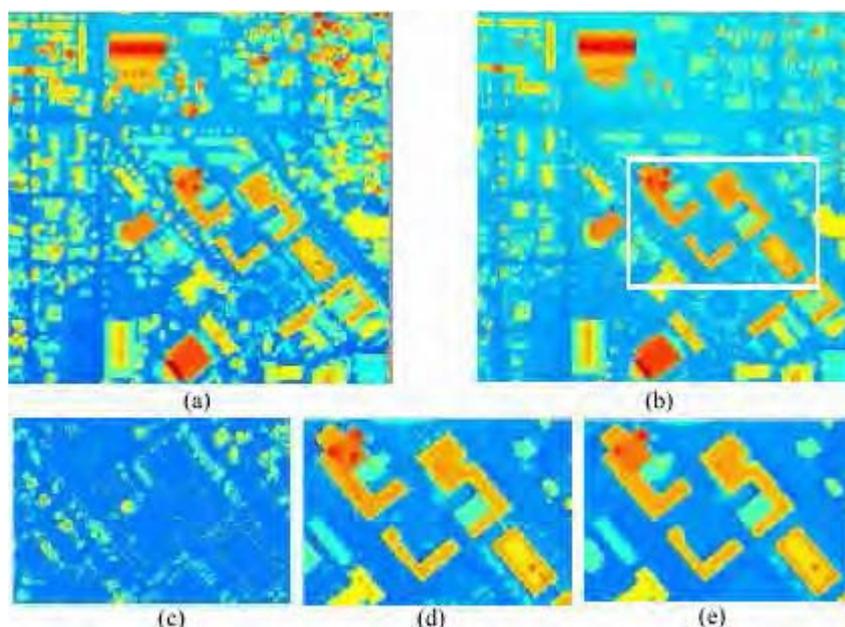


Figura 2.10 Detecção de edificações usando dados LIDAR. (a) e (b) Imagens derivadas dos dados do primeiro e último retorno, respectivamente (falsa-cor). (c) Resultado do primeiro menos o último retorno. (d) Resultado da filtragem local. (e) MDS modificado e normalizado. Adaptado de Alharthy e Bethel (2002).

Wang (2000) apresentou uma abordagem para detecção e extração de edificações usando um MDS gerado a partir de dados adquiridos por um sensor de varredura laser. Para detectar as edificações, usou bordas obtidas no MDS, aplicando Sobel, as quais foram classificadas para distinguir bordas de edificações das bordas de outros objetos. Para isso, foram usados atributos geométricos das linhas das bordas como: ortogonalidade e paralelismo entre linhas, medidas de simetria e circularidade (fatores de forma).

Vögtle e Steinle (2000) usaram dados LIDAR (somente do primeiro retorno) e dados de imagens adquiridas nas faixas do espectro visível e infravermelho próximo (o autor não especifica quais sensores foram usados). Os dados LIDAR do primeiro pulso foram interpolados para gerar um MDS (grade regular) e as imagens multiespectrais

foram transformadas em ortoimagens para prover o perfeito registro com o MDS (Figuras 2.12a e 2.12b).

As bandas infravermelha e vermelha da imagem multiespectral foram usadas para detectar áreas cobertas por vegetação, aplicando um valor de limiar, não especificado, sobre o *NDVI*. O MDS foi normalizado (nMDS) através de um processo de filtragem (não especificado, mas faz referência para um outro trabalho) – Figura 2.12c. Para contornar o problema da segmentação da vegetação (relacionado com sombras nas copas de árvores), foi aplicado o operador morfológico de fechamento. Esse resultado foi usado para eliminar as áreas cobertas por vegetação no nMDS – Figura 2.12d. Sobre esse último resultado foi aplicado o algoritmo de crescimento de região para formar classes baseadas num critério de similaridade de altura. Os elementos agrupados em cada região são analisados por fatores de forma e características geométricas planas para decidir se realmente são edificações (largura, comprimento, área, paralelismo de linhas, formas retangulares, etc.).



Figura 2.11 Imagens de dados LIDAR adquiridos pelo sensor Optech ALTM 1210. Primeiro (intensidade), segundo (reflectância) e último (intensidade) retorno, respectivamente. Adaptado de Elberink e Maas (2000).

Khoshelham (2004) usou praticamente a mesma estratégia que Vögtle e Steinle (2000), exceto que o valor de limiar aplicado ao *NDVI* foi, neste caso, 0,35 e o algoritmo aplicado para formar as regiões foi divisão e fusão.

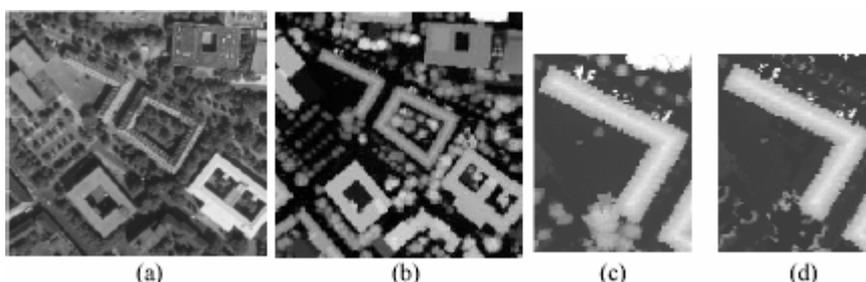


Figura 2.12 Fusão de dados entre imagens LIDAR e multiespectral para detectar edificações. (a) Imagem pancromática. (b) Imagem do MDE extraída de dados LIDAR (primeiro retorno) (c) Detalhe do nMDS. (d) Detalhe do nMDS subtraído da vegetação detectada. Adaptado de Vögtle e Steinle (2000).

Sohn (2004) usou imagens multiespectrais PSM (*Pan-Sharpened*

Multispectral) adquiridas pelos sensores do satélite Ikonos com 1m de GSD, as quais foram ortorretificadas com precisão de ~1,9m (Figura 2.13a) e imagem do MDS correspondente gerada por dados adquiridos no primeiro retorno do sensor laser OPTEC 1020 com densidade de 0,1ponto/m² (Figura 2.13b). Todos os pontos do MDS com elevação superior a 4m sobre o terreno foram segmentados, obtendo um MDS modificado. As elevações detectadas foram modeladas genericamente por um mosaico de polígonos convexos (Figura 2.13c). Áreas cobertas por vegetação foram detectadas aplicando o valor de limiar 0,8 sobre o *NDVI*, as quais foram eliminadas do MDS modificado. Análises posteriores das linhas dos polígonos formados pela modelagem completam a detecção (Figura 2.13d).

Ma (2004) apresentou um estudo e propostas para detectar e extrair edificações usando dados LIDAR com 1m de resolução. Para detectar edificações, ele normalizou o MDS (nMDS) – neste trabalho, o autor faz uma comparação entre três métodos para gerar o MDT correspondente: ajuste planar de superfície; análise de salto de altura e; filtragem morfológica. O método de análise de salto de altura (*height-jump algorithm*) é baseado na observação que objetos elevados têm valores de altura maior que seus vizinhos ou que a superfície do terreno, e que os pontos de suas bordas têm valores de altura significativamente diferentes dos seus vizinhos (que se espera ser o nível da superfície do terreno). O ajuste planar de superfície (*planar-fitting algorithm*) se baseia na condição hipotética da superfície do terreno poder ser observada como uma superfície plana, se admitido um nível de tolerância, assim as regiões que se enquadram nessa condição são delimitadas.

Sobre o nMDS obtido, Ma (2004) aplicou um valor de limiar de altura (3 metros) para extrair as elevações, eliminando objetos como veículos, arbustos, imperfeições no nMDS, etc. As árvores remanescentes são detectadas pelo ajuste planar de superfície, uma vez que existe muita oscilação de altura localizada sobre essas estruturas e a condição hipotética do ajuste planar para essa superfície não pode ser verificada e, nesse caso, muitos planos pequenos com diferentes valores de altura são formados sobre essa superfície, os quais podem ser detectados. Segundo Ma (2004), o uso dessa estratégia para detectar árvores têm o inconveniente de eliminar edificações com telhados no formato de arcos.

Schiewe (2000) usou os dados de imagens multiespectrais adquiridos pela câmara HRSC-A (GSD de 16cm) e o respectivo MDS (GSD de 50cm) extraído por correlação

de imagens. O MDS foi filtrado pelo operador morfológico de abertura por compressão⁴, para gerar o MDS normalizado (nMDS) correspondente. Para detectar áreas cobertas por vegetação (W) e ao mesmo tempo detectar as edificações (B), Schiewe usou várias medidas de índices indicadores (probabilidade) extraídas do $NDVI$, do MDS e do nMDS. A decisão da classe de pertinência de um pixel (edificação, vegetação ou outros) é feita com base em estimativas de probabilidades *a posteriori*, calculadas com os valores dos índices indicadores obtidos.

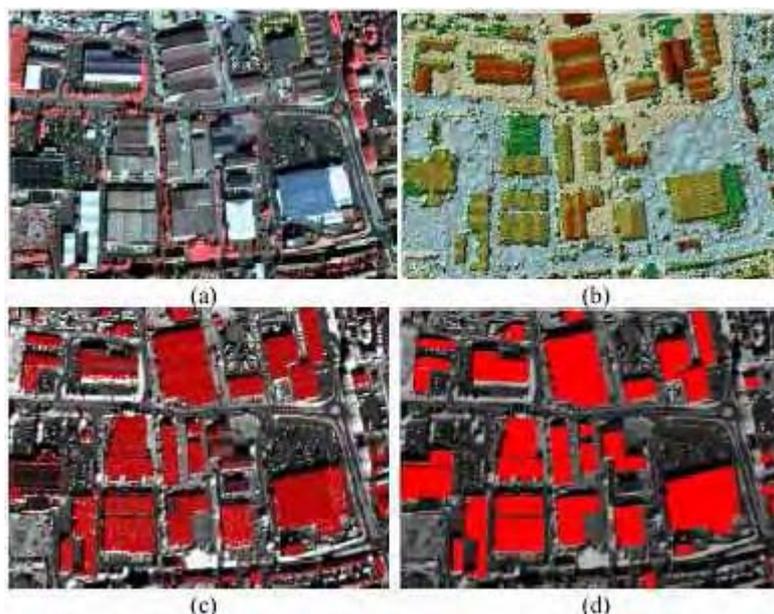


Figura 2.13 Fusão de dados entre imagens LIDAR e multiespectral para detectar edificações. (a) Imagem Ikonos PSM infravermelha falsa-cor. (b) MDS LIDAR falsa-cor. (c) Resultado da modelagem geométrica por polígonos convexos. (d) Resultado final. Adaptado de Sohn (2004).

Os índices indicadores propostos por Schiewe são:

- $p(B \cup W / \text{nMDS})$ – é o valor da probabilidade condicional de um pixel pertencer (ou não) a um objeto elevado: árvore (W) ou edificação (B), dado por:

$$p(B \cup W / \text{nMDS}) = \begin{cases} \frac{\text{nMDS} - 2}{\max(\text{nMDS}) - 2} & \text{se } \text{nMDS} > 2(\text{metros}) \\ 0 & \text{caso contrário} \end{cases}$$

- $p(B / \theta)$ – Schiewe formalizou a hipótese (h_0) que a densidade da distribuição da

⁴ A abertura por compressão usa dois elementos estruturantes com tamanhos diferentes, os quais são aplicados iterativamente sobre uma mesma região da imagem. Em cada iteração realizada, as dimensões do maior elemento estruturante são diminuídas enquanto as do menor são aumentadas. O processo iterativo termina quando os dois elementos estruturantes tiverem as mesmas dimensões. Entretanto, é mostrado na Seção 2.4 que o resultado produzido pela abertura morfológica não é dependente apenas do tamanho do elemento estruturante. O comportamento do relevo também influi no resultado.

direção do gradiente é maior para áreas arborizadas do que para edifícios e outros objetos. Esse valor de densidade é dado pelo total de pixels adjacentes (vizinhança de um pixel) com direção de gradiente maior que 50° (o autor considera que este valor é maior que a inclinação de um telhado) existentes no interior de uma janela quadrada (equivalente a 10m^2). Assumindo que θ tem distribuição normal então, a probabilidade de um pixel pertencer a uma edificação pode ser determinada usando a quantidade Z dada pela distribuição de Poisson e pelo teste de rejeição de h_0 . Os valores μ_B e σ_B são determinados por treinamento (conhecimento *a priori*). $p(B/\theta)$ é dado por:

$$p(B/\theta) = Z(h_0; \mu_B : \sigma_B)$$

- $p(W/\text{NDVI})$ é a probabilidade espectral de um pixel pertencer a uma área de vegetação (W), dado por:

$$p(W/\text{NDVI}) = \begin{cases} \text{NDVI se } \text{NDVI} > 0,15 \\ 0 & \text{caso contrário} \end{cases}$$

A câmara HRSC-A adquire imagens multiespectrais nas faixas espectrais relativas ao azul, verde, vermelho e infravermelho próximo (além da pancromática e das estéreo-fotométricas). Então, pergunta-se: por que Schiwe fez toda essa análise para detectar vegetação e edificações? Uma simples limiarização no *NDVI* não resolveria o problema?.

Este trabalho não prioriza a proposta de Schiwe em detrimento das propostas de outros autores. O que nos interessa são os motivos que conduziram o autor em propor esse método, uma vez que o nosso trabalho usa dados adquiridos pela câmara HRSC-AX que é descendente da HRSC-A⁵.

As faixas espectrais usadas para adquirir as imagens nas faixas do vermelho e infravermelho pela câmara HRSC-A, 730 – 770nm e 925 – 1015nm, respectivamente, não são adequadas para computar valores *NDVI*. Para a faixa vermelha, as câmaras ADS40, IGN, DMC e Ultracam operam entre 605 e 690nm (vegetação verde absorve muita energia dessa faixa do espectro) e para a faixa infravermelha elas operam entre 685 e 900nm (a vegetação verde reflete muita energia desta faixa do espectro). As imagens das faixas relativas ao vermelho e infravermelho adquiridas pela câmara HRSC-A, praticamente, cobrem faixas espectrais relativas ao infravermelho próximo. Ambas realçam a vegetação verde e a infravermelha realça solo exposto e alguns tipos de materiais (concreto, telhados, etc.). Como o *NDVI* se baseia no salto de valores de reflectância entre a imagem vermelha e a

⁵ A câmara HRSC-A foi originalmente projetada para ser usada como um sensor orbital pela missão espacial russa MARS para adquirir imagens do planeta Marte.

infravermelha para vegetação verde, no caso das imagens adquiridas pela HRSC-A esse índice tem menor confiabilidade. No modelo AX houve um reajuste dessas faixas espectrais: 635 – 685nm para a faixa da imagem vermelha e 770 – 810nm para a infravermelha. Entretanto, nessas duas câmaras existe um problema de desvio radiométrico causado pela diferença de ângulo de visada entre os sensores vermelho e infravermelho: na câmara HRSC-A esta diferença é de quase 40° e na HRSC-AX é quase 20°.

Schiewe constatou ainda que um simples corte no *NDVI* também não consegue separar a vegetação de uma porção de áreas sombreadas. Essa constatação é discutida na Seção 4.2.3.4. Um outro problema que foi constatado é a falta de precisão na estimação de valores de altura para regiões sombreadas, devido à alta correlação entre pixels de sombras e, mesmo fora de regiões sombreadas existe problema de cobertura do MDS (omissão e comissão), como mostra a Figura 2.14.

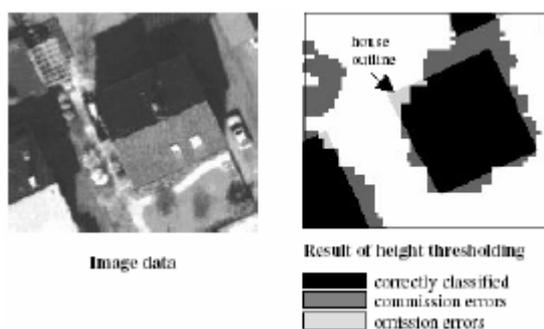


Figura 2.14 Tipos de erros cometidos na detecção de elevações devido à precisão de cobertura do MDS. Adaptado de Schiewe (2000).

2.4 EXTRAÇÃO DO MDT ATRAVÉS DO MDS

Um Modelo Digital de Terreno (MDT) têm muitas aplicações práticas como: detectar áreas de risco de inundação; construção de curvas de nível e micro bacias em áreas agrícolas; planejamento de construção de estradas, redes de água e esgoto, tubulações de gás, etc. Um MDT de uma determinada área pode ser extraído de cartas topográficas existentes para esta área ou, realizando um trabalho de campo específico para coletar pontos estratégicos sobre essa área. Uma alternativa é gerar um MDS através de imagens aéreas ou de pontos adquiridos por sensores laser (ou radar) e extrair deste produto o MDT correspondente.

Derivar o MDT através de dados de altimetria disponibilizados pelo MDS de forma automática não é uma tarefa simples de ser executada. A abordagem geral usada na maioria dos métodos propostos segue os seguintes passos: (a) coletar pontos sobre o MDS que

representem a superfície topográfica do terreno; (b) interpolar os pontos coletados para obter uma superfície contínua e; (3) analisar e corrigir o resultado obtido.

O passo (a) é o mais complicado, uma vez que não existem critérios que definam, formalmente, quais pontos do MDS estão sobre a superfície do terreno. Esse conceito é intuitivo e, em certos casos, adaptado para contemplar circunstâncias particulares. Outra questão a ser considerada é a real representatividade desses pontos coletados. Nem sempre, o volume de pontos coletados implica numa representação adequada do MDT no espaço-objeto. Em regiões onde o relevo da superfície sofre muita oscilação de altura é necessário que seja coletado um número maior de pontos, entretanto, esses pontos devem estar estrategicamente localizados sobre a superfície desse relevo como: pontos de máximos e mínimos locais e pontos de inflexão e, se houver uma descontinuidade da superfície, uma linha de quebra, uma maior densidade de pontos é necessária para representá-la com precisão.

Algumas aplicações, como detectar elementos que se elevam sobre a superfície do terreno, *a priori*, não exige a obtenção de um MDT exato. Para essas aplicações, na maioria dos casos, é suficiente encontrar uma superfície aproximada que seja capaz de normalizar o MDS.

A normalização do MDS (Figura 2.15) é uma operação sobre o próprio MDS que consiste em eliminar a influência da superfície do relevo em relação à altura dos elementos que estão distribuídos sobre essa superfície (como árvores e edificações).

O MDS normalizado (nMDS) é obtido através da subtração do MDS de seu MDT (Modelo Digital de Terreno) correspondente (Equação 2.2). Se o MDS e MDT correspondentes forem exatos, o nMDS obtido será um MDS derivado para uma superfície de terreno horizontalmente plana. Ou seja, neste caso, os valores de altura de todos os elementos elevados que cobrem a superfície do terreno não são mais influenciados pela topografia da superfície do terreno.

$$\text{nMDS} = \text{MDS} - \text{MDT} \quad (2.2)$$

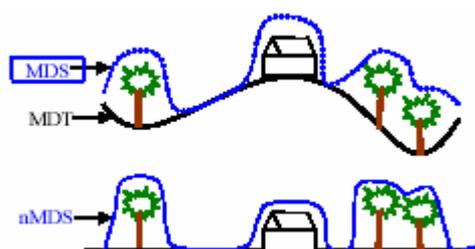


Figura 2.15 Ilustração do processo de geração do nMDS.

O problema para se aplicar a Equação 2.2 é que, nem sempre, se dispõe do MDT correspondente ao MDS que se deseja normalizar. Neste caso, esse MDT, pode ser

extraído do próprio MDS. Essa extração, atualmente, pode ser feita de quatro formas: (a) através da aplicação de processos de filtragem de imagem (ex. filtros morfológicos); (b) através de predições estatísticas; (c) através de análises e segmentação de imagem (ex. crescimento de regiões, quadtree); (d) através da interpolação de pontos criteriosamente amostrados sobre o MDS.

Na prática, é difícil conseguir um MDT que consiga, exatamente, normalizar o MDS. Quanto mais acidentado for o terreno, mais difícil é essa tarefa. Na maioria dos casos, o que se consegue é suavizar o MDS de maneira que a superfície do terreno resultante possa ser considerada plana, ou o mais próximo disto. Apesar dessa dificuldade, muitos pesquisadores (MAYER, 2000; GRUEN e BALTSAVIAS; 1997, GRUEN, 1998) fizeram uso desse procedimento.

A Figura 2.16 ilustra um exemplo de obtenção de um nMDS. O resultado apresentado nesta figura é fruto de pesquisas realizadas para cumprir com os objetivos deste trabalho. O método proposto está detalhado na Seção 4.3.

No caso da aplicação de métodos de interpolação para extrair o MDT do próprio MDS, a maioria dos métodos propostos para detectar (ou amostrar) pontos do terreno produz um conjunto de pontos irregularmente espaçados os quais podem se dispostos numa grade de ajuste triangular irregular (TIN – *Triangular Irregular Network*) obtida pela triangulação de Delaunay. Essa rede de triângulos pode ser interpolada em uma grade retangular regular, a qual pode ser transformada para gerar uma representação do tipo imagem em tons de cinza.

Uma alternativa, que dispensa a coleta de pontos estratégicos, é o uso de filtros específicos, como os morfológicos, que são usados para suavizar o MDS de tal forma que este fique normalizado (nMDS), assume-se que todos os pontos que estão abaixo de um valor de limiar de altura pertencem à superfície do terreno os quais são usados para recuperar os valores de altura no MDS original e, com isso, obter o MDT correspondente.

Muitos trabalhos de extração do MDT a partir do MDS usando operadores morfológicos foram propostos (WEIDNER e FÖRSTNER (1995); KILIAN *et al.* (1996); VOSSelman (2000); ROGGERO (2001); ZHANG *et al.* (2003)). Entretanto, resultados práticos obtidos com a aplicação desses filtros demonstram uma aplicabilidade restrita. Esses filtros não produzem resultados adequados quando aplicados em imagens em que a superfície do relevo muda abruptamente. Além disso, os resultados produzidos pelo uso de filtros morfológicos são dependentes das dimensões do elemento estruturante usado.

O filtro de abertura morfológica é o mais usado para normalizar o MDS.

Entretanto, se aplicado em uma superfície de relevo que não possa ser considerada suave, o uso desses filtros nem sempre produz resultados satisfatórios (Figura 2.17). Mesmo se a superfície for considerada suave, existe uma dependência da qualidade do resultado obtido com o dimensionamento do elemento estruturante. Se o elemento estruturante é sub dimensionado, o resultado produzido sobre o MDS pode ser insuficientemente suavizado (Figura 2.17b), o qual não permite estabelecer facilidades para inferir sobre a natureza das elevações (nesse caso, saber se um ponto do DSM está no nível do terreno ou não). Se super dimensionado, muitos detalhes de elevação são eliminados pela suavização excessiva das elevações e formação de grandes regiões planas (principalmente edificações e árvores) – (Figura 2.17c).

Entretanto, a Morfologia Matemática dispõe de um conjunto muito grande de possibilidades, as quais, se exploradas corretamente podem produzir resultados eficazes. Um exemplo de melhor exploração dos recursos da Morfologia Matemática está na aplicação do conceito de distância geodésica e reconstrução morfológica por dilatação geodésica usada por Arefi e Hahn (2005). A maior vantagem da reconstrução morfológica, sobre os operadores e filtros tradicionais da Morfologia Matemática, é que a dilatação geodésica usa um elemento estruturante elementar isotrópico, ou seja, as dimensões do elemento estruturante não influenciam no resultado final (mais detalhes em Heijmans (1994); Vincent (1993); Heijmans (1999); Goutsias e Batman (1999)).

Um método estatístico chamado “predição linear” foi empregado em alguns trabalhos para segmentar dados LIDAR com o objetivo de gerar MDTs (LOHMANN e KOCH (1999); LOHMANN, *et al.* (2000); KRAUS e PFEIFER (1998); LEE e YOUNAN (2003); KRAUS e OTEPKA (2005)). Esse método é caracterizado por um processo iterativo, no qual, a precisão do MDT gerado aumenta em cada aproximação realizada. Entretanto, para se aplicar esse método é necessário ter uma estimativa do MDT inicial. Cada fase iterativa do processo está baseada em correlações espaciais entre pontos vizinhos do MDT, estimado na iteração anterior, com os respectivos pontos do MDS (medidas de covariância local). A comparação entre o MDS e o MDT gerado (ou predito pelo uso desse) fornece medidas de resíduos. Essas medidas são usadas para estabelecer pesos de ajuste, os quais são reajustados em cada iteração do processo por análise da covariância. Esses valores de pesos são usados para gerar um novo MDT correspondente ao MDS em questão. Se o MDT gerado não tiver a precisão desejada (feita por operador humano), uma nova iteração desse processo deve ser feita.

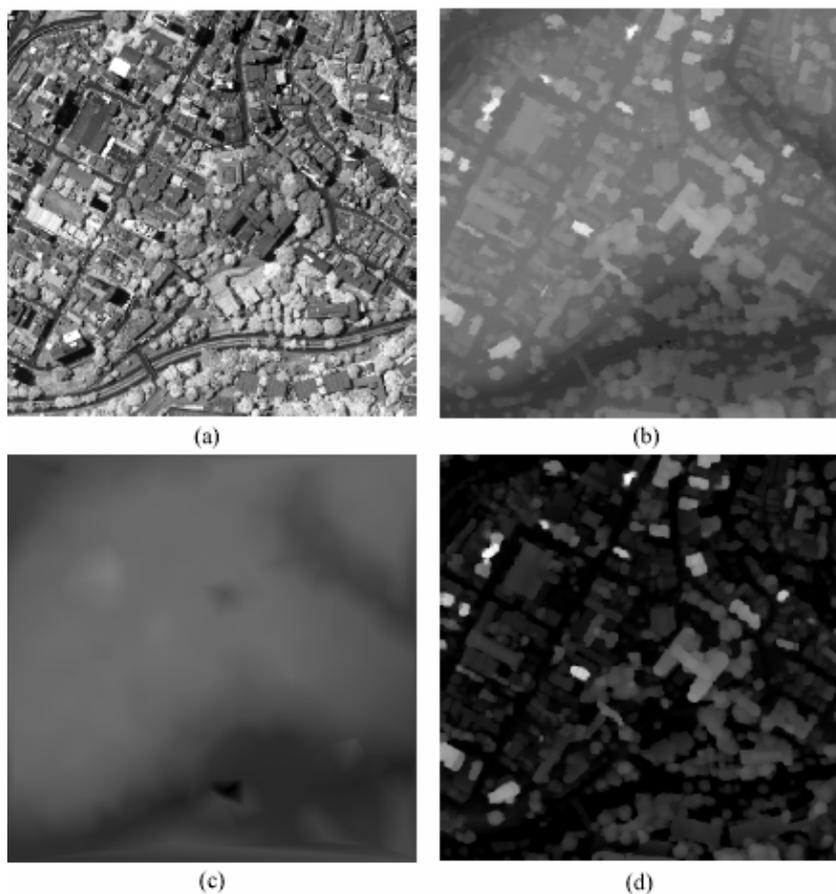


Figura 2.16 Exemplo de normalização do MDS. (a) Imagem adquirida na faixa do infravermelho próximo pela câmara HRSC-AX. (b) MDS correspondente extraído das imagens estéreo-fotométricas (HRSC-AX). (c) MDT extraído do MDS. (d) nMDS gerado.

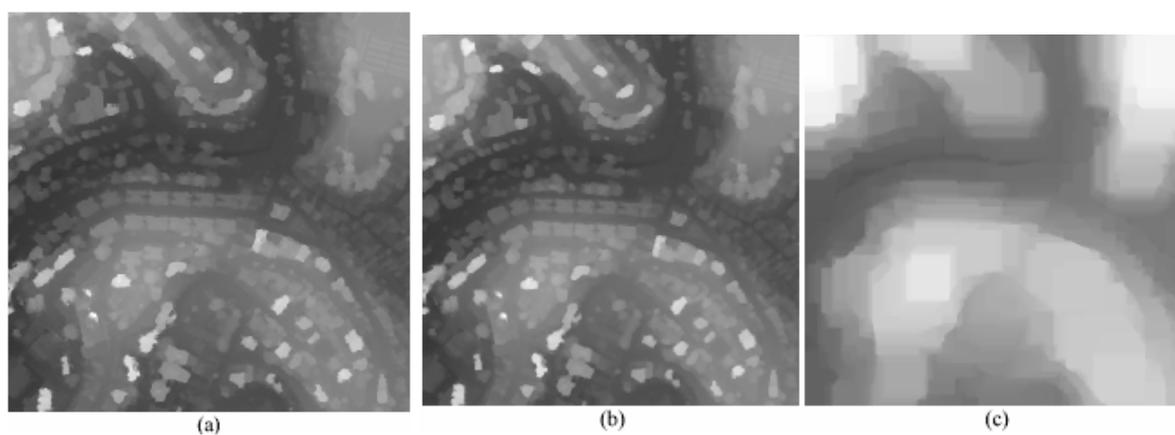


Figura 2.17 Exemplos de aplicação do filtro morfológico de abertura sobre um MDS com superfície de relevo não suave para derivar o nMDS. (a) MDS original. (b) Abertura do MDS por um elemento estruturante retangular 7×7 . (c) Abertura do MDS por um elemento estruturante retangular 101×101 .

Vosselman (2000), ao usar dados brutos LIDAR propôs um método baseado num filtro de inclinação. Um ponto da superfície do terreno é detectado se entre todos os

vetores possíveis entre esse ponto e seus vizinhos, aquele vetor com valor de máxima inclinação não exceder a um limiar predefinido. O problema desse método está em como se define o significado de vizinhança de um ponto para tratar pontos esparsos LIDAR.

Matikainen *et al.* (2003) pré-agrupou dados LIDAR, para separar pontos elevados (árvores e edificações) de pontos considerados sobre a superfície do terreno, aplicando o algoritmo de crescimento de regiões sobre os dados de altura. As elevações detectadas foram validadas por uma classificação fuzzy usando como atributos: textura (matriz de co-ocorrência de nível de cinza); homogeneidade de altura de cada região e; fatores de análise de forma de cada região.

Sithole e Vosselman (2005), usando dados LIDAR (bruto), propuseram um método de filtragem de nuvens de pontos. Esse método forma segmentos de nuvens de pontos com similaridade de altura (de acordo com a suavidade da superfície que eles representam). Dois pontos são considerados pertencentes a um mesmo plano de superfície se existir um caminho adjacente suave entre eles. Entretanto, essa estratégia só é possível se não existir descontinuidade na superfície, ou se essas descontinuidades puderem ser contornadas através de um caminho secundário (promovido por rampas e pontes) que conecta pontos de ambos os lados da superfície. Cada segmento obtido é classificado em uma de duas classes: elevação ou terreno; usando como atributos os relacionamentos geométricos entre os pontos do segmento que está sendo analisado e os pontos dos segmentos circunvizinhos.

Jordan *et al.* (2002) usou um MDS derivado de imagens aéreas adquiridas com alta resolução (25cm) pela câmara IGN. O MDT foi computado como um modelo de frequência de ordem baixa, o qual permite excluir altas frequências (edifícios e outras estruturas artificiais). O MDT foi modelado como uma decomposição de ordem N numa base de funções harmônicas 2D do MDS.

Woestyne *et al.* (2004) apresentou um procedimento semi-automático para extrair o MDT do MDS, o qual foi obtido por correspondência entre imagens (estéreo-par). A linha geral desse procedimento consiste em segmentar o MDS em regiões com altura similares, formando superfícies conectadas. As maiores regiões são consideradas como correspondentes à superfície do terreno. Essas regiões foram formadas por algoritmos de segmentação tipo *watershed*.

Ma (2004) usou dois métodos para detectar pontos localizados no nível da superfície do terreno usando um MDS gerado por dados LIDAR com 1m de resolução espacial: (a) o método de análise de salto de altura (*height-jump algorithm*), baseado nas observações que: (1) objetos elevados têm valores de altura maior que seus vizinhos

(considerando que esses vizinhos são pontos sobre o terreno) e; (2) os pontos situados nas bordas de uma elevação têm valores de altura significativamente diferentes dos seus vizinhos (que se espera ser o nível da superfície do terreno) e; (b) o método de ajuste planar de superfície (*planar-fitting algorithm*) que se baseia na condição hipotética de que partes menores da superfície do terreno podem ser observadas como superfícies planas, se admitido um nível de tolerância, assim aquelas regiões que se enquadram nesta condição são delimitadas. O resultado da intersecção dos pontos sobre o terreno obtidos pelos dois métodos foi usado para gerar o MDT correspondente.

Jiang (2004) aplicou os mapas auto-organizáveis de Kohonen (SOM – *self-organizing maps*), um método de agrupamento não-supervisionado (TSO e MATHER 2001), para agrupar pontos de dados altimétricos esparsos (edificações, árvores e no nível do terreno) adquiridos por sensores de varredura laser.

2.5 CORPOS D'ÁGUA

A água tem como característica refletir uma parcela muito pequena da energia eletromagnética incidente, pois, corpos d'água têm a capacidade de transmitir, absorver e dispersar a maior parcela dessa energia. O espectro da radiação refletida pela água ocupa, em geral, a faixa de comprimentos de onda entre 400-900nm, o que equivale à faixa do visível ao infravermelho próximo. Corpos d'água mais puros são mais evidentes por apresentarem baixa reflectância, principalmente nas faixas espectrais iguais ou superiores ao infravermelho próximo (Figura 2.18). A presença de sedimentos em suspensão na água promove uma resposta espectral semelhante àquela emitida por solo úmido. Neste caso, a reflectância é intensificada pela presença de partículas de solo em suspensão e, ao mesmo tempo, reduzida pelas propriedades óptica da água (absorção, transmissão e dispersão).

Interações da energia eletromagnética com a água são complexas e dependem de uma série de fatores como: a reflexão especular (rugosidade da superfície); tipo e concentração de materiais em suspensão (clorofila, argilas e nutrientes); tipo e constituição do fundo do corpo d'água e; variáveis climatológicas. A atuação desses fatores altera o comportamento espectral padrão esperado para corpos d'água (CHUVIECO, 1990). Um estudo físico-matemático das propriedades ópticas da água é apresentado em Haltrin (2005).

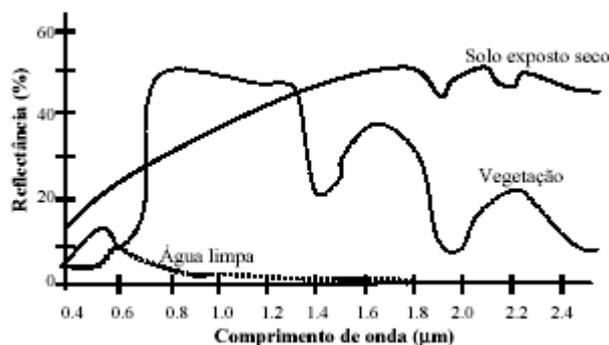


Figura 2.18 Comportamento espectral da água limpa, solo exposto seco e vegetação verde. Adaptado de Lillesand e Kiefer (2000).

O *NDVI* realça a vegetação verde explorando os baixos valores de reflectância desse alvo na faixa relativa ao vermelho do espectro eletromagnético e valores mais elevados na faixa do infravermelho próximo. Propor um índice de realce para corpos d'água é mais complicado devido aos baixos valores de reflectância observados para esse alvo ao longo de todo o espectro eletromagnético. Mesmo assim, devido ao pequeno salto de reflectância existente para corpos d'água em imagens adquiridas nas faixas do vermelho e infravermelho próximo, o *NDVI* consegue promover contraste para corpos d'água (Figura 2.19e).

Gao (1996) propôs o índice *NDWI* (*Normalized Difference Water Index*), que explora um pequeno salto nos valores de reflectância existente entre a faixa do vermelho (600 – 700nm) e infravermelho médio (1100 – 1800nm). Existem poucos sensores com capacidade de obter imagens com abrangência nessas faixas espectrais. Entre esses poucos, estão aqueles a bordo dos satélites Landsat TM e SPOT 4 e 5 e AVIRIS (aerotransportado). Para imagens LandSat essas faixas espectrais estão cobertas pelos sensores das bandas 3 e 5 e, neste caso, o índice proposto por Gao é dado por $NDWI = (B3 - B5) / (B3 + B5)$. Um resultado da aplicação deste índice é mostrado na Figura 2.19b. No caso de imagens Landsat, a simples soma com saturação das imagens das bandas *B4* e *B5*, adquiridas pelos sensores do Landsat, promovem um realce significativo para corpos d'água (Figura 2.19f). Gao usou esse índice em estudos de determinação do grau de estresse da massa foliar verde.

Para sensores com resolução espectral menor, com capacidade de cobrir a faixa do espectro visível e a faixa do infravermelho próximo entre 700 – 900nm (caso de sensores dos satélites CBERS, Ikonos e Quickbird e das câmaras aerotransportadas ADS40, HRSC-AX, IGN, DMC e Ultracam), o realce de corpos d'água é uma tarefa mais complicada.

McFeeters (1998) propôs o índice *NDWI* (mesmo nome daquele proposto por Gao) que usa valores de reflectância registrados na banda verde (*G*) e infravermelho

próximo (*NIR*) para computar esse índice de realce de corpos d'água pela diferença normalizada. O índice de McFeeters é dado por $NDWI = (G - NIR)/(G + NIR)$ (Figura 2.19c). Esse índice foi usado por McFeeters para detectar e delinear corpos d'água.

Polidorio *et al.* (2004) constataram, através de observações empíricas, que a média da razão do salto de reflectância entre os valores observados na banda verde (*G*) e infravermelho próximo (*NIR*) é da ordem de 4, ou $G \approx 4NIR$. Dessa forma, projetaram um índice para realce de corpos d'água chamado *WWI* (*Weighted Water Index*). Espera-se que esse índice seja capaz de acomodar os pixels relativos aos corpos d'água em torno do valor zero, e, para os demais alvos, sejam produzidos valores negativos (Equação 2.3) (Figura 2.19d). Esse índice foi usado em Polidorio *et al.* (2005a) para detectar e discriminar nuvens, áreas sombreadas e corpos d'água em imagens CBERS e Landsat (Figura 2.20). Em Polidorio *et al.* (2005b) esse índice foi usado para estimar e corrigir a degradação radiométrica sofrida por imagens CBERS e Landsat devido ao espalhamento e à absorção atmosférica (Figura 2.21). Em Polidorio *et al.* (2005c) esse índice foi usado para delinear corpos d'água usando imagens temporais CBERS e Landsat.

$$WWI = \frac{G - 4NIR}{G + 4NIR} \quad (2.3)$$

A inserção de dados adquiridos por câmaras digitais multiespectrais aerotransportadas começou a ocorrer num passado muito recente (por volta do ano 2000). Devido aos custos elevados dessas câmaras e de seus sistemas complementares e, por exigir a aplicação de novos conceitos operacionais, as câmaras fotogramétricas tradicionais ainda dominam a maior parte do mercado.

O realce de alvos específicos em dados de imageamento através da aplicação de índices usando imagens coloridas (RGB) é mais difícil de obter, uma vez que os componentes *R*, *G* e *B* são altamente correlacionados. Niederöst (2000), Gruen e Baltsavias (1997) usaram o índice *DoA* – *Degree of Artificiality* (Equação 2.1) e Polidorio *et al.* (2003a) propuseram o índice *NandA* – *Natural and Artificial features* (Equação 2.4) para aumentar o contraste entre elementos naturais (vegetação, sombras, solo exposto e corpos d'água) e elementos artificiais (telhados de edificações, asfalto, concreto, etc.).

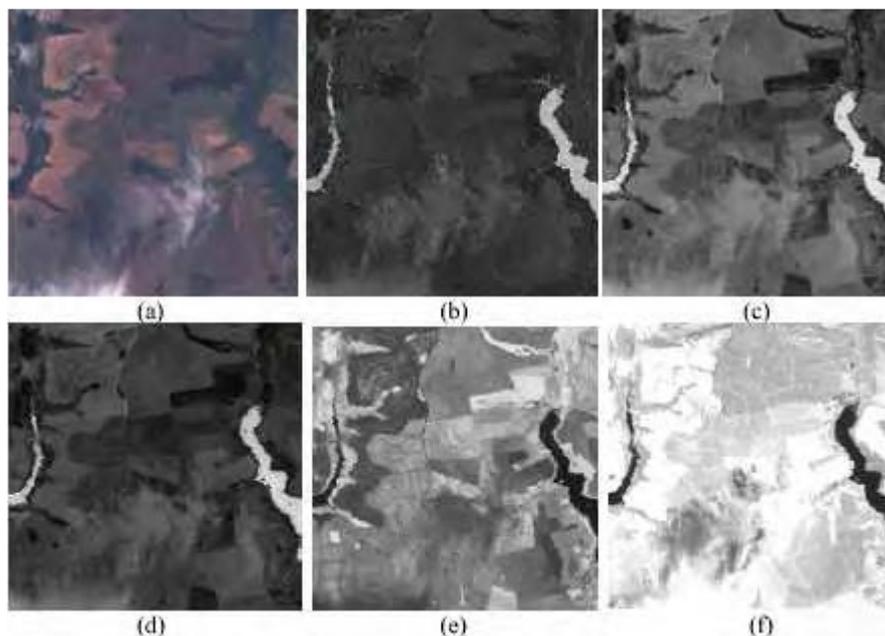


Figura 2.19 Imagem original Landsat TM – composição colorida R3G2B1. (b) *NDWI* proposto por Gao (1996). (c) *NDWI* proposto por McFeeters (1998). (d) *WWI* proposto por Polidorio *et al.* (2004). (e) *NDVI* proposto por Rouse *et al.* (1973). (f) Resultado da soma com saturação (B4 + B5).

Apesar dos índices *DoA* e *NandA* não apresentarem resultados com a qualidade que apresentam o *NDVI* e o *WWI*, eles permitem extrair informações que podem ajudar no conhecimento do contexto da imagem (por exemplo, estimar um índice de ocupação do solo por elementos artificiais). Niederöst (2000) usou o *DoA* para detectar a presença de vegetação verde. Zanin *et al.* (2005) usaram o *NandA* para detectar pontos sementes para extração de rodovias. Resultados dos realces produzidos pelos índices *NandA* e *DoA* são mostrados na Figura 2.22.

$$NandA = G - (R + B) \quad (2.4)$$

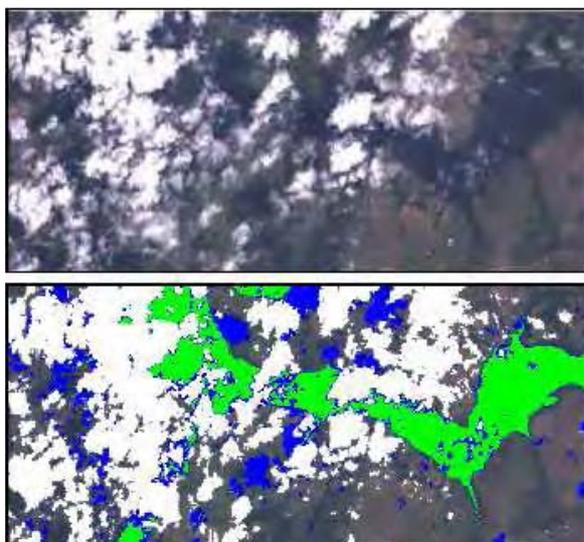


Figura 2.20 Resultado da detecção de nuvens, áreas sombreadas e corpos d'água em imagens Landsat (R3G2B1). Adaptado de Polidorio *et al.* (2005a).



Figura 2.21 Resultado da correção radiométrica em imagem CBERS (R3G2B1). Adaptado de Polidorio *et al.* (2005b).

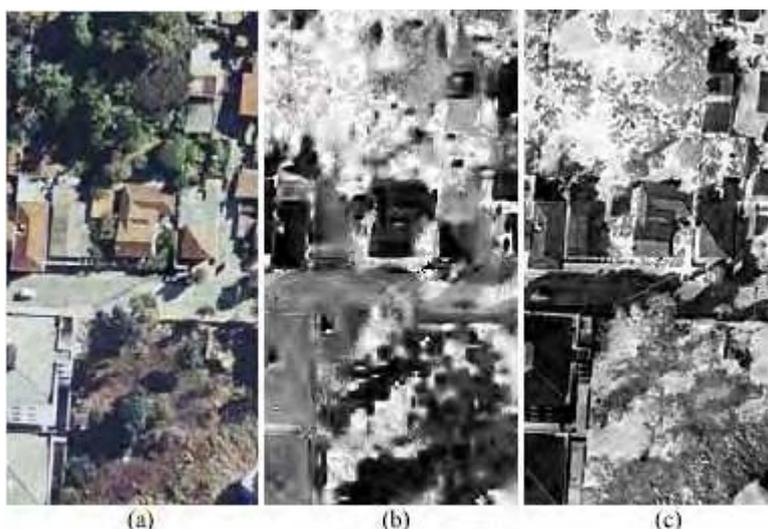


Figura 2.22 Aumento de contraste entre elementos artificiais e naturais em imagens coloridas digitalizadas. (a) Imagem colorida original. (b) Imagem produzida por valores *DoA*. (c) Imagem produzida por valores *Nanda*.

2.6 RODOVIAS

Os elementos básicos que descrevem uma rodovia são as suas bordas e o seu eixo central. Apesar dessa descrição simplista, extrair rodovias de imagens aéreas é uma tarefa de alta complexidade. Rodovias podem sofrer oclusões por árvores, edificações e outras estruturas adjacentes; podem ser parcialmente cobertas por outros materiais como lama e sombras ou, ainda, diferentes materiais podem ser usados na sua construção (como: asfalto, concreto e terra). Diferentes trechos de uma mesma rodovia podem ser construídos com esses diferentes materiais.

Extração de rodovias (ou de vias urbanas) tem várias aplicações como: mapeamento, serviços de navegação assistida, planejamento urbano, análise de tráfego, auxílio em serviços de manutenção de estradas, geração de modelos virtuais de cidades, etc.

Os métodos propostos para extrair rodovias, de forma geral, se baseiam em restrições geométricas, restrições radiométricas e análises de contexto (presença de veículos, bordas de calçadas, presença de vegetação nas laterais, etc.). A maioria desses métodos de extração usa dados extraídos de imagens pancromáticas ou do componente intensidade. Diversas pesquisas sobre extração automática e semi-automática têm sido realizadas por especialistas das áreas de Visão computacional e Fotogrametria Digital desde a década de 70 (DAL POZ e AGOURIS, 2001). O critério mais comum usado para classificar os métodos de extração de rodovias está relacionado com a necessidade ou não da interferência humana com o sistema de extração, dando origem aos denominados métodos automáticos e semi-automáticos.

Na extração semi-automática de rodovias, segundo Dal Poz e Agouris (2001), o operador humano do sistema fornece como informações um ponto inicial (semente) sobre a rodovia e a direção que deve ser seguida, a partir das quais a rodovia é extraída. No processo de extração, geralmente são empregados algoritmos baseados na análise de consistência de perfis da superfície intensidade extraídos transversalmente ao eixo da rodovia, ou na análise de bordas anti-paralelas, ou na combinação de ambos os princípios. Numa outra forma de extração semi-automática o operador necessita fornecer alguns pontos sementes descrevendo grosseiramente a forma e a posição da rodovia. O polígono inicial formado pelos pontos descritores é refinado por algoritmos baseados na otimização global por programação dinâmica, ou pelo princípio do contorno ativo ou por *snakes* (DAL POZ e AGOURIS, 2001). Para que essa metodologia seja considerada automática, é necessário que os pontos descritores sejam encontrados sem a interferência do operador.

Baumgartner *et al.* (1999) propuseram um método automático para extração

de rodovias, restrito a imagens de áreas rurais. Nesse método, são feitas análises de contexto (relações entre a rodovia e outros elementos: sombras, árvores, presença de veículos, etc.) e análise de linhas de bordas ao longo do espaço escala (conhecimento de restrições que definem uma rodovia, como: largura da rodovia, paralelismo das linhas de lados opostos à rodovia, topologia da estrutura da rede de rodovias, propriedades de reflectância do piso da rodovia).

Zanin *et al.* (2005) utilizaram imagens coloridas para detectar pontos sementes de rodovias, sobre as quais foi aplicado um método que aumenta o contraste entre elementos naturais e artificiais que facilita o processo de segmentação. Com modelos baseados em conhecimento de restrições e análise de contexto o resultado da segmentação foi filtrado e os pontos sementes foram detectados. Usando esta nova abordagem, o tempo necessário para extrair estradas diminuiu em mais de 50%.

Clode *et al.* (2004) usaram dados LIDAR (reflectância e altura) para detectar rodovias usando um processo de classificação. Akel *et al.* (2004) também usaram dados LIDAR, mas com o objetivo de gerar o MDT correspondente. O método aplicado para gerar o MDT neste trabalho se baseia na extração da malha viária, ou seja, as rodovias constituem um subproduto necessário ao método de extração do MDT. Hu *et al.* (2004) usaram dados LIDAR e imagens para extrair atributos e informações contextuais para extrair rodovias em áreas urbanas. Zhang e Wang (2004) usaram imagens multiespectrais Quickbird para fazer um agrupamento não supervisionado de alvos comuns, dentre as quais, aquelas com possibilidades de serem representantes de rodovias foram examinadas, usando atributos extraídos da imagem pancromática, para serem confirmadas como rodovias.

2.7 MÉTRICAS DE AVALIAÇÃO DA QUALIDADE DA DETECÇÃO

Para avaliar com maior rigor resultados produzidos por métodos de detecção/classificação de alvos, é necessário conhecer a verdadeira classificação de todos os pixels envolvidos no processo. Na prática, nem sempre é possível ter esse conhecimento. Uma alternativa consiste em efetuar uma avaliação amostral (CHUVIECO, 1990).

Uma alternativa para se fazer essa avaliação é através do uso da matriz de confusão, a qual representa as contradições entre os resultados obtidos e a referência dos padrões (verdade terrestre). Essa matriz permite confrontar duas situações: a quantificação (ex. total de pixels) da classificação dos padrões corretamente efetuada em suas respectivas classes (representadas pelas linhas da matriz de confusão) e a quantificação da classificação dos padrões incorretamente inseridos em classes diferentes daquelas definidas como corretas

(representadas pelas colunas da matriz de confusão). Cada célula dessa matriz registra um desses valores quantificados, o qual deveria ser classificado como pertencente à classe especificada pela linha da matriz mas que foram classificados segundo a classe especificada pela coluna dessa mesma matriz. Se, numa situação ideal, somente as células correspondentes à diagonal principal dessa matriz apresentar valores válidos então, essa situação, indica que o processo de classificação foi realizado com perfeição.

A matriz de confusão permite calcular: a estimativa global da acurácia do resultado; o erro de omissão; o erro de inclusão e o coeficiente de concordância Kappa. Segundo Centeno (2004), o coeficiente de concordância Kappa foi proposto por Cohen (1960)⁶.

O coeficiente de concordância Kappa (κ) é capaz de medir a acurácia de um mapa temático produzido por um determinado processo (classificação, segmentação, agrupamento, etc.) em função de um mapa temático de referência, ou verdade terrestre. Quanto maior é o valor do coeficiente Kappa, melhor pode ser considerado o resultado do mapa temático produzido pelo uso desse processo. Centeno (2004) apresenta uma relação entre valores do coeficiente Kappa e o desempenho do processo produtor do mapa temático (Tabela 2.1). Este trabalho usa os coeficientes de avaliação extraídos da matriz de confusão e o índice Kappa para avaliar a qualidade da detecção de telhados de edificações.

Tabela 2.1 Relações do coeficiente Kappa com o desempenho da classificação.

Valor do coeficiente Kappa	Desempenho da classificação
$\kappa < 0$	Péssimo
$0,0 < \kappa \leq 0,2$	Mau
$0,2 < \kappa \leq 0,4$	Razoável
$0,4 < \kappa \leq 0,6$	Bom
$0,6 < \kappa \leq 0,8$	Muito bom
$0,8 < \kappa \leq 1,0$	Excelente

FONTE: Centeno (2004)

⁶ COHEN, J. A coefficient of agreement of nominal scales. **Educational and Psychological measurement**. n. 20, pp. 37 – 46, 1960.

CAPÍTULO III

MATERIAIS E MÉTODOS

Neste Capítulo são apresentados os materiais e uma síntese dos métodos usados nos experimentos realizados neste trabalho. Também são apresentados alguns problemas inerentes aos dados usados e situações relacionadas com a complexidade de contexto desses dados.

3.1 MATERIAIS

- Computador AMD, 1GHz, 256MB de memória RAM, 80GB de espaço em disco, plataforma Windows XP Home Edition;
- Microsoft Office XP (www.microsoft.com);
- Surfer versão 8.0 (www.goldensoftware.com);
- Envi versão 3.5 (www.itvis.com);
- Adobe Photoshop versão 8.0 (<http://www.adobe.com>);
- Adobe Acrobat versão 5.0 (<http://www.adobe.com>);
- Matlab versão 5.3 (www.mathworks.com);
- SDC Morphology Toolbox versão 1.1 (<http://www.mmorph.com>);
- Imagem colorida (RGB) digitalizada adquirida pela câmara RC-10, cedida pela empresa Esteio – Engenharia de Aerolevamento (<http://www.esteio.com.br>) – área urbana de Presidente Prudente;
- Imagem colorida (RGB) digitalizada adquirida pela câmara RMKTOP 15, cedida pela empresa Esteio – Engenharia de Aerolevamento (<http://www.esteio.com.br>) – área urbana de Poços de Caldas;
- Imagens coloridas (RGB) adquiridas pela câmara DMC (www.intergraph.com) distribuídas em CD-ROM como material de propaganda;
- Imagens coloridas (RGB) adquiridas pela câmara Ultracam (<http://vexcel.com>)

distribuídas em CD-ROM como material de propaganda.

- Imagens coloridas (RGB) adquiridas pela câmara Kodak DCS Pro 14n (www.kodak.com/go/dcspro14n), cedidas pelo Departamento de Cartografia FCT/UNESP – área urbana de Presidente Prudente.
- Imagens coloridas (RGB) adquiridas pela câmara ADS40 (<http://gi.leica-geosystems.com/>) ortorretificadas com GSD de 20cm, cedida pela empresa Wild Comercial e Importadora Ltda. (www.wildcomercial.com.br/);
- Imagens coloridas (RGB) adquiridas pela câmara IGN (http://isprs.ign.fr/colorprocessing_en.htm) com 25cm de resolução espacial, disponível em http://isprs.ign.fr/packages/packages_en.htm;
- Imagens coloridas (RGB) e infravermelhas adquiridas pela câmara IGN (http://isprs.ign.fr/colorprocessing_en.htm) com 25cm de resolução espacial, cedidas pelo Institut Géographique National (IGN) – França (www.ign.fr);
- Imagens correspondentes às faixas do espectro eletromagnético R, G, B, infravermelho próximo e pancromática adquiridas pela câmara HRSC-AX (<http://www.dlr.de/HRSC-A>) ortorretificadas com GSD de 20cm e georreferenciadas, cedidas pela empresa de aerolevantamentos Digimapas (<http://www.digimapas.com.br>) – área urbana de Salvador, com cobertura de 9km²;
- MDS derivado das imagens estéreo-fotométricas adquiridas pela câmara HRSC-AX (<http://www.dlr.de/HRSC-A>) com GSD de 50cm, georreferenciado e com 10cm de precisão altimétrica, disponibilizado em grade regular formato de imagem TIFF com 16bits/pixel de precisão, cedido pela empresa de aerolevantamentos Digimapas (<http://www.digimapas.com.br>) – área urbana de Salvador, com cobertura de 9km².

Todas as imagens usadas têm 8bits/banda de resolução radiométrica. As imagens da câmara HRSC-AX foram reamostradas de 20cm para GSD de 50cm para obter o perfeito registro com o respectivo MDS. Isto foi feito usando as funções do software ENVI 3.5, aplicando o método de interpolação pelo vizinho-mais-próximo para reamostrar os níveis de cinza.

3.2 CARACTERÍSTICAS DOS DADOS

As imagens adquiridas pelas câmaras ADS40 e IGN, usadas neste trabalho, apresentam uma tênue linha com valor radiométrico comprometido nas bordas de transição de

níveis de altura elevados. Na imagem IGN essa linha tem a cor verde (Figura 3.1). Na imagem ADS40 essa linha é azul. Esse ruído provoca confusão na detecção de vegetação e sombras.

As imagens adquiridas pela HRSC-AX também apresentam esse tipo de problema, com maior frequência e maior área, mas com tendência para a cor vermelha.

A diferença do ângulo de visada dos sensores multiespectrais do sistema HRSC-AX é uma característica que dificulta a análise das imagens adquiridas por essa câmara. Como as superfícies reais não são perfeitamente difusas, a reflexão de energia eletromagnética varia conforme o ângulo da elevação solar (azimute solar) e do ângulo de aquisição de imagens. Desta forma, imagens, de uma mesma superfície, adquiridas de diferentes ângulos de visada deveriam ser tratadas para compor um conjunto coerente de dados espectrais. Entretanto, devido às variações da reflexão bidirecional, as quais variam conforme o tipo de superfície, não há um modelo conhecido para esse problema. Basta lembrar que as folhas da vegetação mudam de posição e, conseqüentemente, alteram a resposta bidirecional.

Assim, não são mantidas as proporções esperadas entre os valores radiométricos capturados por esses diferentes sensores que estão arrançados em diferentes ângulos de visadas. Os padrões dessas proporções (coerência do conjunto de dados) são importantes para a análise espectral das imagens, por exemplo, para cálculos de valores de índices como o *NDVI*.

Esse fato está registrado nas seqüências de imagens apresentadas na Figura 3.2. Pode-se observar, na imagem da seqüência 4 como a vegetação verde é bem realçada na imagem adquirida na faixa do infravermelho. É esperado que, na faixa relativa ao vermelho (seqüência 3), sejam registrados os menores valores de brilho provenientes dessa mesma vegetação. No entanto, observa-se, neste caso, que isto ocorre na imagem da faixa azul (seqüência 1). Esse fato é promovido pela diferença no ângulo de visada entre os sensores de cada faixa. Na câmara HRSC-AX, essa diferença entre a faixa do vermelho e do infravermelho próximo é quase 20°. Jensen (2000) mostrou que diferenças nos ângulos de visada promovem desvios radiométricos significativos nas imagens adquiridas. Isso diminui a eficiência de índices, como o *NDVI*.

Várias imagens adquiridas pela HRSC-AX foram inspecionadas e, em todas, foi constatado que a composição colorida RGB é avermelhada. Essa característica inesperada pode ser conseqüência dos diferentes ângulos de visadas dos sensores da HRSC-AX e, nesse caso, o ângulo de visada do sensor da faixa espectral relativo ao vermelho recebe um fluxo de energia radiante maior que os sensores do azul e do verde.

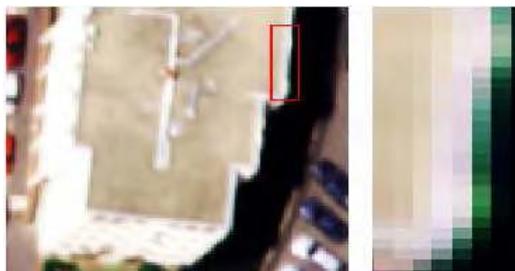


Figura 3.1 Imagem colorida adquirida pela câmara IGN. Presença de ruído nas bordas de transição altas.

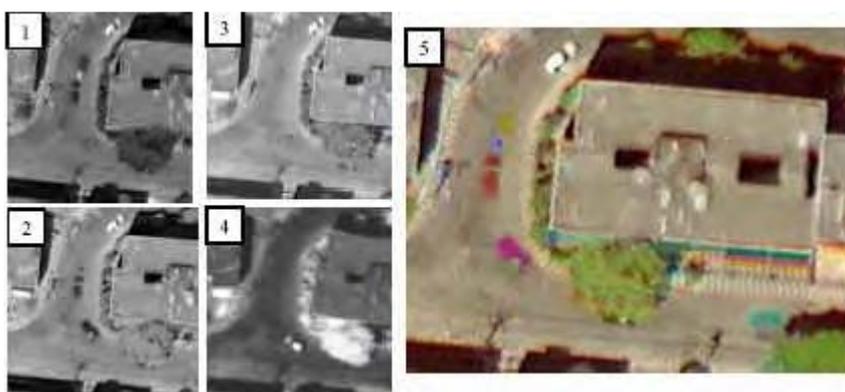


Figura 3.2 Problemas com o imageamento de alvos móveis e pela diferença do ângulo de visada dos sensores em relação ao sistema de imageamento da câmara HRSC-AX.

Uma terceira característica relacionada com essa câmara é o produto do imageamento de alvos móveis (como: veículos e superfície de corpos d'água). Como esses alvos móveis são imageados com alguma diferença de tempo entre os sensores espectrais, eles são registrados em diferentes posições. Pode-se observar nas seqüências de imagens (Figura 3.2) que: na seqüência 1 (azul) tem um veículo branco estacionado, o qual continua nesse estado nas seqüências 2 (verde) e 3 (vermelho); na seqüência 4 (infravermelho) o veículo se deslocou; ainda, é possível observar um veículo de cor escura que muda de posição nas seqüências 1 e 2 e, nas 3 e 4 não aparece mais nas cenas imageadas. Essa característica se manifesta localmente e prejudica a análise das respostas espectrais.

Como o sistema é de varredura linear (*scanner*), quando se faz o imageamento de alvos móveis, o sistema de varredura de um mesmo sensor pode registrar a energia de um mesmo ponto sobre esse alvo mais de uma vez, provocando marcas fantasmas na imagem (veja nas seqüências individuais 1 e 2, próximo ao veículo escuro). Esse problema se manifesta localmente, e prejudica as análises de respostas espectrais.

Os resultados causados pelo deslocamento de alvos podem ser bem observados na composição colorida (seqüência 5) na forma de marcas fantasmas de cores saturadas de diversos matizes. Essas falsas marcas podem ser confundidas com um elemento

de interesse.

O problema mais grave detectado nas imagens adquiridas pela câmara HRSC-AX pode ser visto na Figura 3.3a, e no detalhe 3.3c. Como os sensores multiespectrais adquirem imagens em ângulos de visadas diferentes, por estarem fisicamente alojados em diferentes posições sobre o plano focal da câmara, ocorre que cada um deles recebe um raio luminoso refletido da superfície da Terra que não é, exatamente, o mesmo fluxo proveniente do mesmo ponto dessa superfície. Em outras palavras, ocorre um problema de correspondência que é agravado pelo aumento de paralaxe entre esses sensores dificultando o registro entre diversos pixels das imagens multiespectrais. Nas imagens utilizadas, esse problema é observado com maior intensidade em alvos que se elevam sobre a superfície do terreno, pois, nesse caso, a paralaxe é maior. Além disso, devido aos diferentes ângulos de visadas entre os sensores da AX, pode ocorrer áreas de oclusão em pelo menos um deles.

Tanto o problema de paralaxe como os de oclusão promovem alterações nas respostas espectrais dos alvos (e de resolução geométrica) que podem ser observadas na Figura 3.3c. Observe na Figura 3.3a que todos os prédios altos apresentam esse problema.

Essa alteração das respostas espectrais conduz à formulação de falsas hipóteses sobre a natureza dos elementos, e geram falsos atributos que confirmam, positivamente, essas falsas hipóteses. Um exemplo está ilustrado na Figura 3.3d, a qual mostra, em vermelho, a detecção de áreas cobertas por vegetação aplicando o valor de limiar 0,5 sobre os respectivos valores *NDVI*.

Essas características da câmara HRSC-AX não são comuns a outros sistemas sensores os quais colocam um filtro (sistema *trichroid*), o qual decompõe um mesmo fluxo radiante nas faixas espectrais a serem imageadas. A câmara ADS40 adota essa abordagem para decompor em três componentes de luz (relativos às faixas azul, verde e vermelho do espectro eletromagnético) e distribui cada componente sobre o respectivo sensor. Entretanto, as imagens adquiridas pelo sensor infravermelho não são adquiridas desse mesmo fluxo energético e, portanto, apresenta problemas de registro com as imagens adquiridas pelos sensores que cobrem as faixas do espectro visível, que pode observado na Figura 3.3d.

Os MDSs extraídos pelo uso das imagens estéreo-fotométricas adquiridas pelas câmaras trilineares (ADS40 e HRSC-AX) têm acurácia superior aos extraídos pelo uso de imagens convencionais (filme ou *frame*) devido à redundância dos dados e por minimizar os efeitos de oclusões. Mesmo assim, alguns problemas não foram, ainda, satisfatoriamente resolvidos. Tanto Schiewe (2000) como Pateraki e Baltasvias (2003a e 2003b) constataram a deficiência dos processos de extração de MDS em regiões sombreadas (pela alta correlação

entre pontos dessas regiões) e nas bordas das edificações (pela descontinuidade da superfície – linhas de quebra). Essa deficiência é mostrada na Figura 3.3a.

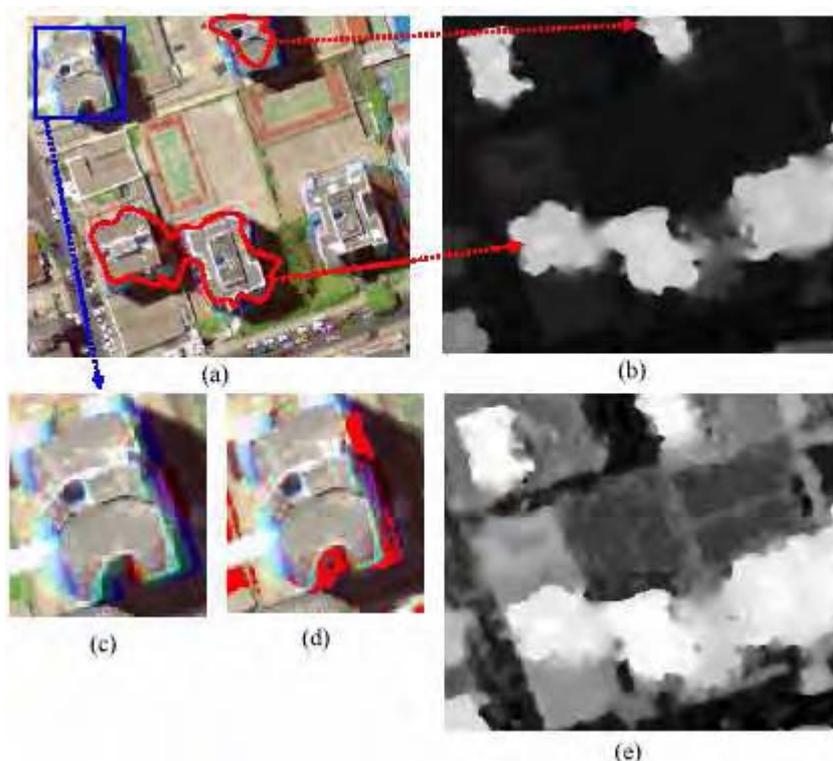


Figura 3.3 Problemas de registro dos dados de imageamento e acurácia do MDS.

Na parte superior da imagem apresentada na Figura 3.3a é mostrado um edifício o qual não é totalmente coberto (linha vermelha) pelo MDS correspondente (Figura 3.3b) e na parte inferior mostra que o MDS cobre dois edifícios fisicamente separados por mais de 10m devido aos erros de correlação provocados pela presença da sombra entre eles.

O processo de correlação de imagens não é absolutamente perfeita e eventualmente falha. Quando isso ocorre, são geradas pequenas instabilidades locais no MDS. Esse fato pode ser observado na imagem realçada do MDS (Figura 3.3e), a qual apresenta instabilidades no interior de áreas planas (como as quadras de tênis).

As imagens adquiridas pela câmara HRSC-AX usadas neste trabalho foram ortorretificadas pela empresa DIGIMAPAS, usando o sistema desenvolvido pelo DLR/ISTAR. As imagens são retificadas para a extração do MDS correspondente e sobre essas é aplicado um método de ortorretificação, o qual usa esse mesmo MDS. Em qualquer fase desse processo pode ocorrer erro, principalmente se o relevo da superfície do terreno for muito acidentado (caso da cena utilizada). A Figura 3.4 mostra que algum problema ocorreu no processo de ortorretificação das imagens. Nota-se que as formas geométricas de alguns edifícios foram distorcidas. Essa distorção gera falsas bordas que podem conduzir à perda

desses elementos, ou sua extensão sobre outras áreas. Esse problema também gera padrões de cores inexistentes para esses elementos comprometidos.



Figura 3.4 Distorção na forma geométrica de algumas edificações, provocando deslocamento e inserção de bordas (imagem pancromática – HRSC-AX).

3.3 COMPLEXIDADE DE CONTEXTO NOS DADOS USADOS

Este trabalho não é dirigido para aplicações específicas que focalizam dados adquiridos (ou derivados) por um único sensor. Várias imagens adquiridas de diferentes regiões por diferentes sensores são usadas para testar a metodologia e técnicas propostas.

Além dos problemas com a precisão e acurácia dos dados usados neste trabalho, relatados na Seção 3.2, há que se considerar ainda a complexidade intrínseca ao processo de detecção de elementos específicos. Os conjuntos de dados usados neste trabalho devem ser considerados como sendo de alta complexidade de análise, pois além de usar dados adquiridos por diferentes sensores, uma grande parte desses dados refere-se a um contexto altamente complexo.

Este trabalho não tem a pretensão de generalizar a metodologia proposta com base na solução de casos extremos. Os estudos de caso são realizados para mostrar que a metodologia proposta foi testada em vários contextos. Como algumas cenas são de paisagens urbanas de alta complexidade, os resultados devem mostrar o potencial da metodologia proposta, bem como suas limitações.

Para exemplificar melhor a complexidade de contexto em que os dados foram adquiridos e relacioná-los com os objetivos deste trabalho, são analisadas as seguintes situações:

- a) Detectar regiões sombreadas e áreas cobertas por vegetação verde presentes em imagens aéreas coloridas usando atributos extraídos unicamente da imagem RGB. Considera-se que a imagem mostrada na Figura 3.5 seja uma

representante de alta complexidade para resolver esse problema.

- b) Detectar edificações, marcadores adequados para rodovias e ruas, sombras, corpos d'água em imagens aéreas de regiões urbanas densas (Figura 3.6).
- c) Extrair o MDS normalizado e detectar edificações em imagens aéreas de regiões urbanas densas situadas sobre um relevo de alta complexidade (Figura 3.7).

São nesses contextos de complexidade que a metodologia proposta foi testada e avaliada.



Figura 3.5 Imagem colorida (IGN) que ilustra a complexidade da cena e dificuldade para detectar sombras e vegetação.

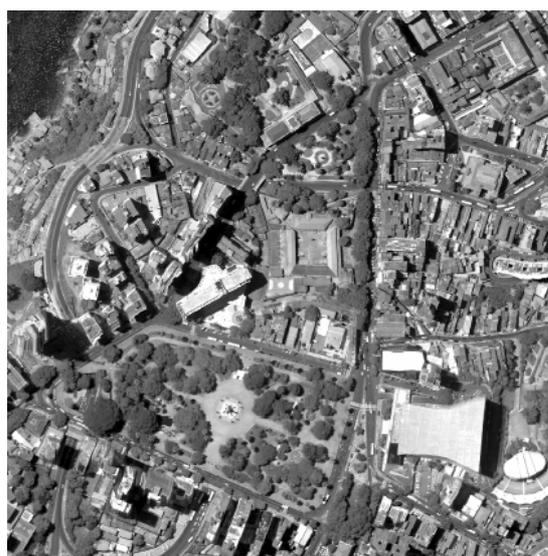


Figura 3.6 Complexidade inerente às regiões urbanas densas. Imagem pancromática ortorretificada HRSC-AX com GSD de 50cm. Vista parcial (600×600m) da região urbana de Salvador.

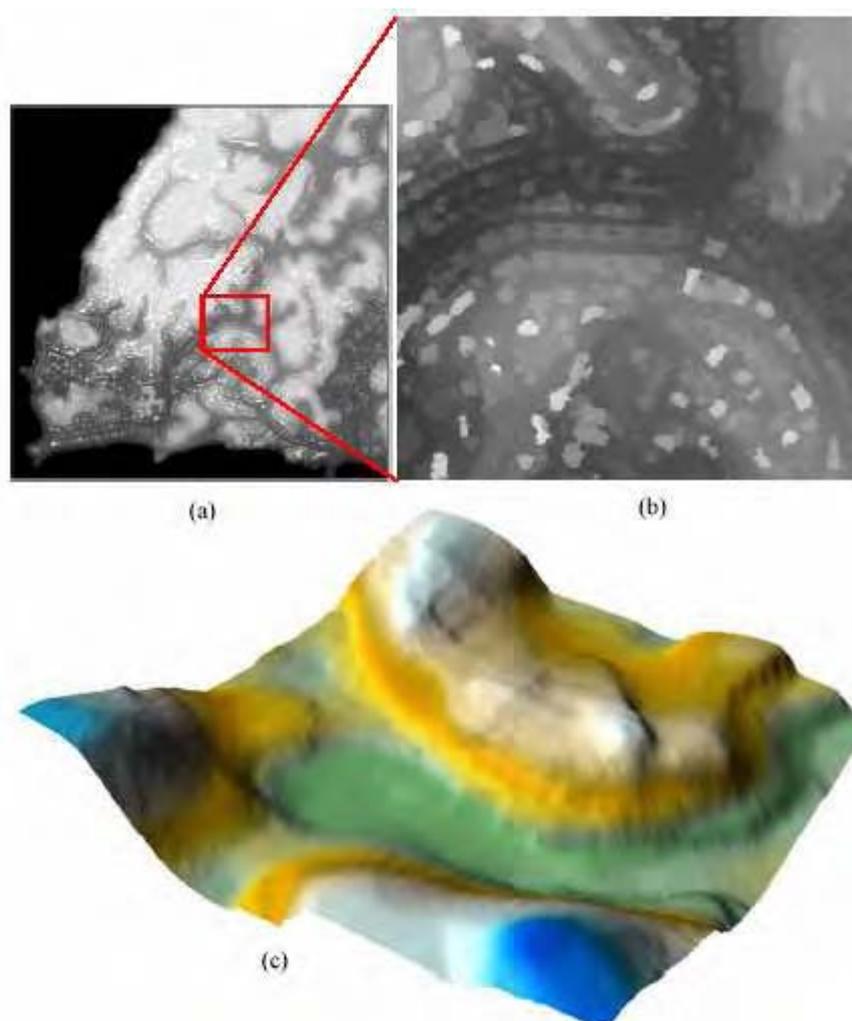


Figura 3.7 Complexidade do relevo. (a) MDS parcial da cidade de Salvador (3×3km) extraído das imagens estéreo-fotométricas adquiridas pela câmara HRSC-AX com GSD de 50cm. (b) Detalhe do MDS (600×600m). (c) MDT correspondente ao detalhe do MDS.

3.4 METODOLOGIA

Os dados usados neste trabalho podem ser divididos em três grupos: (1) disponibilidade somente de imagens coloridas (RGB); (2) disponibilidade de imagens coloridas (RGB) e de imagens adquiridas no infravermelho próximo e; (3) disponibilidade de imagens coloridas (RGB), pancromáticas e imagens adquiridas no infravermelho próximo e dados de elevação (MDS) correspondentes a essas imagens.

Em consonância com os objetivos deste trabalho, para cada grupo de dados são propostos métodos capazes de detectar um conjunto de elementos presentes em imagens aéreas de regiões urbanas.

Para dados do grupo 1 são propostos métodos capazes de detectar e

discriminar regiões sombreadas e cobertas por vegetação verde. Para dados do grupo 2 são propostos métodos capazes de detectar e discriminar regiões sombreadas; áreas cobertas por vegetação; corpos d'água; rodovias e ruas pavimentadas com asfalto (marcas). Para dados do grupo 3 são propostos métodos capazes de detectar e discriminar regiões sombreadas; áreas cobertas por vegetação; corpos d'água; rodovias e ruas pavimentadas com asfalto (marcas) e telhados de edificações, além da normalização do MDS.

Todos os métodos propostos são baseados em segmentação de imagens através de análises de atributos radiométricos, cor, saturação, bordas e comportamentos espectrais padrões. Esses métodos não necessitam da utilização de algoritmos de classificação ou de agrupamentos. Os próprios métodos são capazes de estimar valores de limiar, usados nas operações de segmentação. A maioria dos métodos propostos faz uso apenas de operações lógicas e aritméticas simples para produzir os resultados. Operadores, filtros e técnicas da Morfologia Matemática são amplamente empregados para resolver problemas do grupo 3.

A seguir são apresentadas as estruturas gerais dos métodos propostos para atingir os objetivos especificados. Os procedimentos são apresentados com mais detalhes no Capítulo 4.

3.4.1 Detecção de Elementos em Imagens Coloridas

O fluxograma básico das operações necessárias para detectar e discriminar sombras e vegetação verde usando atributos extraídos de imagens aéreas coloridas (RGB) é mostrado na Figura 3.8. Essas operações são detalhadas no Capítulo 4.

Os componentes R, G e B, extraídos do sistema de cor RGB, de uma imagem colorida, ou as respectivas imagens adquiridas nos intervalos espectrais do visível, são altamente correlacionados. Essa alta correlação dificulta a especificação de atributos capazes de auxiliar na detecção de alvos específicos. Para diminuir essa alta correlação, são usados componentes do sistema de cor HSI (ou HSV), uma vez que esses componentes são disjuntos (ou independente), além de fornecer três outros conjuntos de dados (H – matiz, S – Saturação, I – Intensidade). Essa exploração permite extrair de uma imagem colorida seis conjuntos de dados (ou atributos) – *R, G, B, H, S e I*.

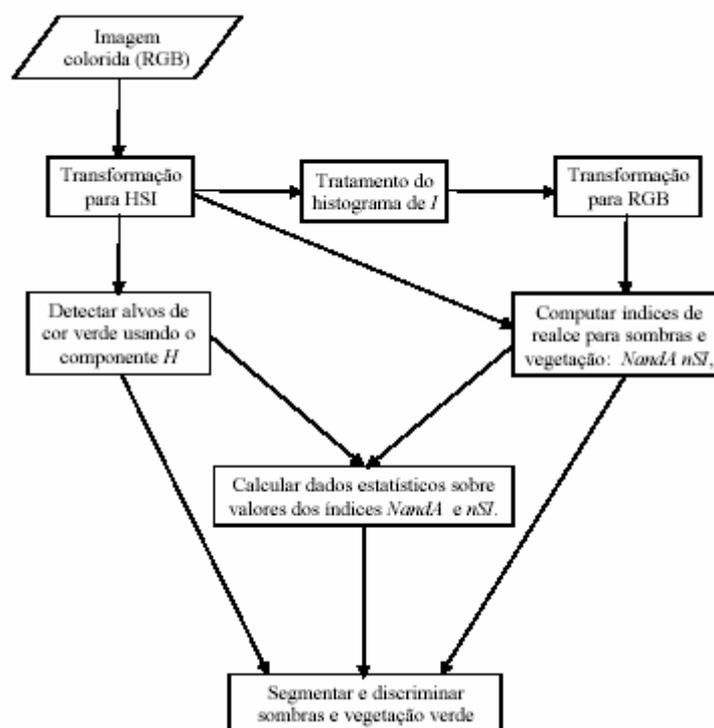


Figura 3.8 Fluxograma básico para detecção e discriminação de sombras e vegetação usando imagens coloridas.

Para detectar e discriminar sombra e vegetação verde em imagens aéreas coloridas, é adotada a seguinte estratégia: do componente H (matiz) são extraídos dois conjuntos de pontos-imagem: um indicando a presença de elementos nas imagens que têm como atributo a cor verde; outro indicando restrições de cores para pontos-sombra. Esses dois conjuntos são usados para computar dados estatísticos sobre valores do índice nSI (*normalized Shadow Index* – Seção 4.1 – Equação 4.1), o qual é um índice que realça regiões sombreadas, e sobre os valores do índice $Nanda$ (*Natural and Artificial features* – Seção 2.1 – Equação 2.4).

Para garantir um nível de padronização de iluminação entre diferentes imagens de diferentes ambientes adquiridas por diferentes sensores, é feito um pré-tratamento do histograma do componente I . Esse tratamento é feito pela equalização⁷, ou pelo alargamento linear do histograma⁸. A escolha do método usado nesse tratamento é dependente somente da distribuição de frequências dos valores de brilho associados com os pixels do componente I . Após esse tratamento do histograma de I , é recomposta a imagem colorida através da transformação HSI para RGB, permitindo que esses novos componentes R, G, e B sejam extraídos e usados para computar valores dos índices nSI e $Nanda$.

⁷ (*histogram equalization*) veja Gonzalez e Woods (1992) e Myler e Weeks (1993).

⁸ (*stretched histogram linearly*) veja Lillesand e Kiefer (2000).

A segmentação e a discriminação de sombras e vegetação é feita por análise de histograma do índice *Nanda* e medidas estatísticas simples extraídas do índice *nSI*.

3.4.2 Detecção de Elementos em Imagens Coloridas e Infravermelhas

O fluxograma básico das operações necessárias para detectar e discriminar sombras, vegetação, corpos d'água e marcadores de rodovias e vias públicas pavimentadas com asfalto é mostrado na Figura 3.9. Essas operações são detalhadas na Seção 4.2.

O uso das imagens coloridas (RGB) e infravermelhas possibilitam experimentar novas combinações para explorar os comportamentos espectrais e radiométricos dos alvos de interesse. Além dos seis componentes extraídos dos sistemas de cor RGB e HSI (Seção 3.4.1), a imagem infravermelha correspondente fornece dados menos correlacionados com aqueles disponibilizados pelas bandas do visível. Além disso, as imagens infravermelhas realçam, naturalmente, a presença de alguns alvos, como vegetação e corpos d'água.

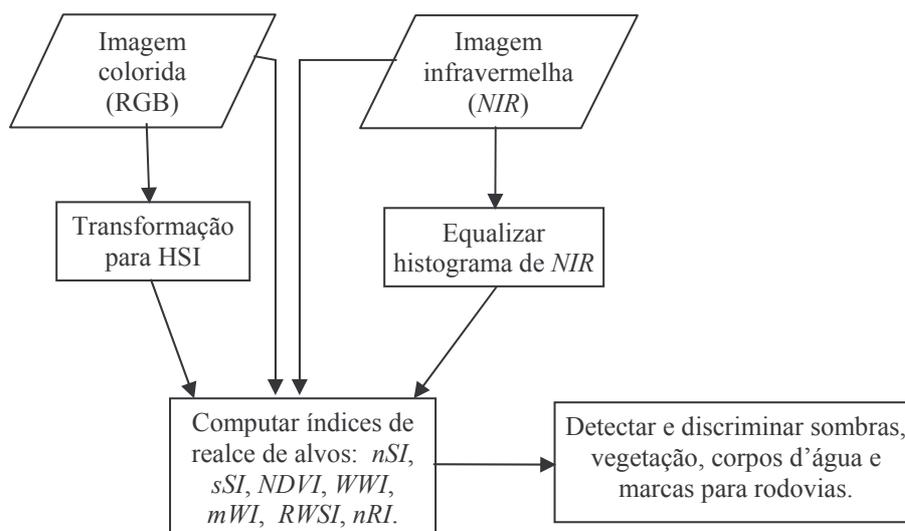


Figura 3.9 Fluxograma básico para detecção e discriminação de sombras, vegetação, corpos d'água e marcas de rodovias usando imagens coloridas (RGB) e infravermelhas.

O uso de imagens adquiridas na faixa do infravermelho próximo permitem estabelecer outros índices de realce de elementos específicos da paisagem urbana, com qualidade superior aqueles computados somente com o uso das imagens coloridas (bandas do visível). Esses realces são tão acentuados que o processo de detecção e discriminação das feições pode ser feito por simples operações lógico-aritméticas (técnicas determinísticas).

3.4.3 Detecção de Telhados de Edificações e Normalização do MDS

Para detectar telhados de edificações são usados os seguintes conjuntos de dados: imagens coloridas (RGB), imagens pancromática, imagens infravermelhas e MDSs correspondentes. Os dados do MDS estão disponibilizados em grade regular no formato de imagem em tons de cinza com 16bits de resolução. A imagem pancromática não é absolutamente necessária, e pode ser substituída pelo componente intensidade extraído do sistema HSI.

A estratégia básica usada para detectar os telhados de edificações consiste em resolver o paradoxo de Beucher-Meyer, o qual é baseado na detecção de marcadores que pertençam ao alvo desejado (marcadores internos), bem como de marcadores que apontem para a sua respectiva vizinhança (marcadores externos). Os marcadores detectados são processados para minimizar conflitos (obter dois marcadores distintos para uma mesma região). Esses conjuntos de marcadores são usados pelo operador morfológico *watershed* com marcadores automaticamente definidos⁹ para segmentar os telhados das edificações.

A implementação do algoritmo usado neste trabalho é aquela proposta por Lotufo e Falcão (2000). Essa proposta de implementação do operador *watershed* tem a vantagem de não necessitar do gradiente da imagem (o gradiente é implicitamente considerado pela forma da implementação do operador) e nem de promover mudanças de homotopia na imagem, desde que se aplique, previamente, uma filtragem capaz de eliminar máximos e mínimos locais. Os filtros conexos de abertura e fechamento por área (*AreaOpen* e *AreaClose*)¹⁰ foram escolhidos para realizar essa tarefa, uma vez que eles são bem adaptados para tratar altas e baixas frequências, não inserem novas bordas no processo, não deslocam bordas de interesse, mas podem eliminar algumas delas e não necessitam de dimensionamento de elementos estruturantes, ou seja, esses filtros não têm dependência espacial com as dimensões dos elementos de interesse existentes na imagem.

⁹ D'Ornellas (2001); Vincent e Soille (1991); Lotufo e Falcão (2000); Meyer e Beucher (1990).

¹⁰ Os filtros morfológicos conexos são aplicados sobre imagens binárias, com o objetivo de eliminar zonas planas. Esses filtros podem eliminar algumas bordas existentes mas não deslocam e nem inserem novas bordas. Na prática, os filtros conexos reduzem a quantidade de zonas planas na imagem através da união de zonas planas adjacentes. Pertencem a esta família de filtros: (1) filtros homotópicos (HIRATA, 1997); (2) *Planing* (MEYER, 1998); (3) *Livelings* (MEYER, 1998) e; (4) *AreaOpening* e *AreaClosing* (HEIJMANS, 1998 e 1999).

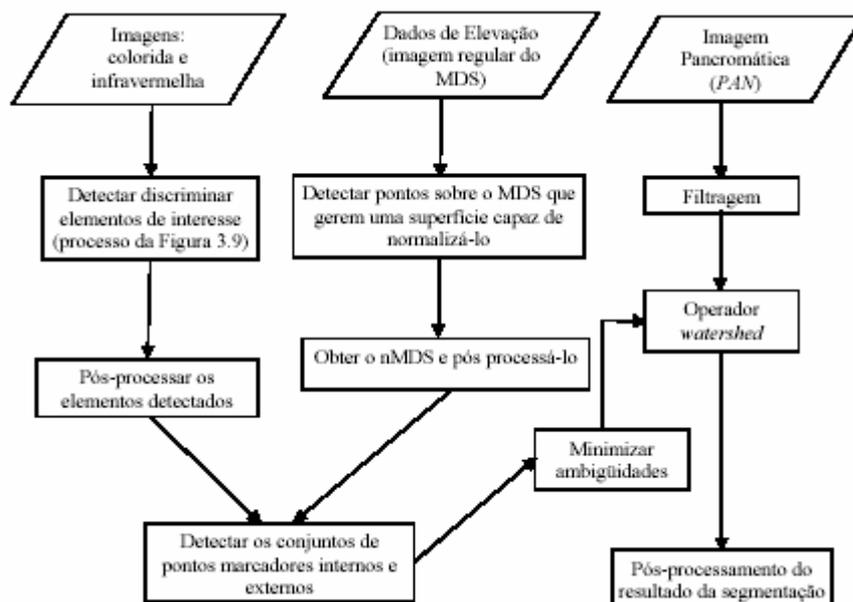


Figura 3.10 Fluxograma básico para detecção de telhados de edificações e normalização do MDS.

O conjunto de marcadores internos é extraído das elevações detectadas no MDS normalizado (nMDS) – Seções 2.4 e 4.3.4 – exceto para aquelas regiões cobertas por vegetação ou sombreadas. As áreas cobertas por vegetação, sombras, corpos d’água e marcadores de rodovias são detectados pelo algoritmo proposto no fluxograma da Figura 3.9 e, após tratamentos específicos, constituem o conjunto dos marcadores externos, junto com os pontos detectados como não elevados no nMDS.

Os tratamentos aplicados aos conjuntos de marcadores visam eliminar ou minimizar conflitos entre diferentes marcadores que competem sobre uma mesma região. Esses conflitos têm origem em várias fontes, a maioria causada por problemas relativos à precisão e acurácia dos dados usados (Seções 3.2 e 3.3).

3.5 FUNÇÃO DE TRANSFORMAÇÃO DE DIMENSÃO

Para possibilitar uma formulação matemática adequada dos métodos de segmentação e discriminação de elementos que compõem a paisagem urbana apresentados nas próximas seções, é necessário definir uma função de transformação de dados dispostos em estruturas bidimensionais (matriz) em unidimensionais (vetores).

Seja B uma matriz de dimensões $m \times n$ que contém somente valores binários (0s e 1s). Seja também a função SUM dada por

$$SUM(B) = \sum_{i=1}^m \sum_{j=1}^n B_{ij},$$

logo, o resultado de $SUM(B)$ corresponde a quantidade de elementos da matriz B associados com o valor 1 (exemplo, se B é uma matriz binária de ordem 3×3 , e se é composta somente por valores 1 então $SUM(B)$ produz o valor 9, indicando que na matriz B existem 9 valores 1).

Seja M uma matriz de dimensões $m \times n$ que contém valores pertencentes ao conjunto dos valores reais. Seja A a seguinte função de transformação

$$\begin{aligned} \mathbf{A}_p(B, M) &= M_{ij}, \text{ se } B_{ij} = 1, \\ \text{onde: } 1 \leq p \leq SUM(B); 1 \leq i \leq m \text{ e } 1 \leq j \leq n & \quad (3.1) \\ \text{para } p, i, j, m, n \in \square & \end{aligned}$$

então, a função de transformação A fornece como resultado um vetor contendo valores mapeados pelo índice $1 \leq p \leq SUM(B)$ originados de M_{ij} que correspondem aos valores $B_{ij} = 1$.

Para melhor entendimento, veja o seguinte exemplo ilustrativo:

se $B = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$ e $M = \begin{pmatrix} 1 & 2 \\ 3 & 4 \end{pmatrix}$, então a aplicação $V = \mathbf{A}_p(B, M)$ produz como resultado o vetor $V = (1 \ 4)$.

CAPÍTULO IV

DESENVOLVIMENTO METODOLÓGICO E ESTUDOS DE CASOS

Neste Capítulo são apresentados os detalhes dos procedimentos metodológicos e seus estudos de caso, bem como análises dos resultados produzidos.

4.1 DETECÇÃO DE ELEMENTOS DA PAISAGEM URBANA USANDO IMAGENS COLORIDAS

Detectar regiões sombreadas e vegetação verde em imagens coloridas é um desafio. A prática tem demonstrado que usar somente dados associados com as bandas espectrais do espectro visível não produz resultados adequados, devido à alta correlação existente entre esses componentes e, também, pelo comportamento instável da sombra (Seção 2.2 e Seção 4.2.2) e pela diversidade de tonalidades de cor verde associada com a vegetação verde.

A tonalidade da vegetação depende do tipo, da idade, do estado de saúde e da época do ano em que são analisadas e, no caso de análise por imageamento, depende das condições atmosféricas e da iluminação que atuam sobre o ambiente no momento da aquisição da imagem. Alguns tipos de vegetação apresentam folhagens altamente saturadas (verde-escuro), outras apresentam folhagens secas, as quais são difíceis de serem separadas de sombras.

4.1.1 Extração de Atributos

Para realçar a vegetação e regiões sombreadas em imagens aéreas coloridas foram experimentados neste trabalho os valores produzidos pelos índices *DoA* e *NandA*

(Equações 2.1 e 2.4)¹¹ os quais exploram os valores de brilho associados com as bandas espectrais do visível. Entretanto, a experimentação realizada mostrou que o índice *DoA* não realiza um realce adequado e, os valores produzidos por esse índice, não é capaz de auxiliar o processo de detecção de sombras e vegetação verde proposto neste trabalho (Figura 4.1c).

O estudo do comportamento físico das sombras, apresentado na Seção 2.2, mostrou que elas possuem baixa intensidade luminosa, devido à oclusão da luz incidente direta, e alta saturação, devido ao espalhamento atmosférico de Rayleigh. Entretanto, existem imagens que não respondem adequadamente a esse modelo, como as imagens adquiridas pela câmara IGN que faz, automaticamente, uma correção atmosférica parcial (pelo método DOS – *Dark Object Subtraction*), e imagens adquiridas pela câmara Ultracam, a qual promove uma pequena restauração de áreas sombreadas.

Os efeitos da correção DOS podem ser observados na imagem do índice *DoA* (Figura 4.1c ou regiões em amarelo sobre a Figura 4.1f), na qual aparecem áreas no interior das sombras totalmente escuras, ao invés de, pelo efeito do índice, serem claras. O índice *Nanda*, Equação 2.4, supera esse comportamento inesperado, mas não produz um nível efetivo de realce que possibilite diferenciar vegetação de sombras (Figura 4.1d).

A discriminação entre sombras e vegetação é feita pelo índice, proposto neste trabalho, *nSI* (*normalized Shadow Index*) – Equação 4.1 – O qual explora os valores elevados do componente saturação (*S*) e os baixos valores do componente intensidade (*I*) extraídos do sistema de cor HSI (ou HSV) associados com regiões sombreadas para computar, através da diferença normalizada, os valores desse índice. A Figura 4.1e apresenta, na forma de imagem, um exemplo de resultado produzido por esse índice. Em geral, sombra e vegetação têm alta saturação, mas, a vegetação tem intensidade luminosa um pouco maior que alguns tipos de sombras mais claras. Essa diferença é suficiente para contrastar esses dois elementos pelo uso do *nSI*.

$$nSI = \frac{S - I}{S + I} \quad (4.1)$$

O índice *Nanda* é calculado pela diferença entre os valores de brilho registrados nos componentes R, G e B da imagem colorida e, portanto, os valores produzidos por *Nanda* não são normalizados. Para melhores análises, é necessário que esses valores estejam definidos no intervalo $[-1,1]$. Essa normalização é feita dividindo-se todos os valores de *Nanda* pelo maior valor absoluto produzido por ele mesmo ou,

¹¹ $DoA = \frac{G - R}{G + R}$; $Nanda = G - (R + B)$

$$NandA^N = \frac{NandA}{\max(|NandA|)}$$

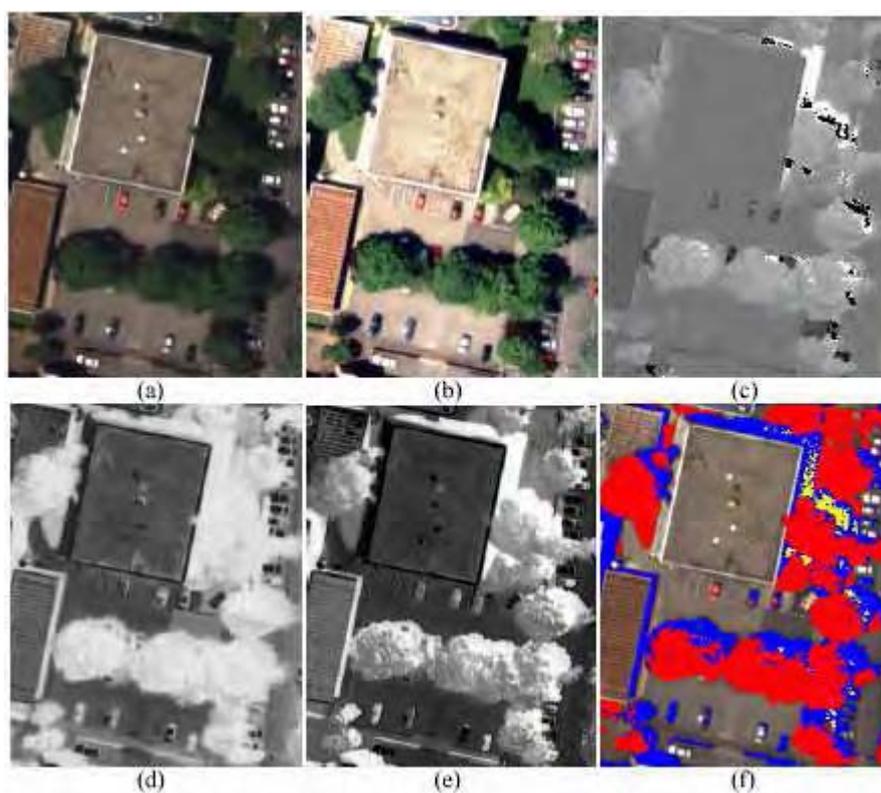


Figura 4.1 Exemplo de aplicação dos índices. (a) Imagem colorida original (IGN). (b) Imagem colorida padronizada por equalização. (c) Imagem *DoA*. (d) Imagem *NandA*. (e) Imagem *nSI*. (f) Imagem temática: vermelho (vegetação); azul e amarelo (sombras).

Para computar esses índices (*nSI*, $NandA^N$ e *DoA*) em imagens aéreas coloridas é necessário, primeiro, padronizá-las, pois se deve considerar que a aquisição dessas imagens pode ser feita em diferentes condições de iluminação e, ainda, este trabalho faz uso de dados de imageamento adquiridos por diferentes sensores, os quais têm características próprias aplicadas ao imageamento. Essa padronização é feita através da equalização ou do alargamento linear do histograma do componente intensidade (*I*) extraído do sistema HSI.

Após aplicar esse procedimento de padronização, deve ser recomposta, através da transformação HSI para RGB, uma nova imagem, correspondente à original. Essa recomposição é feita usando esses novos valores de brilho padronizados associados com o componente *I* – Figuras 4.1a e 4.1b – e, somente então, os componentes *R*, *G*, *B* e *I*, necessários aos cálculos dos índices propostos, podem ser extraídos. O procedimento de padronização não altera os valores do matiz e nem da saturação que estão associados com os elementos presentes na imagem.

A seleção do processo de padronização entre equalização ou alargamento

linear do histograma é realizada com base na média entre os valores de brilho do componente intensidade original. É esperado que os valores de brilho associados com pixels de sombras e de vegetação estejam distribuídos no lado esquerdo do histograma, devido aos baixos valores de brilho correspondente. Considerando que os valores de brilho do componente I ocupam o intervalo $[0, 255]$, se a média entre esses valores for maior que o valor 130 (49% do intervalo possível), existe a indicação da presença de muitos alvos com aparência clara na imagem e, dessa forma a equalização do histograma dos valores associados com I pode produzir uma outra imagem muito mais clara e, assim, distorcer valores de brilho de alguns desses alvos. Assim, nesse caso deve ser aplicado o alargamento linear do histograma $h^s(X)$ ¹² para aumentar o contraste entre os diferentes alvos para minimizar a possibilidade de ocorrência dessa distorção. Se o valor da média dos valores de brilho, extraídos do componente intensidade, for menor que 130, há a indicação de que a imagem é escura ou, existem muitas feições escuras. Nesse caso, é necessário que os valores de I sejam realçados com maior vigor para promover uma redistribuição uniforme desses valores de brilho ao longo do histograma por uma transformação não-linear. Nesse caso, deve ser usada a equalização do histograma.

Para melhor analisar o comportamento dos índices $NandA^N$, nSI e DoA , quarenta pixels foram, manualmente, agrupados em quatro classes, mutuamente exclusivas, cada uma contendo dez pixels e organizadas da seguinte forma: Classe de Alvos Claros – composta de pixels associados com valores de brilho mais elevados; Classe de Alvos Escuros – composta de pixels associados com valores de brilho mais baixos; Classe de Sombras – composta exclusivamente de pixels associados com regiões sombreadas e; Classe de Vegetação – composta exclusivamente de pixels associados com vegetação.

Os valores de cada índice foram calculados para os pixels amostrados, os quais foram dispostos no gráfico apresentado na Figura 4.2. Os valores dos índices mostrados neste gráfico foram normalizados para o intervalo $[0,1]$ para possibilitar uma melhor comparação entre eles.

Pode-se observar nas linhas deste gráfico que todos os índices conseguem destacar sombras e vegetação. Entretanto, o índice DoA produz os resultados mais pobres e, portanto ele não será usado neste trabalho.

O índice $NandA^N$ tem seu pico em regiões sombreadas e em áreas cobertas por vegetação. O índice nSI tem o seu pico em regiões sombreadas e o seu segundo pico está

¹² $h^s(X) = \frac{X - \min(X)}{\max(X) - \min(X)}$

sobre áreas cobertas por vegetação.

Esse padrão de comportamento desses índices foi observado em todas as imagens usadas experimentadas neste trabalho.

4.1.2 Pré-segmentação de Sombras e Vegetação

O método para detectar e discriminar sombras e vegetação usa três atributos: valores do índice $NandA^N$; valores do índice nSI e; informação do matiz das cores dos alvos extraídos do sistema de cor HSI.

O primeiro passo do método de segmentação consiste em pré-segmentar todas as regiões da imagem com potencial de serem sombras e/ou vegetação. O segundo passo consiste em discriminar sombras e vegetação. A segmentação de todas as regiões potenciais de serem sombras ou vegetação é feita usando o histograma dos valores produzidos pelo índice $NandA^N$.

Análises do histograma de $NandA^N$ mostram uma tendência de distribuição bi-modal dos valores produzidos por esse índice. Essa tendência é confirmada quando o número de classes que cobre a amplitude do histograma é reduzido para 10 (Figura 4.3).

Devido ao fato do índice $NandA^N$ realçar a vegetação e sombras com valores elevados, os valores relativos a esses dois elementos têm a forte tendência de serem acomodados no lado direito do histograma. Então, a adoção desses valores acomodados no lado direito do histograma permite inferir a respeito da natureza desses elementos.

Para obter o valor de limiar T_1 , que separa as duas metades do histograma, é necessário localizar as duas classes com maiores frequências que estão, respectivamente, no lado esquerdo e no lado direito do histograma. O valor médio do intervalo entre essas duas classes, intervalo $[A, B]$ mostrado na Figura 4.3, define o valor de T_1 .

Todos os valores distribuídos pelo histograma que estão à direita de T_1 são candidatos a pontos de sombras e/ou vegetação, mas, podem incluir outros elementos. Também, pode ocorrer de existir pontos associados com os elementos de interesse que estão próximo à T_1 , mas à esquerda dele.

O refinamento do valor de T_1 é feito através de medidas estatísticas simples. A imagem correspondente aos valores produzidos pelo índice $NandA^N$ mostra a geração de zonas muito próximas de planas, sem muita variabilidade, e com valor médio elevado para vegetação e sombras. Para garantir que todas as regiões sombreadas e áreas cobertas por vegetação sejam pré-segmentadas, é necessário relaxar o valor de T_1 , deslocando-o para o

lado esquerdo do histograma.

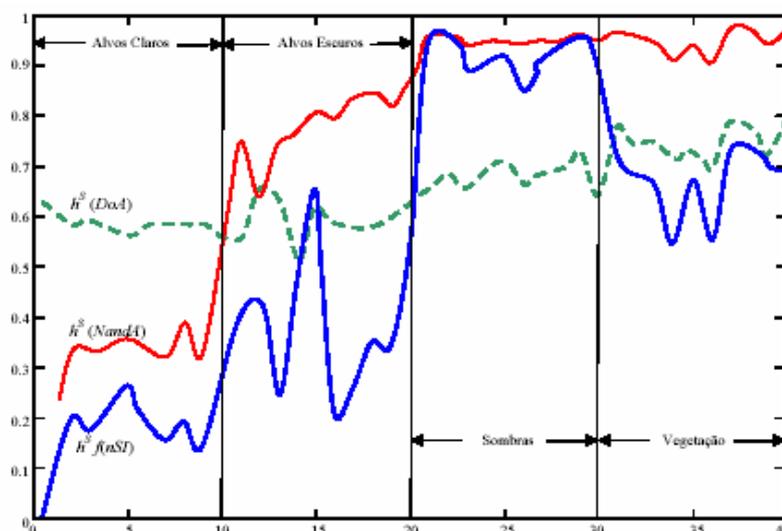


Figura 4.2 Comportamento dos índices sobre classes de alvos (resultados apresentados com alargamento linear do histograma - h^S).

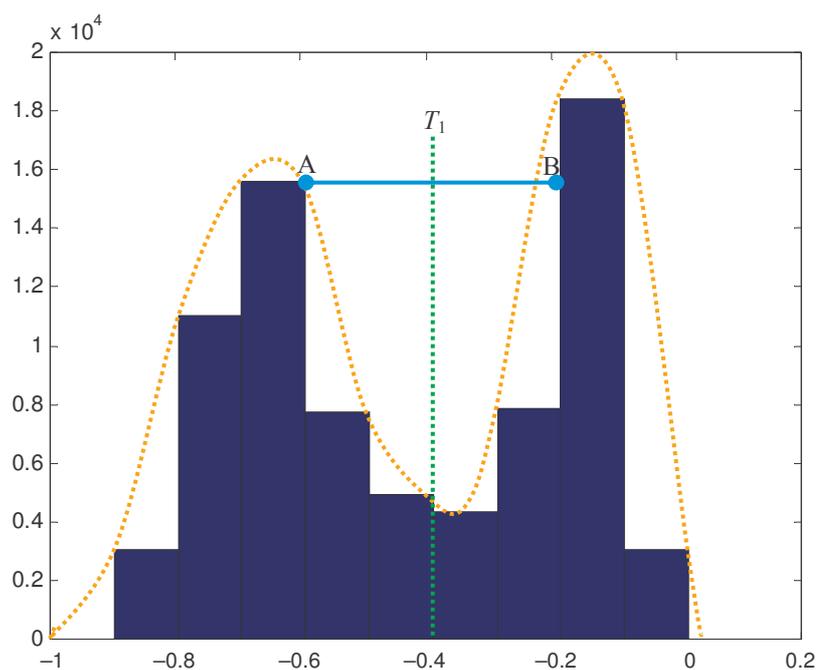


Figura 4.3 Histograma bi-modal com 10 classes dos valores normalizados de $NandA^N$ e a respectiva segmentação das classes que contêm candidatos à sombra e vegetação.

Esse deslocamento é feito pela Equação 4.3, a qual produz um novo valor de limiar T_2 usando exclusivamente pontos segmentados cujo valor pertençam ao vetor¹³ $X = \mathbf{A}_p(B, NandA^N)$, onde B é uma matriz, que contém valores binários, obtida através da

¹³ Obtido com a aplicação da Equação 3.1.

limiarização dos valores de $NandA^N$ pelo valor de limiar T_1 , dada por

$$B_{ij} = \begin{cases} 1, & \text{se } NandA_{ij}^N > T_1 \\ 0, & \text{caso contrário} \end{cases}$$

Sobre esses valores armazenados no vetor X são calculadas medidas estatísticas simples, média μ_X e desvio padrão σ_X , as quais são utilizadas pela Equação 4.3 para refinar o valor de limiar T_1 , produzindo um novo valor de limiar T_2 .

$$T_2 = T_1 + |\mu_X| - 2\sigma_X \quad (4.3)$$

A Equação 4.3 considera que a relação $2\sigma_X > |\mu_X|$ é sempre verdadeira, a qual foi deduzida, empiricamente, através das análises dos resultados obtidos na experimentação realizada. Essa relação empírica se apóia no fato que o índice $NandA^N$ produz, praticamente, valores negativos entre os quais, os mais elevados, ou mais próximos do valor zero, estão associados com sombras e vegetação. Então, se os valores armazenados no vetor X estiverem associados com muitos pontos de sombra e de vegetação, o valor absoluto da média entre os valores de X , $|\mu_X|$, estará próximo de zero e a variabilidade esperada $2\sigma_X$ para esses mesmos valores deve ser maior que $|\mu_X|$. Para analisar a Equação 4.3 deve-se considerar que os valores T_1 e μ_X são negativos. Então, se X é composto somente por pontos associados com vegetação e sombras, a Equação 4.3 deve produzir $T_2 \cong T_1$, caso contrário, deve produzir $T_2 < T_1$, deslocando o valor de limiar T_2 para o lado esquerdo do histograma.

Usando o valor de limiar T_2 , os pontos candidatos à sombra e à vegetação F podem ser segmentados de forma mais completa através do uso da Equação 4.4, a qual produz uma imagem binária F , que associa todos os pontos candidatos correspondentes à sombra e à vegetação com o valor 1.

$$F_{ij} = \begin{cases} 1, & \text{se } NandA_{ij} > T_2 \\ 0, & \text{caso contrário} \end{cases} \quad (4.4)$$

4.1.3 Segmentação e Discriminação de Vegetação

Para discriminar os pixels associados com vegetação verde, é necessário usar atributos de cor, extraídos do componente H (matiz) do sistema de cor HSI (ou HSV) e os valores F produzidos pela Equação 4.4.

No sistema de cor HSI, o matiz H é dado por uma medida angular normalizada para o intervalo $[0, 1]$. O valor H , para uma determinada cor, depende da linha de cor de referência usada e de sua posição angular, sendo que esses dois valores são arbitrários.

Gonzalez e Woods (1992) usaram a linha vermelha como referência na posição 0° . Pratt (1991) usou a linha azul como referência na posição 0° . Este trabalho usa a linha azul como referência na posição 180° e, considera que os três matizes básicos ocupam todo o intervalo fechado possível $[0, 360^\circ]$. Valores H , correspondentes ao matiz verde, ocupam o intervalo aberto $(60^\circ, 180^\circ)$, ou ao intervalo normalizado $(0.17, 0.50)$. Dessa forma, todos os pixels (i, j) da imagem colorida, que estão associados com matiz verde (M^V), são obtidos pela Equação 4.5.

$$M_{ij}^V = \begin{cases} 1, & \text{se } 0.50 > H_{ij} > 0.17 \\ 0, & \text{caso contrário} \end{cases} \quad (4.5)$$

A vegetação verde é representada na imagem binária vgt por pixels com valor igual a 1. Essa discriminação é feita pela aplicação da Equação 4.6 através da intersecção entre as imagens binárias F e M^V .

$$vgt = F \cap M^V \quad (4.6)$$

A Figura 4.1f mostra um exemplo de resultado da segmentação e discriminação de vegetação pelo método proposto (em vermelho).

4.1.4 Segmentação e Discriminação de Sombras

A discriminação dos pixels associados com sombras, pré-segmentados no conjunto F , é feita em duas etapas: (a) uma aproximação inicial para estimar dados estatísticos associados com pontos de sombras e; (b) refinamento dessa estimativa inicial.

Os atributos necessários para discriminar pixels associados com sombras são: a imagem binária M^V , daqueles pixels associados com o valor 1 correspondentes aos elementos que possuem como atributo a cor verde na imagem original; a imagem binária F que associa pixels candidatos à sombra e à vegetação (Equação 4.5) e; valores do índice nSI , usado para realçar pontos de sombras (Equação 4.1).

A imagem binária F é composta de pixels associados com vegetação, sombras e outros artefatos. A estimativa inicial de sombras é feita sobre a eliminação de pixels associados com vegetação e outros artefatos de cor verde da imagem F , os quais são comumente confundidos com sombras. Essa eliminação é obtida com a subtração de F por M^V . Assim, a aproximação inicial shd^0 para se obter uma estimativa de pixels associados com regiões sombreadas nas imagens originais é obtida por

$$shd_{ij}^0 = \begin{cases} 1, & \text{se } F_{ij} - M_{ij}^V > 0 \\ 0, & \text{caso contrário} \end{cases}$$

Embora seja possível haver pixels de sombras associados com a cor verde, (por exemplo, sombras claras projetadas sobre superfícies de cor verde) é mais comum que os pixels de sombra estejam associados com o matiz azul¹⁴.

Seja $X^0 = \mathbf{A}_p(shd^0, nSI)$, o vetor de todos os valores produzidos pelo índice nSI correspondentes aos pontos (i, j) associados com o valor 1 na imagem binária shd^0 (resultado da estimativa inicial de pontos de sombra), obtido pela aplicação da Equação 3.1.

Dessa forma, o vetor X^0 armazena valores nSI que estão associados com pixels de sombras nas imagens originais, ou que estão associados com outros artefatos que podem ser confundidos com sombras.

O índice nSI produz valores elevados e com baixa variabilidade para pixels associados com regiões de sombras. É esperado que o valor da média (μ) entre esses valores nSI que compõem o vetor X^0 seja maior que a variabilidade (σ) entre esses mesmos valores. Observações empíricas mostraram que, para a maioria dos casos, esses valores associados com o vetor X^0 apresentam uma relação $\mu/\sigma < 3$. Análises dos valores produzidos por essa relação, mostraram que, para segmentar sombras corretamente, essa relação deve produzir um valor superior a 6, ou seja os valores associados com X^0 devem produzir um valor médio alto mas com baixa variabilidade (sabendo que 1 é o valor máximo que pode compor X^0 , pois X^0 mapeia valores de nSI , o qual produz valores normalizados no intervalo $[-1, 1]$ e os pontos de sombras estão entre os valores mais elevados produzidos por esse índice).

Se os valores que compõem X^0 são exclusivamente provenientes de pixels associados com sombras na imagem original, o valor da média, entre esses valores nSI armazenados em X^0 , é um valor elevado, mas com baixa variabilidade. Espera-se que, através dessa diferença de ordem de grandeza entre os valores da média e da variabilidade, a desejada relação $\mu/\sigma > 6$ seja alcançada e, conseqüentemente, tornar possível a segmentação das regiões sombreadas na imagem original. Caso contrário se for obtida uma relação $\mu/\sigma < 6$, existe a indicação da presença de artefatos não-sombras que foram pré-segmentados em shd^0 . Neste caso, para melhorar o resultado da segmentação de sombras, é necessário

¹⁴ Em imagens adquiridas pela câmara HRSC-AX, uma parcela de pixels de sombra está associada com o matiz vermelho devido à geometria de imageamento dessa câmara. Também é comum o aparecimento de pixels de cor verde em bordas de alta transição (Seção 5.1). Se esses pixels tiverem alta saturação, eles serão associados com vegetação verde.

eliminar esses valores associados com artefatos não-sombras que foram incluídos em X^0 . Para esse fim foi elaborada, empiricamente, uma equação de recorrência que permite obter um outro vetor $X (X^1)$, o qual armazena outros valores nSI que estão associados com uma menor quantidade de pontos não-sombras na imagem original. Esse novo conjunto de valores X^1 tem valor médio maior e variabilidade menor que o conjunto anterior X^0 , permitindo que a relação $\mu/\sigma > 6$ seja alcançada (ou aproximada). Essa equação de recorrência considera o cálculo de um valor de limiar, T_0^{shd} , baseado na expectativa de que o índice nSI produziu os maiores valores para pontos relacionados com sombras, mas que esses mesmos valores têm baixa variabilidade. Essa equação de recorrência é dada por

$$\begin{aligned}
 T_0^{shd} &= \mu_{X^0} - \frac{3}{2} \sigma_{X^0} \\
 shd_{ij}^1 &= \begin{cases} 1, & \text{se } nSI_{ij} > T_0^{shd} \\ 0, & \text{caso contrário} \end{cases} \quad (4.7) \\
 X^1 &= \mathbf{A}_p(shd^1, nSI)
 \end{aligned}$$

Se $\mu_{X^1}/\sigma_{X^1} > 6$ então, assume-se que todos os pontos (i, j) de nSI que possuem valor maior que T_0^{shd} estão associados com pontos de sombra na imagem original. Caso contrário, $\mu_{X^1}/\sigma_{X^1} < 6$, indica que ainda existem muitos pontos associados com elementos não-sombras no resultado shd_{ij}^1 .

Para a maioria dos casos estudados, para essas novas condições, foi produzido um valor $\mu_{X^1}/\sigma_{X^1} < 4$. Apesar dessa equação de recorrência nem sempre ser capaz de produzir um valor $\mu_{X^1}/\sigma_{X^1} > 6$, deve ser considerado que ela consegue melhorar substancialmente a segmentação de pontos relacionados com sombras, uma vez que em todos os testes realizados, a relação μ_{X^0}/σ_{X^0} nunca produziu um valor superior ao valor 2. Então, $2 < \mu_{X^1}/\sigma_{X^1} < 6$ indica uma melhoria no resultado da segmentação.

O resultado parcial X^1 passa a ser a nova estimativa para detectar pixels associados com sombras. Usando os valores X^1 uma nova razão $\mu_{X^1}/\sigma_{X^1} < 4$ é, geralmente, produzida. Para otimizar essa relação, um novo valor de limiar T_1^{shd} , que segmenta uma maior quantidade de pontos relacionados com sombras sobre o índice nSI , pode ser computado com mais segurança pela equação de recorrência 4.8.

$$\begin{aligned}
T_1^{shd} &= \mu_{X^1} - \sigma_{X^1} \\
shd_{ij}^2 &= \begin{cases} 1, & \text{se } nSI_{ij} > T_1^{shd} \\ 0, & \text{caso contrário} \end{cases} \\
X^2 &= \mathbf{A}_p(shd^2, nSI)
\end{aligned} \tag{4.8}$$

A equação de recorrência 4.7 deve proporcionar $\mu_{X^2}/\sigma_{X^2} > 6$ para a maioria dos casos, estabelecendo assim uma boa margem de segurança para segmentar os pixels associados com sombras, representados por shd^2 . Entretanto, existem situações em que a Equação 4.8 não consegue otimizar o valor do limiar necessário ($\mu/\sigma > 6$) para segmentação de sombras. Um exemplo dessa situação é mostrado na imagem da Figura 4.4b. Neste caso, a aplicação da Equação 4.8 gerou a relação $\mu/\sigma = 2.3$, a qual é insuficiente para discriminar as regiões sombreadas.

Se, após a aplicação da Equação 4.8, for obtido um valor $\mu/\sigma < 6$, então significa que o valor de limiar T_1^{shd} deve ser otimizado por um processo iterativo. Cada iteração desse processo incrementa o valor de T_k pelo aumento do valor de μ_{X^k} e diminuição do valor de σ_{X^k} , ou, em outras palavras, pelo aumento do grau de pureza de pontos associados com sombras amostrados por X^k . O fluxograma desse processo de otimização é apresentado na Figura 4.5.

Para o exemplo da Figura 4.4a, após a execução do processo de otimização proposto, foi produzido o valor $\mu/\sigma = 7$. Os resultados obtidos com a aplicação do valor de limiar T_4 otimizado são apresentados na imagem da Figura 4.4c.

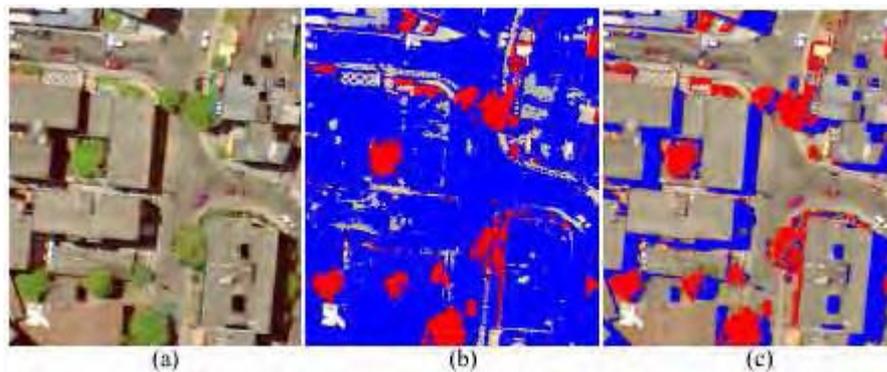


Figura 4.4 Resultados obtidos com o método proposto para segmentação e discriminação de vegetação e sombras. (a) Imagem colorida original (HRSC-AX). (b) Resultado produzido sem otimização do processo de segmentação de sombras. (c) Resultado obtido pelo processo de segmentação de sombras otimizado.

Na experimentação realizada, entre todas as imagens que necessitaram passar pelo processo de otimização, a mais demorada convergiu em três iterações.

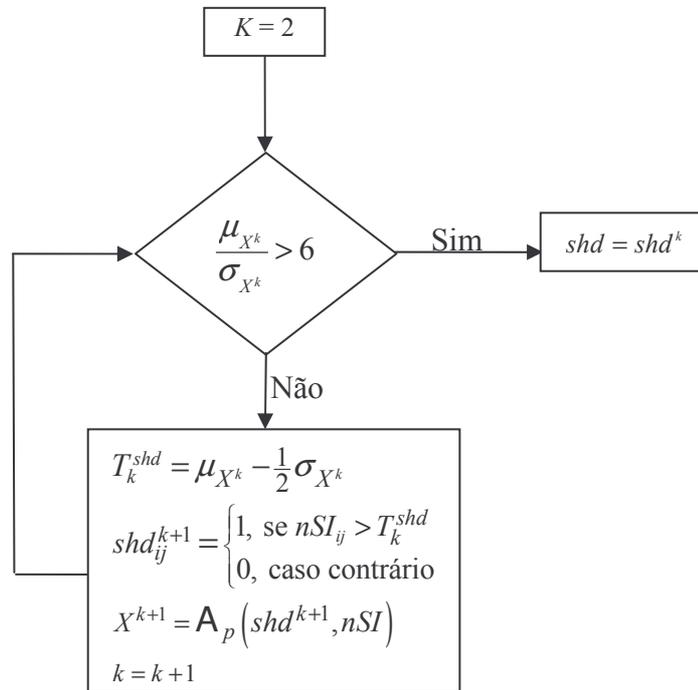


Figura 4.5 Fluxograma do processo de otimização do valor de limiar usado na segmentação de sombras.

4.1.5 Outros Resultados

A seguir são apresentados outros resultados obtidos com a aplicação do método proposto para detectar sombras e vegetação verde em imagens aéreas coloridas.

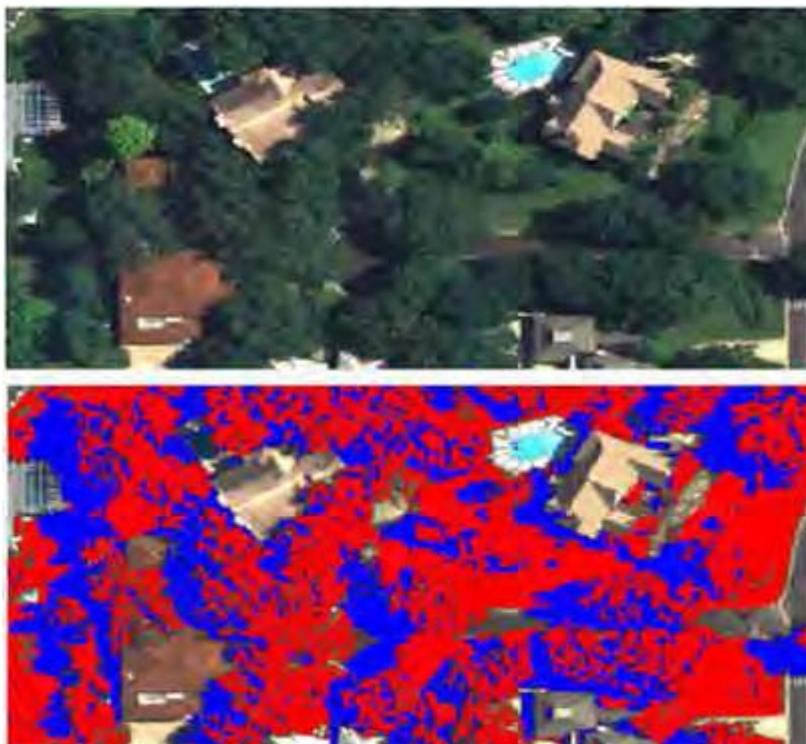


Figura 4.6 Imagem colorida original (ADS40) e imagem apresentando os resultados produzidos pelo método proposto. Sombras em azul e vegetação em vermelho.



Figura 4.7 Imagem colorida original (Kodak 14N) e imagem apresentando os resultados produzidos pelo método proposto. Sombras em azul e vegetação em vermelho.



Figura 4.8 Imagem colorida original (RC-10) e imagem apresentando os resultados produzidos pelo método proposto. Sombras em azul e vegetação em vermelho.



Figura 4.9 Imagem colorida original (DMC) e imagem apresentando os resultados produzidos pelo método proposto. Sombras em azul e vegetação em vermelho.



Figura 4.10 Imagem colorida original (Ultracam) e imagem apresentando os resultados produzidos pelo método proposto. Sombras em azul e vegetação em vermelho.

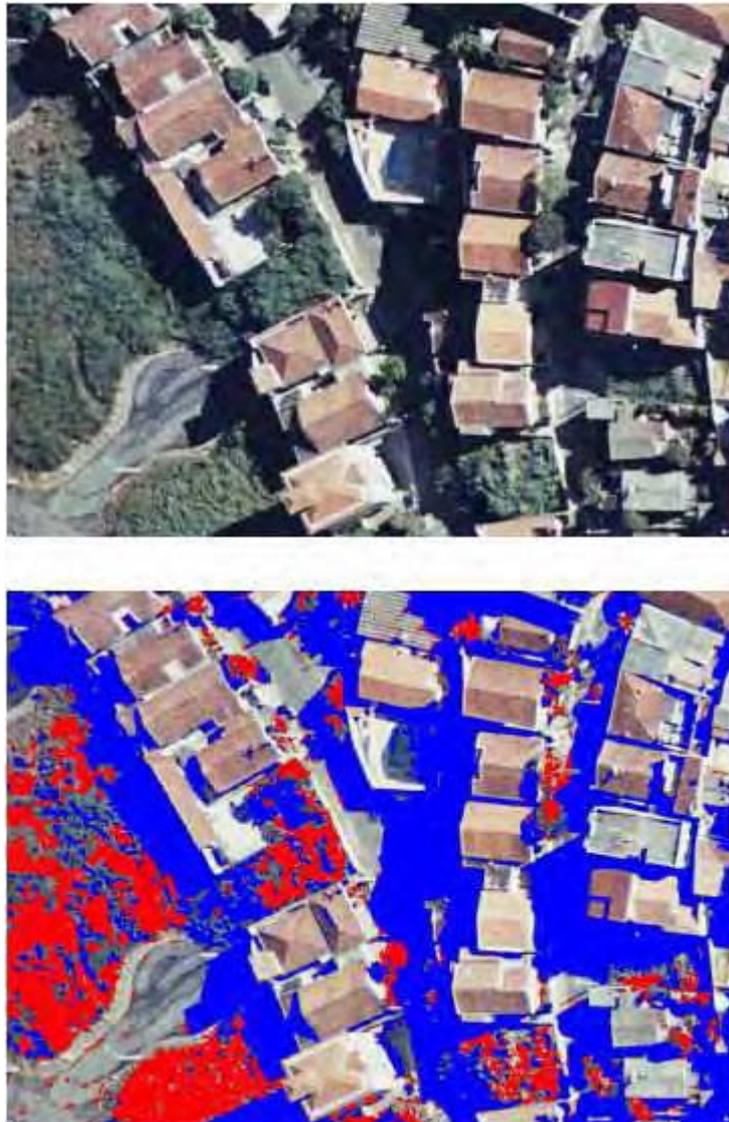


Figura 4.11 Imagem colorida original (RMKTOP 15) e imagem apresentando os resultados produzidos pelo método proposto. Sombras em azul e vegetação em vermelho.

4.1.6 Análise dos Resultados

Na Seção 2.2 foi apresentado o método proposto por Tsai (2006) para realizar a segmentação de regiões sombreadas. O autor propôs um índice chamado de razão espectral dado por $(H + 1)/(V + 1)$, onde H e V são, respectivamente, os valores do matiz e da intensidade (o autor explorou os sistemas de cor HSI e HSV). As regiões sombreadas são segmentadas por um valor de limiar otimizado, obtido pelo método de Otsu, aplicado sobre os valores produzidos por esse índice de razão espectral.

A imagem temática apresentada na Figura 4.12b mostra os resultados produzidos pelo método desenvolvido neste trabalho para segmentação de sombras (azul) e vegetação (vermelho).

Os resultados produzidos pelo método proposto por Tsai para segmentação de sombras estão apresentados na imagem temática mostrada na Figura 4.12c. Nessa imagem temática, a união das regiões azuis com as vermelhas constitui o resultado final obtido pelo método proposto por Tsai. Ainda, nessa imagem, as regiões exclusivamente em vermelho são aquelas que somente o método de Tsai detectou como sombras. O método desenvolvido neste trabalho excluiu essas regiões do resultado. Observe que a maior parte dos pontos vermelhos não está associada com regiões sombreadas.

A imagem original apresentada na Figura 4.12a foi adquirida pela câmara IGN e, em relação ao problema de detecção de sombras, essa imagem é de alta complexidade por apresentar muitos elementos escuros. Deve ser considerado que essa imagem não está de acordo com padrões normalmente esperados, apesar dessa ocorrência e, por esse motivo, constitui-se um desafio para os métodos de segmentação de sombras.

Embora o método desenvolvido tenha conseguido contornar muitos pontos críticos dessa imagem e produzido resultado mais adequado que o método proposto por Tsai, a qualidade dos resultados da segmentação de sombras são inferiores ao padrão médio obtidos para as outras imagens usadas nos estudos de caso realizados. Esse desempenho, abaixo da média geral, se deve à alta correlação positiva que a maioria dos elementos presentes nessa imagem tem com as regiões sombreadas.

Imagens adquiridas pela câmara HRSC-AX, como aquela da Figura 4.4, apresentam muitos problemas nas bordas de elementos elevados e marcas fantasmas nas ruas, devido aos problemas relatados na Seção 3.2. Muitos desses padrões anormais são

segmentados como sombras ou vegetação.

Alguns pontos sobre o asfalto foram segmentados como vegetação na imagem apresentada na Figura 4.7 (Kodak 14N). Esse erro é difícil de ser cometido pelo método proposto, entretanto, quando aparece, possui sempre o padrão mostrado na respectiva imagem temática, isto é, poucos pontos são erroneamente segmentados e, quando estão conectados, formam diversas regiões isoladas de tamanho pequeno. Esses erros de segmentação são facilmente eliminados por processos de filtragem (como filtros de área ou abertura morfológica).

Nos testes realizados, o pior resultado obtido com o método de segmentação de vegetação ocorreu em uma pequena área de uma imagem adquirida pela câmara ADS40, Figura 4.13, a qual apresentou o telhado de uma edificação salpicado por pontos de vegetação. Isto ocorreu devido à variabilidade de cores registradas sobre esse telhado.

A imagem mostrada na Figura 4.9 foi adquirida pela câmara DMC. Essa imagem foi disponibilizada no formato de arquivo JPEG, o qual armazena uma versão da imagem original compactada, em detrimento da perda do detalhamento espectral. Por esse motivo, a qualidade do resultado da segmentação da vegetação obtido ficou abaixo do padrão médio da qualidade dos outros resultados. Mesmo assim, o método proposto conseguiu superar a degradação inerente a essa imagem, mas mostrou a importância da exatidão na representação da resposta espectral, principalmente para a vegetação verde, para o sucesso do método proposto.

Os algoritmos propostos para detectar vegetação e sombras não tratam conflitos entre sombras, vegetação e corpos d'água¹⁵.

De forma geral esse método produz resultados melhores que outros algoritmos, mesmo usando imagens adquiridas por câmaras que realizam automaticamente algum tipo de ajuste de valores radiométricos. Como nas imagens adquiridas pela Ultracam, a qual faz restaurações de regiões sombreadas, deixando-as com uma aparência mais clara que o normal. O algoritmo de detecção de sombras deste trabalho consegue superar a presença de muitos tipos de elementos escuros, não-sombras, presentes na imagem (Figura 4.12).

¹⁵ Esses conflitos (sombras-vegetação-água) são tratados na Seção 4.2.

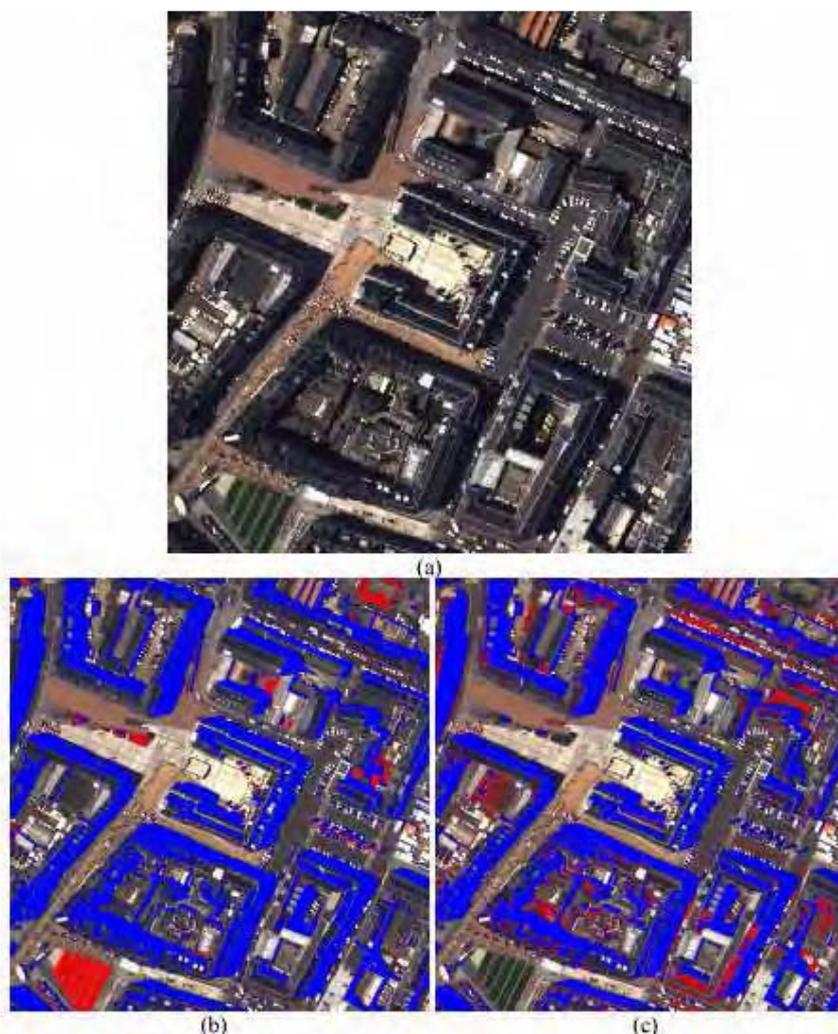


Figura 4.12 (a) Imagem colorida original (IGN). (b) Resultados da segmentação de vegetação (vermelho) e sombras (azul) pelo método deste trabalho. (c) Resultados obtidos pelo método proposto por Tsai (2006) (em vermelho e em azul) para detecção de sombras. Os resultados em azul foram produzidos pelo método deste trabalho.



Figura 4.13 Imagem RGB original (ADS40) e imagem dos resultados produzidos pelo método proposto. Sombras em azul e vegetação em vermelho.

Além das imagens adquiridas por vários sensores digitais, o método proposto foi aplicado em imagens digitalizadas adquiridas em filme por câmaras tradicionais (RC-10 e RMKTOP 15). O processo de digitalização promove perdas de qualidade dos dados

radiométricos e insere ruídos nas imagens digitais correspondentes (Figuras 4.7 e 4.11). Apesar dessas interferências e degradações, o método proposto neste trabalho apresentou bons resultados na segmentação de sombras. Entretanto, em alguns casos, a qualidade da segmentação de vegetação ficou abaixo da média registrada para imagens adquiridas por sensores digitais.

4.2 DETECÇÃO DE ELEMENTOS EM IMAGENS INFRAVERMELHAS E COLORIDAS

Imagens adquiridas na faixa do infravermelho próximo¹⁶ constituem uma valiosa fonte de dados para análises e detecção de elementos específicos. Em geral, essas imagens têm baixa correlação com as respectivas imagens nas faixas do espectro eletromagnético visível¹⁷. A Tabela 4.1 apresenta um exemplo de correlação entre valores de brilho extraídos dos componentes RGB e valores de brilho registrados na imagem correspondente adquirida na faixa do infravermelho, ambas pela câmara IGN.

Essa baixa correlação permite realizar uma melhor exploração da resposta espectral de alguns alvos com o objetivo de extrair atributos específicos.

O interesse principal deste trabalho é detectar elementos específicos em imagens aéreas. Essa detecção é feita sobre valores de índices que realçam os contornos e a região desses elementos desejados, selecionados em função da baixa correlação observada entre os valores de brilho registrados nos componentes *R*, *G* e *B* da imagem colorida com os respectivos valores de brilho capturados na imagem infravermelha (*NIR*) correspondente.

Tabela 4.1 Coeficientes de correlação entre os componentes *R*, *G*, *B* e imagem *NIR*.

	<i>R</i>	<i>G</i>	<i>B</i>	<i>NIR</i>
<i>R</i>	1.00			
<i>G</i>	0.90	1.00		
<i>B</i>	0.83	0.95	1.00	
<i>NIR</i>	0.46	0.44	0.27	1.00

Realces promovidos por índices, usualmente, são mais padronizados que, por exemplo, pela aplicação de técnicas de filtragem, devido ao fato dos índices serem menos sensíveis às variações do ambiente. Principalmente porque as diferentes condições de iluminação entre diferentes cenas são minimizadas, além de não dependerem de valores paramétricos (por exemplo, aplicados em processos de convolução) e de valores dimensionais (tamanho do filtro). Ainda, a maioria dos processos de filtragem opera sobre dados de

¹⁶ Este trabalho usa imagens adquiridas na faixa do infravermelho próximo pelas câmaras HRSC-AX e IGN. Para outras câmaras não estavam disponíveis dados desse tipo.

¹⁷ Todas as imagens coloridas (RGB) usadas neste trabalho cobrem as faixas relativas ao azul, ao verde e ao vermelho do espectro eletromagnético visível.

imagens monocromáticas e os índices de transformação operam sobre atributos espectrais e de cor, ou seja, o realce promovido por índices envolve uma quantidade maior de atributos.

Os índices de realce de alvos específicos usam dados extraídos de imagens espectrais. Esses dados são, normalmente, associados aos valores de reflectância, como relata Huete e Justice (1999) sobre o *NDVI*.

Global-based operational applications of the NDVI have utilized digital counts, at-sensor radiances, 'normalized' reflectances (top of the atmosphere), and more recently, partially atmospheric corrected (ozone absorption and molecular scattering) reflectances. Thus, the NDVI has evolved with improvements in measurement inputs. Currently, a partial atmospheric correction for Rayleigh scattering and ozone absorption is used operationally for the generation of the Advanced Very High Resolution Radiometer [...]. The NDVI is currently the only operational, global-based vegetation index utilized. This is in part, due to its 'ratioing' properties, which enable the NDVI to cancel out a large proportion of signal variations attributed to calibration, noise, and changing irradiance conditions that accompany changing sun angles, topography, clouds/shadow and atmospheric conditions [...] the NDVI tends to increase for atmospherically corrected data (HUETE e JUSTICE, 1999).

Para obter esses valores de reflectância é necessário, primeiro, corrigir (eliminar ou reduzir) os efeitos atmosféricos (espalhamento e absorção) que atuam sobre a região imageada. Para corrigir apropriadamente o espalhamento atmosférico é necessário, por exemplo, conhecer os tipos, dimensões e concentrações de partículas em suspensão na atmosfera local ao imageamento.

Dessa imagem corrigida são extraídos os valores de reflectância associados com cada pixel. Essa operação é dependente do azimute solar (hora do dia) e do zênite solar (data do ano) em que a imagem foi adquirida.

Mesmo considerando imagens adquiridas por uma plataforma satélite (como Landsat) que adquire imagens de diferentes regiões do planeta sempre na mesma hora local do dia (por exemplo, 10H30M da manhã), computar valores de reflectância associados com cada pixel da imagem é uma tarefa complexa.

Por outro lado, missões de imageamento aéreo (uso de aviões) podem demorar várias horas do dia, senão dias, para serem concluídas. Em outras palavras, as condições ambientais e ângulo de elevação solar são alterados rapidamente, pois essas operações de imageamento aéreo são demoradas. Então, nessas condições, calcular valores de reflectância associados com cada pixel em cada conjunto de imagens adquiridas é uma tarefa muito mais difícil de ser executada, senão impraticável (tanto do ponto de vista prático como econômico).

Assim, neste caso, é mais prático usar os valores de brilho ou *DN* (*Digital Number*) associados com cada pixel como um ‘valor aproximado de fator de reflectância’ associado com um alvo específico do que “tentar” estimar o seu valor real. Este trabalho adota essa simplificação para computar os índices baseados em dados espectrais (como *NDVI* e *WWI*).

Nesta seção são propostos métodos para detectar: vegetação; sombras; corpos d’água e marcadores sobre rodovias e vias públicas pavimentadas com asfalto.

4.2.1 Extração de Atributos

Dois atributos usados nos métodos descritos nesta Seção já foram apresentados em Capítulos anteriores: o *NDVI* e o *WWI* (Equação 4.3), os quais são mais comumente usados para realçar vegetação e corpos d’água, respectivamente, além do *nSI* que foi apresentado neste Capítulo¹⁸.

O primeiro passo para computar os índices espectrais propostos e usados neste trabalho é promover a equalização do histograma da imagem *NIR*. Essa operação é importante, pois ela aumenta o contraste entre alvos de superfícies claras e escuras. Em geral, essa operação incrementa os valores de brilho de elementos mais claros e promove o decremento dos valores de brilho de elementos mais escuros, em relação aos valores de brilho da imagem original.

Um exemplo desse fato está ilustrado sobre a imagem *NIR* mostrada na Figura 4.14 (veja também Figura 4.17). Sobre a linha central dessa imagem foi desenhada uma linha vermelha. Todos os valores de brilho sob essa linha vermelha foram extraídos da imagem *NIR* original (linha azul) e da respectiva imagem com histograma equalizado (linha amarela) e, dispostos em gráficos de linhas exclusivos sobre essa imagem.

A linha azul desse gráfico representa a oscilação de cada valor de brilho da imagem original. A linha amarela (pontilhada) representa a oscilação de cada valor de brilho da imagem com histograma equalizado. A linha branca representa a oscilação de cada valor de brilho do componente intensidade extraído do sistema de cor HSI. Pode-se observar que, onde a linha vermelha está sobre alvos escuros, a linha amarela (equalizado) está sempre abaixo ou muito próxima da linha da imagem original (linha azul). No caso da linha vermelha

¹⁸ $NDVI = \frac{NIR - R}{NIR + R}$; $WWI = \frac{G - 4NIR}{G + 4NIR}$; $nSI = \frac{S - I}{S + I}$

sobre alvos claros, a linha amarela (equalizado) está acima da linha azul (original).

Em virtude desse aumento de contraste promovido pela equalização do histograma da imagem *NIR*, essa nova imagem é usada neste trabalho em substituição à imagem *NIR* original. A partir daqui, quaisquer referências à imagem *NIR*, entenda-se imagem *NIR* com histograma equalizado, exceto nos casos em que for mencionado o uso da imagem original.

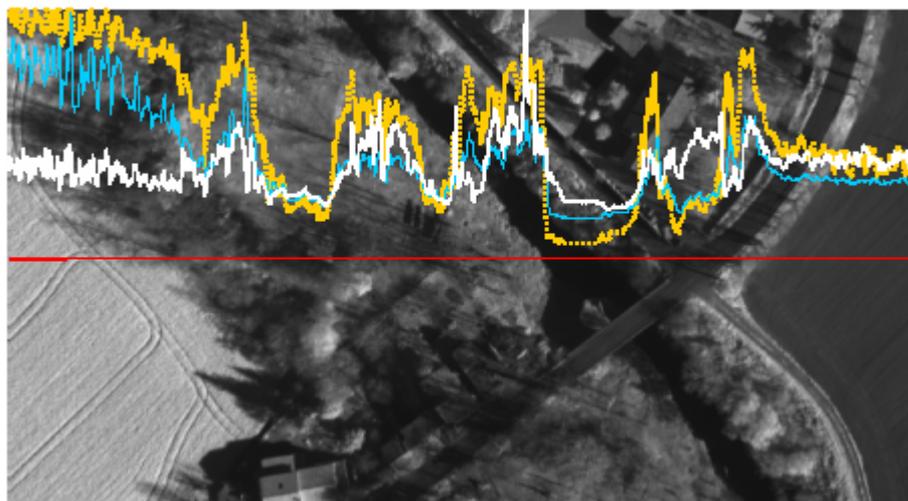


Figura 4.14 Ilustração do aumento de contraste entre elementos claros e escuros com a equalização da imagem *NIR*. (Imagem *NIR* original adquirida pela câmara IGN).

4.2.1.1 *sSI* – Índice Espectral de Sombras

O índice *sSI* (*Spectral Shadow Index*) segue o mesmo princípio do índice *nSI*. A diferença está no uso dos valores de brilho da imagem *NIR* em substituição ao componente intensidade (*I*) extraído do sistema de cor HSI. Essa substituição visa promover um maior contraste entre vegetação e sombras, uma vez que os valores de brilho associados com pixels de vegetação verde são muito maiores na imagem *NIR* que aqueles observados no componente *I*. Entretanto, o índice *sSI* (Equação 4.9) também promove um realce significativo sobre corpos d'água, devido aos baixos valores de brilho registrados na imagem *NIR* para pixels relativos a esse elemento.

$$sSI = \frac{S - NIR}{S + NIR} \quad (4.9)$$

4.2.1.2 *nRI* – Índice Normalizado de Rodovias

O índice *nRI* (*normalized Road Index*) foi formulado para realçar rodovias e vias públicas pavimentadas com asfalto e é obtido através de uma combinação de índices.

O primeiro passo é conseguir uma medida de realce que envolva os padrões de rodovia. Isto é conseguido com o índice *RWSI* (*Road-Water-Shadow Index*), o qual realça rodovias, corpos d'água e alguns tipos de sombras.

O índice *RWSI* é obtido pela diferença normalizada entre a imagem *NIR* e o componente *I* (HSI). Pode ser observado, nos gráficos da Figura 4.14, que onde a linha vermelha passa sobre alvos escuros (sombras, corpos d'água e rodovias), o valor da intensidade *I* (linha branca) é maior que o valor correspondente na imagem *NIR* com histograma equalizado (linha amarela pontilhada). Essa diferença positiva em favor do valor da intensidade é realçada com o cômputo do índice *RWSI* pela diferença normalizada (Equação 4.10)

$$RWSI = \frac{I - NIR}{I + NIR} \quad (4.10)$$

Os gráficos apresentados na Figura 4.15 mostram comportamentos das respostas de alguns índices em função de alguns alvos específicos. Esses comportamentos podem ser comparados com a resposta espectral capturada na imagem *NIR* correspondente com histograma equalizado (linha preta).

Deve ser observado na Figura 4.15, em particular, o comportamento da linha pontilhada vermelha, a qual corresponde à resposta do índice *RWSI* sobre os alvos considerados. O comportamento da resposta desse índice mostra que os valores mais elevados estão sobre rodovias pavimentadas com asfalto, alguns tipos de sombras e corpos d'água. Esse padrão de resposta se repetiu em todas as imagens analisadas e, ainda, o *RWSI* tem um comportamento estável sobre corpos d'água e rodovias.

O índice com menor correlação com o *RWSI* sobre rodovias é o *nSI*, e aquele com maior correlação é o *NDVI*. Entretanto, o valor da soma (*NDVI + nSI*) é menor que o valor correspondente ao *RWSI* sobre rodovias. Como o *NDVI* tem a sua melhor resposta sobre vegetação e o *nSI* sobre sombras e, o valor da soma de ambos tem uma resposta média próxima de zero para solo exposto, seria interessante se (*NDVI + nSI*) fosse maior que os correspondentes valores de *RWSI* sobre pontos de todos os outros alvos, exceto rodovias. Mas isto não ocorre, pois existem muitos pontos onde valores *NDVI* e valores *nSI* se anulam ou ambos são negativos.

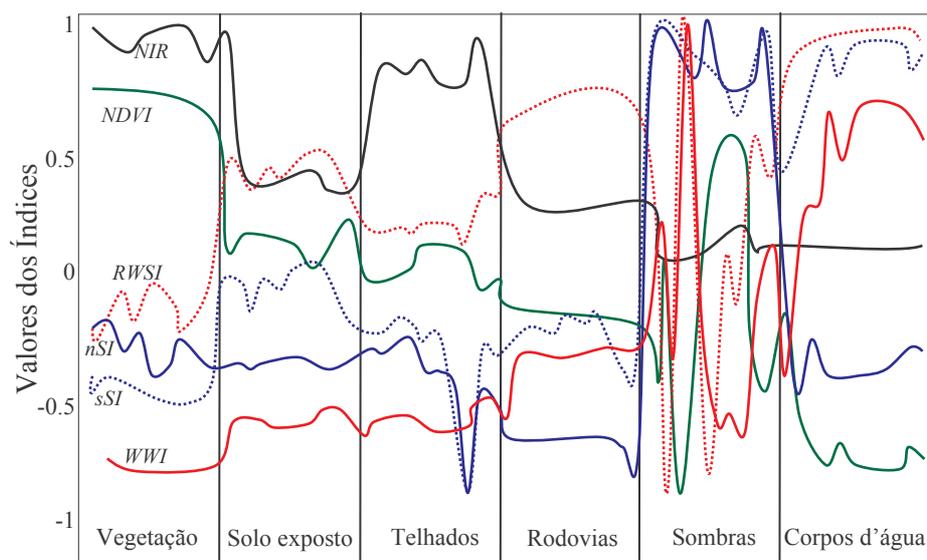


Figura 4.15 Padrões das respostas dos índices sobre os elementos de interesse: vegetação, solo exposto, telhados de edificações, rodovias, regiões sombreadas e corpos d'água: *NIR* (linha preta), *NDVI* (linha verde), *nSI* (linha azul), *sSI* (linha pontilhada azul), *WWI* (linha vermelha) e *RWSI* (linha pontilhada vermelha).

Com o alargamento linear do histograma $h^S(X)^{19}$, os valores dos índices são deslocados para o lado positivo, deixando de ocupar o intervalo $[-1,1]$ para ocupar o intervalo $[0,1]$. Assim, apesar de $(NDVI + nSI)$ produzir resultados nulos ou negativos em muitos pontos, a transformação $h^S(NDVI + nSI)$ desloca proporcionalmente esses valores para o lado positivo. Se o ponto de mínimo de $(NDVI + nSI)$ estiver sobre uma rodovia (caso ideal), corpo d'água ou sombra então, para outros elementos, $h^S(NDVI + nSI)$ produzirá valores superiores, ou quase equivalentes, aos produzidos por *RWSI*. Entretanto, para computar um valor de índice pela diferença normalizada, é necessário que todos os dados envolvidos tenham base em uma mesma escala (ou ordem de grandeza). Assim, também se deve aplicar essa transformação nos valores do índice *RWSI*, ou seja, computar $h^S(RWSI)$. Como *RWSI* tem seu ponto de máximo sobre pontos de rodovias, corpos d'água ou sombras, a operação de transformação $h^S(RWSI)$ não deve aumentar significativamente as distâncias (diferenças) em relação aos pontos $h^S(NDVI + nSI)$ correspondentes a outros elementos, exceto nos

¹⁹ Neste caso se trata de um estreitamento do histograma, uma vez que os valores dos índices estão distribuídos no intervalo $[-1, 1]$ e com a aplicação da Equação $h^S(X) = \frac{X - \min(X)}{\max(X) - \min(X)}$, eles passam a ocupar o intervalo $[0, 1]$.

casos de rodovias e corpos d'água.

A Figura 4.16 mostra um exemplo da relação de distâncias entre os valores de pontos correspondentes produzidos pela composição e transformação dos índices $RWSI$, $NDVI$ e nSI na forma $h^S(RWSI)$ e $h^S(NDVI + nSI)^{20}$. Deve ser observado, nessa relação, que as maiores diferenças entre esses dois conjuntos de valores estão sobre rodovias, corpos d'água e alguns tipos de sombras.

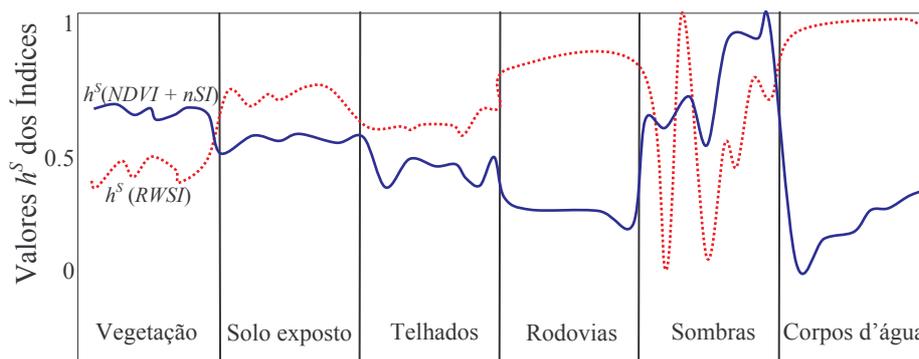


Figura 4.16 Relação de distância entre $h^S(NDVI + nSI)$ – linha azul – e $h^S(RWSI)$ – linha vermelha pontilhada.

Baseando-se nessas relações de distância, define-se a proposta do índice de realce de rodovias nRI (*normalized Road Index*), o qual é dado pela Equação 4.11.

$$nRI = \frac{h^S(RWSI) - h^S(NDVI + nSI)}{h^S(RWSI) + h^S(NDVI + nSI)} \quad (4.11)$$

4.2.1.3 mWI – Índice Espectral de Água Máximo

O índice WWI^{21} foi projetado para realçar corpos d'água em imagens adquiridas por sensores embarcados em plataformas satélites (orbitais). Como a resolução espacial dessas imagens é, geralmente, maior que 2m (2.8m para imagens Quickbird), detalhes sobre os corpos d'água são misturados entre si, deixando-os com uma aparência mais homogênea. Mas para imagens aéreas adquiridas com 30cm, ou menor, esses detalhes passam a ter maior significância e fazem com que o WWI responda de forma variada sobre corpos d'água.

Para minimizar essa interferência na resposta de corpos d'água, propõe-se

²⁰ O uso de sSI ao invés de nSI nesta expressão também produz resultados interessantes, com o inconveniente de realçar tipos de solos mais claros e vegetação seca.

²¹ $WWI = \frac{G - 4NIR}{G + 4NIR}$

uma alternativa ao uso do *WWI*, chamado *mWI* (*maximum Water Index*), o qual consiste, primeiro, em tomar os maiores valores de brilho possíveis entre as três imagens espectrais adquiridas no espectro visível (ou nas respectivas bandas R, G e B de uma imagem colorida). Esse procedimento cria uma nova imagem *M* composta somente com os maiores valores de brilho registrados entre essas imagens. *M* é dado por: $M = \max(R, G, B)$. Assim, se houver vegetação verde, os pixels de *M* relativos a esse elemento serão os mesmos do componente *G* (imagem adquirida na faixa verde do espectro eletromagnético). Se houver água e, se ela for avermelhada, os seus pixels serão os mesmos da imagem adquirida na faixa vermelha do espectro, e assim por diante.

O objetivo dessa operação é conseguir obter os maiores valores de brilho para corpos d'água. Como é esperado que a imagem infravermelha registre os menores valores de brilho para corpos d'água, o índice *mWI* (Equação 4.12) calculado pela diferença normalizada entre *M* e *NIR*, realça corpos d'água de diferentes tipos de forma mais padronizada que o índice *WWI*.

Como os valores de radiância observados sobre corpos d'água são muito baixos em todo espectro eletromagnético, quaisquer modificações sobre esses valores podem comprometer a eficiência deste índice. Assim, para este caso, devem ser usados os valores de brilho registrados na imagem infravermelha original ($NIR_{Original}$)

$$mWI = \frac{M - NIR_{Original}}{M + NIR_{Original}} \quad (4.12)$$

4.2.2 Análise e Visualização do Comportamento dos Índices

A Figura 4.17 apresenta uma imagem NIR com histograma equalizado (a imagem NIR original é apresentada na Figura 4.14), as quais são usadas para computar exemplos dos índices já apresentados.

A Figura 4.15 apresenta gráficos de linha mostrando os comportamentos das respostas dos índices sobre seis grupos de alvos específicos: vegetação, solo exposto, telhados de edificações, rodovias, sombras e corpos d'água. Os gráficos em questão foram obtidos da seguinte forma: (1) dez pontos sobre cada um dos alvos considerados foram, manualmente, escolhidos; (2) os respectivos valores dos índices *NDVI*, *WWI*, *nSI*, *sSI* e *RWSI* foram calculados para cada ponto escolhido e, em seguida, dispostos nos respectivos gráficos de linha. Para melhor análise, os respectivos valores *NIR*, normalizados para o intervalo [0,1], também foram dispostos em um gráfico de linha particular. As seguintes análises são feitas

sobre esses gráficos mostrados na Figura 4.15.

Para os grupos solo exposto e telhados de edificações a variabilidade da resposta dos índices é maior que aquelas apresentadas nestes gráficos. Isto se deve à variabilidade de cor e da constituição química dos materiais que compõem esses alvos específicos. Ainda, a resposta espectral do solo depende do seu teor de umidade.

Em todas as imagens analisadas (adquiridas pelas câmaras HRSC-AX e IGN), considerando os elementos vegetação e rodovias, os valores das respostas obtidas por esses índices, foram mais estáveis e mais elevados nos índices *NDVI* para vegetação, e *RWSI* e *nRI* para rodovias.

Sobre corpos d'água, as intensidades das respostas dos índices são significativamente alteradas. Em outras palavras, dependendo do tipo e da constituição de um corpo d'água, cada índice pode obter uma resposta maior ou menor alterando assim, a altura da sua respectiva curva de resposta sobre esse elemento. Essa alteração não é linear entre os índices. Dependendo do tipo do corpo d'água, pode haver uma maior aproximação ou maior distanciamento entre essas curvas de respostas.

Esse fato dificulta a detecção e a discriminação de corpos d'água. Entretanto, não foram observados casos de alteração na ordem das posições dessas curvas, ou seja, as respostas mais altas para corpos d'água, independentemente das alturas das curvas, são dadas pelos índices *RWSI*, *sSI* e *WWI*. Contudo, o índice *mWI* além de conseguir a resposta máxima para corpos d'água, consegue superar a variabilidade existente entre corpos d'água distintos (ou no interior de um mesmo corpo d'água), produzindo respostas mais estáveis.

O comportamento das respostas desses índices para regiões sombreadas, apresentado na Figura 4.15, mostra a dificuldade de se tratar esse elemento. Com exceção dos índices *sSI* e *nSI*, todos os outros oscilam fortemente sobre pontos sombreados. Inclusive, o *NDVI* produz valores elevados sobre alguns tipos de sombras, tornando impossível detectar e extrair vegetação, através da segmentação de valores *NDVI* por um valor de limiar, sem haver a confusão de uma parcela dessas sombras, ditas aqui como tipos “especiais” de sombras, com a própria vegetação.

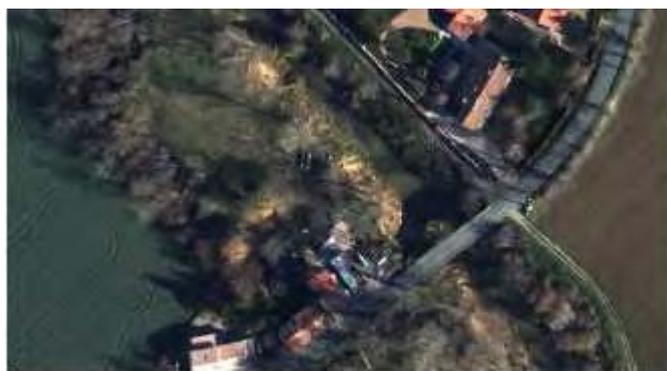
Esse comportamento instável das sombras se deve ao fato da resposta radiométrica, capturada pelo sensor sobre esse elemento, ser dependente: (a) da natureza da superfície sobre a qual ela está projetada; (b) da radiância difusa que atua sobre essa superfície e; (c) da intensidade do espalhamento atmosférico de Rayleigh. Os índices *sSI* e *nSI* conseguem minimizar esse comportamento instável por usar atributo de cor (saturação)

nos seus respectivos cálculos, o qual é mais estável em regiões sombreadas.

As figuras a seguir apresentam visualizações dos valores produzidos pelos índices usados e propostos neste trabalho.



Figura 4.17 Imagem NIR com histograma equalizado.



(a)



(b)

Figura 4.18 Realce de vegetação verde. (a) Imagem colorida original. (b) imagem *NDVI*.

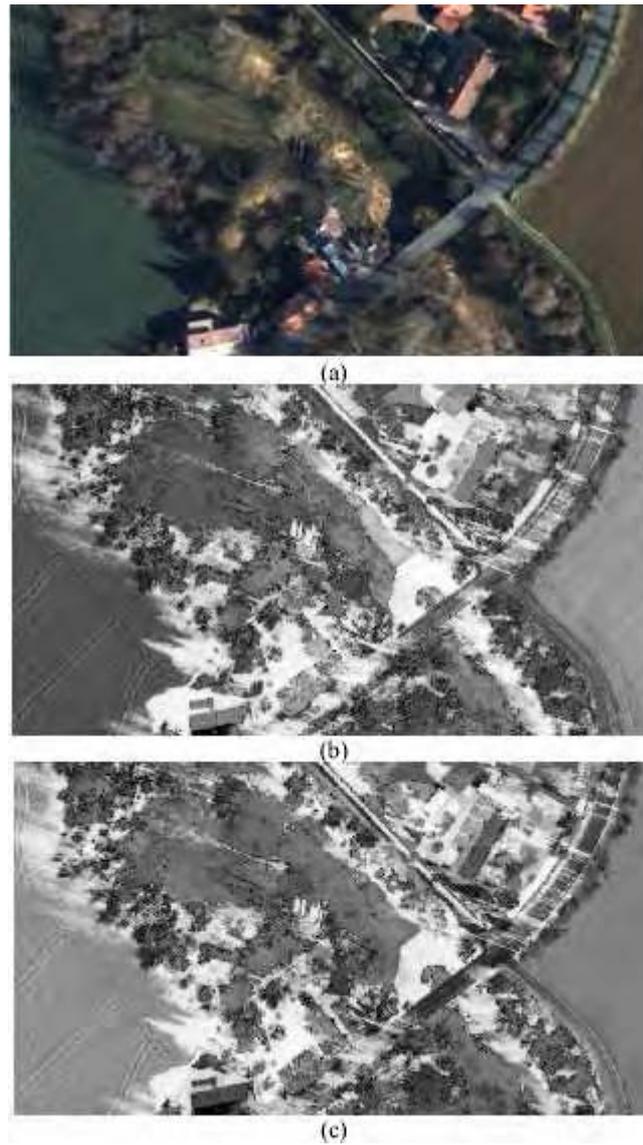


Figura 4.19 Realce de sombras. (a) Imagem original. (b) Imagem *sSI*. (c) Imagem *nSI*.

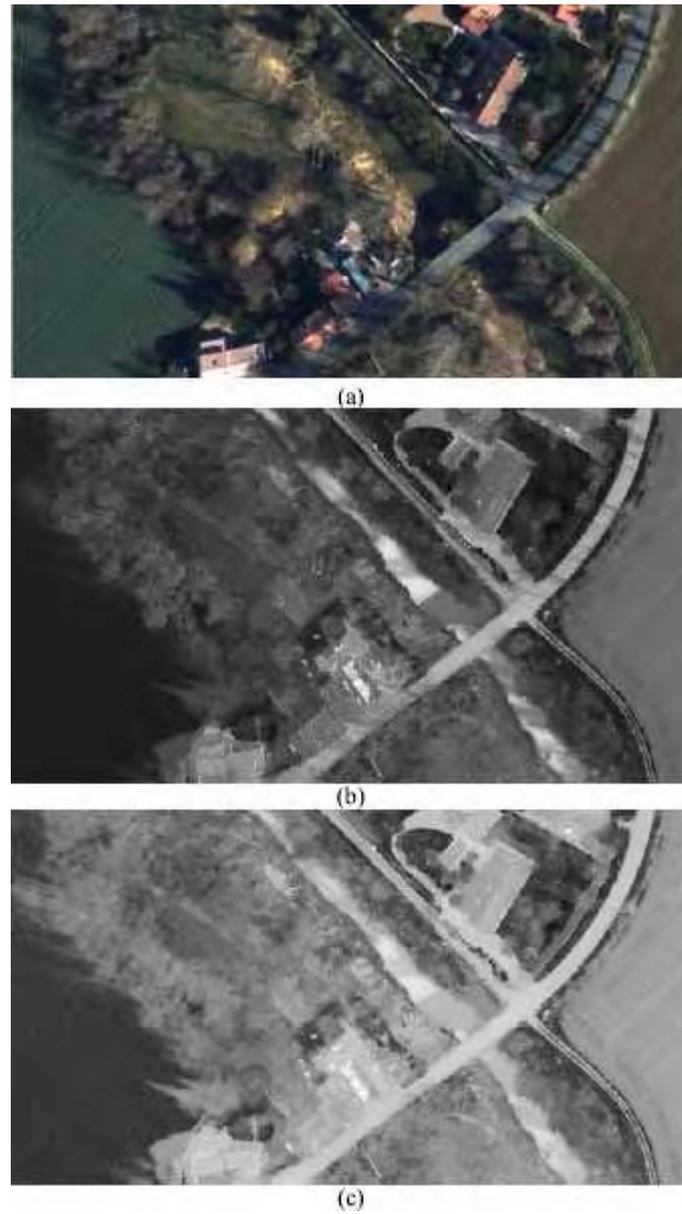


Figura 4.20 Realce de corpos d'água. (a) Imagem original. (b) Imagem *WWI*. (c) Imagem *mWI*.



Figura 4.21 Realce de corpos d'água, sombras e rodovias. (a) Imagem original. (b) Imagem *RWSI*. (c) Imagem *nRI*.

4.2.3 Discriminação e Detecção dos Elementos de Interesse

A seguir são apresentados métodos específicos para detectar e discriminar os elementos de interesse: sombras, corpos d'água, vegetação, rodovias e vias públicas pavimentadas com asfalto.

Esses métodos usam operações lógicas e aritméticas simples para cumprir seus objetivos e, em alguns casos medidas estatísticas simples também são necessárias.

Foram experimentados neste trabalho vários métodos de classificação e técnicas de agrupamentos (como a máxima verossimilhança, mapas auto-organizáveis de Kohonen e o algoritmo K-médias), os quais usaram os resultados dos índices propostos neste

trabalho como atributos em seus respectivos processos. Os resultados obtidos foram de boa qualidade, com menor acurácia do K-médias.

Entretanto, neste trabalho são propostas técnicas mais simples, totalmente automáticas, para detectar e discriminar os elementos de interesse. Essa simplicidade é possível pois, as técnicas propostas, são baseadas na qualidade das respostas de realce promovidas pelos índices propostos.

4.2.3.1 Detecção e Discriminação de Corpos d'água

Para detectar e discriminar corpos d'água são usados atributos de cor, extraídos do componente H do sistema de cor HSI; da intensidade da resposta do índice mWI (Equação 4.12) e dos valores de brilho da imagem infravermelha original.

Seja X o vetor que contém todos os valores mWI superiores ao valor 30% do valor máximo observado no próprio mWI , ou usando a Equação 3.1,

$$B_{ij} = \begin{cases} 1, & \text{se } mWI_{ij} > 0.3 \max(mWI) \\ 0, & \text{caso contrário} \end{cases}$$

$$X = \mathbf{A}_p(B, mWI)$$

Experimentos mostraram que o valor de corte usado, $0.3 \max(mWI)$, sobre valores mWI é suficiente para englobar todos os corpos d'água existentes nas imagens, incluindo rodovias, alguns tipos de sombras e solo exposto. Um exemplo de resultado desse corte é mostrado na imagem temática da Figura 4.22b (união das regiões em azul e vermelho).

Observa-se na Figura 4.22b que os pixels não correspondentes aos corpos d'água ou têm valor de brilho maior que corpos d'água observados na imagem NIR (solo exposto e rodovias) ou são sombras muito intensas. Para eliminar esses pixels é necessário usar atributos de cor (extraídos do sistema de cor HSI) e medidas estatísticas extraídas dos valores armazenados no vetor X .

Os parâmetros estatísticos de média e dispersão sobre os valores mWI , originados dos pontos candidatos a corpos d'água, armazenados no vetor X , juntamente com a resposta espectral padrão conhecida para corpos d'água, permitem melhorar o pré-resultado apresentado na Figura 4.22b. Se não existir corpos d'água nas imagens analisadas, o índice mWI responde com valores baixos e com pequena variabilidade, pois, esse índice produz valores muito próximos para rodovias, alguns tipos de solo e alguns tipos de sombras. Se existirem corpos d'água, a tendência é que seja produzido um valor médio um pouco mais elevado, mas a variabilidade aumenta muito pouco.

A razão entre as medidas estatísticas desvio padrão σ_X e média μ_X obtidas entre os valores mWI armazenados no vetor X , estabelece o coeficiente de dispersão relativa do conjunto. Quanto mais similares espectralmente forem os alvos, menor é o valor da razão σ/μ . Se isto ocorrer para os valores selecionados de mWI , significa que os alvos sombras, rodovias, solo exposto e corpos d'água têm valores muito próximos e, neste caso, separá-los é mais difícil. Uma medida para se saber o grau dessa dificuldade (k) é dada pela Equação 4.13. O peso dois é usado nesta equação para relaxar o valor do parâmetro k .

$$k = \frac{\mu_X}{2\sigma_X} \quad (4.13)$$

Como os valores de brilho relativos aos corpos d'água registrados nas imagens, em geral, são baixos então, na expressão $(mWI - NIR)$, NIR subtrairá baixos valores de mWI relativos aos corpos d'água, e valores maiores relativos a outros alvos, exceto para alguns tipos de sombra. Se, essa expressão for ponderada pelo parâmetro de dificuldade k , uma maior quantidade de pontos não associados com corpos d'água podem ser removidos.

Considerando que, quanto maior for o valor de k menor a dispersão dos valores mWI associados com os diferentes alvos relacionados no vetor X e, quanto mais compactos eles estiverem, maiores valores NIR devem subtrair valores mWI para conseguir discriminar coerentemente corpos d'água. Logo, como existe a relação direta de aumento dos valores NIR com o aumento do parâmetro de dificuldade k , a expressão

$$(mWI - k(NIR))$$

define parte do processo de detecção de corpos d'água. Os resultados obtidos com essa expressão podem ser vistos na imagem temática da Figura 4.22c. O valor $k = 2$ foi obtido neste exemplo.

Ocorrem dois tipos de resultados errados apresentados na imagem temática da Figura 4.22c. Um está praticamente sobre as rodovias, influenciados por sombras tênues (provocado pelo relaxamento do valor de k). O outro, sobre sombras muito escuras (provocado, principalmente, pela correção radiométrica DOS da câmara IGN).

Experimentos realizados neste trabalho mostraram que tanto essas sombras mais escuras como as mais tênues estão associadas com uma faixa restrita de matiz, a qual não envolve corpos d'água. Essa restrição do matiz (h) é feita sobre o componente H , extraído do sistema de cor HSI, pela Equação 4.14.

$$h_{ij} = \begin{cases} 1, & \text{se } 0.1 < H_{ij} < 0.58 \\ 0, & \text{caso contrário} \end{cases} \quad (4.14)$$

A imagem temática, Figura 4.22b, mostra em amarelo e em azul todos os alvos cobertos por essa restrição. Observa-se que somente as sombras mais escuras e mais tênues não são envolvidas por essa restrição.

O processo final da detecção e discriminação de corpos d'água (*wtr*) é feito pela Equação 4.15, a qual aplica a intersecção entre os resultados obtidos com o uso do parâmetro *k*, como peso para os valores *NIR*, e a restrição do matiz *h*.

Eventuais pontos, ou pequenas regiões, isolados são erroneamente segmentados. Para resolver esse problema são usados os operadores morfológicos erosão \mathcal{E}_B e dilatação \mathcal{D}_B ²². O resultado da segmentação é erodido para remover esses pontos errados e, o resultado produzido é dilatado para reconstituir as áreas de interesse danificadas pela erosão. Essas duas operações usam o mesmo elemento estruturante (*B*), um quadrado de dimensões 5×5. Erodir e dilatar uma imagem usando o mesmo elemento estruturante é equivalente à abertura morfológica da imagem por esse elemento estruturante, ou $\gamma_B = \mathcal{D}_B \mathcal{E}_B$. O resultado final da detecção e discriminação de corpos d'água pelo método proposto é mostrado na Figura 4.23.

A confusão mais freqüente cometida por este método é marcar a presença de corpos d'água sobre rodovias.

$$W_{ij} = \begin{cases} 1, & \text{se } (mWI_{ij} - k(NIR_{ij})) > 0 \\ 0, & \text{caso contrário} \end{cases} \quad (4.15)$$

$$wtr = \gamma_B(W \cap h)$$

²² Operadores, filtros e transformadas da Morfologia Matemática binária e cinza são encontrados em (BANON e BARRERA, 1998; FACON, 1996; HEIJMANS, 1994; SOILLE, 1999; DOUGHERTY, 1992; D'ORNELLAS, 2001; SERRA, 1982).

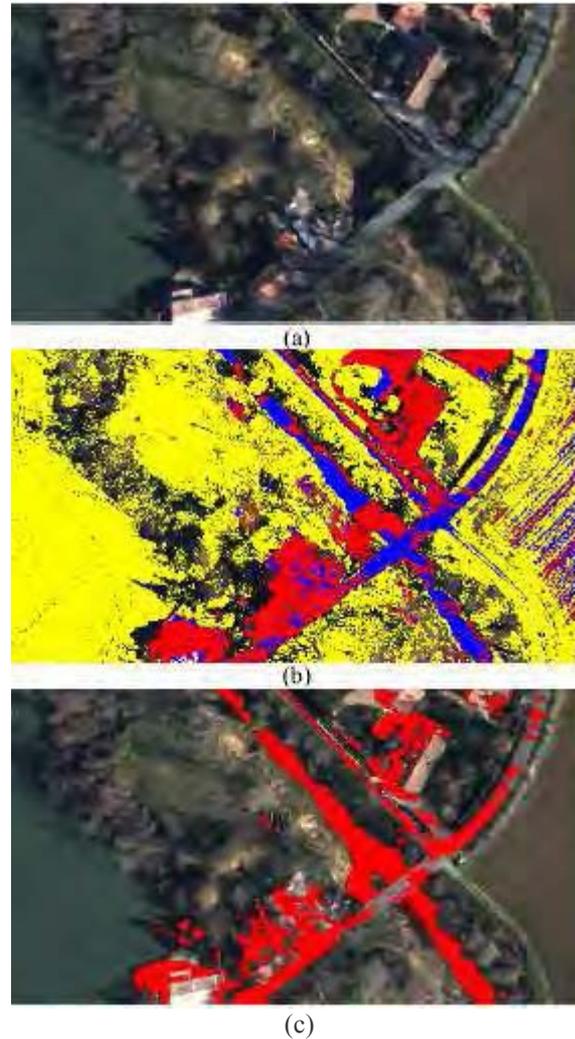


Figura 4.22 (a) Imagem original IGN. (b) Imagem temática: corte superior a 30% do valor máximo observado no índice mWI (em vermelho e azul). Restrição do matiz dos alvos (em amarelo e azul). Intersecção entre os resultados do corte e da restrição do matiz (em azul). (c) Resultado da segmentação de corpos d'água usando somente o parâmetro de dificuldade k como restrição.



Figura 4.23 Resultado final da segmentação de corpos d'água.

4.2.3.2 Detecção e Discriminação de Sombras

Sombras e corpos d'água são difíceis de discriminar. Como corpos d'água já foram discriminados (Seção 4.2.3.1), sombras podem ser mais facilmente separadas. Para discriminá-las, fez-se uma análise dos gráficos dos comportamentos das respostas dos índices sobre elementos específicos mostrado na Figura 4.15. Por uma questão de comodidade, uma cópia dessa figura foi inserida nesta Seção (Figura 4.24).

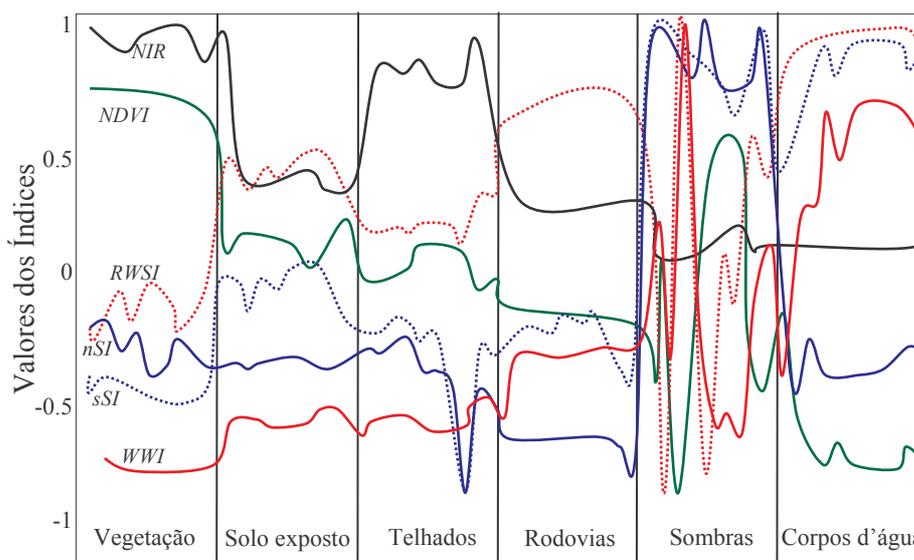


Figura 4.24 Cópia da Figura 4.15, a qual mostra o comportamento das respostas dos índices sobre elementos específicos.

Observa-se na Figura 4.24 que os índices *nSI* (linha azul) e *sSI* (linha azul pontilhada) produzem os maiores valores de respostas para regiões sombreadas, além de serem mais estáveis. Além disso, os valores de brilho correspondentes na imagem *NIR* (linha preta) são sempre superiores aos respectivos valores de *nSI* e *sSI*, exceto nas regiões sobre corpos d'água e sombras.

Uma outra característica importante sobre sombras está no comportamento do *NDVI*. O índice *NDVI* (linha verde) possui valores inferiores aos valores de brilho da imagem *NIR* (linha preta) para todos os elementos considerados, exceto para algumas regiões de sombras “especiais”. Para essas regiões, quanto maior é o valor *NDVI*, menores são os valores correspondentes *nSI* e *sSI*. Assim, as regiões sombreadas (*shd*) são detectadas por duas soluções diferentes. Uma que explora as regiões onde $NDVI > NIR$ e, outra que explora a diferença entre os valores mínimos produzidos pelo *nSI* e *sSI*, $\min(nSI, sSI)$, e os valores de brilho correspondentes registrados na imagem *NIR*. Deve-se ainda, excluir desse resultado a intersecção com corpos d'água *wtr* (Equação 4.16).

A Figura 4.25b apresenta um exemplo do resultado de segmentação de sombras usando o método proposto.

$$shd_{ij} = \begin{cases} 1, & \text{se } (sw_{ij} - wtr_{ij}) > 0 \\ 0, & \text{caso contrário} \end{cases} \quad (4.16)$$

Onde:

$$sw_{ij} = \begin{cases} 1, & \text{se } (NDVI_{ij} > NIR_{ij}) \text{ ou } (\min(nSI_{ij}, sSI_{ij}) - NIR_{ij}) > 0 \\ 0, & \text{caso contrário} \end{cases}$$

4.2.3.3 Detecção de Marcadores de Rodovias

O método de detecção de marcadores de rodovias e vias públicas explora os índices com respostas mais elevadas, e mais estáveis, para esses elementos (nRI , mWI e WWI). Apesar do índice $RWSI$ também possuir uma resposta elevada e estável para rodovias, ele foi excluído por ser altamente correlacionado com o índice nRI (Equação 4.11). Se for desconsiderada a região de sombras (pela alta instabilidade), o índice WWI possui o seu segundo pico (e estável) sobre rodovias (Figura 4.24 – linha vermelha). Esses três índices também têm uma boa resposta sobre corpos d'água e regiões sombreadas, mas produzem valores negativos para a maioria dos outros elementos. Assim, uma composição das respostas desses três índices (Equação 4.17) promove o realce desses elementos (Figura 4.26b). Se existirem corpos d'água na imagem, eles serão os mais realçados por esta composição. O próximo elemento que tem maior realce são as sombras 'especiais' e, em seguida, rodovias, sombras normais e alguns outros (poucos) artefatos.

$$rd_{ij} = nRI_{ij} + mWI_{ij} + WWI_{ij} \quad (4.17)$$

Em função do realce positivo para rodovias estabelecido pela Equação 4.17, os candidatos passíveis de serem detectados como marcadores de rodovias e vias públicas ocupam a parte positiva de rd . Então, seja

$$B_{ij} = \begin{cases} 1, & \text{se } rd_{ij} > 0 \\ 0, & \text{caso contrário} \end{cases}$$

$$X = \mathbf{A}_p(B, rd)$$

onde, X é o vetor composto por todos os pontos com valores positivos sobre rd . Sejam também as seguintes medidas extraídas de valores rd restritos ao vetor X : μ_x (valor médio),

σ_X (desvio padrão), $mx = \max(X)$ (valor máximo) e $mn = \min(X)$ (valor mínimo).

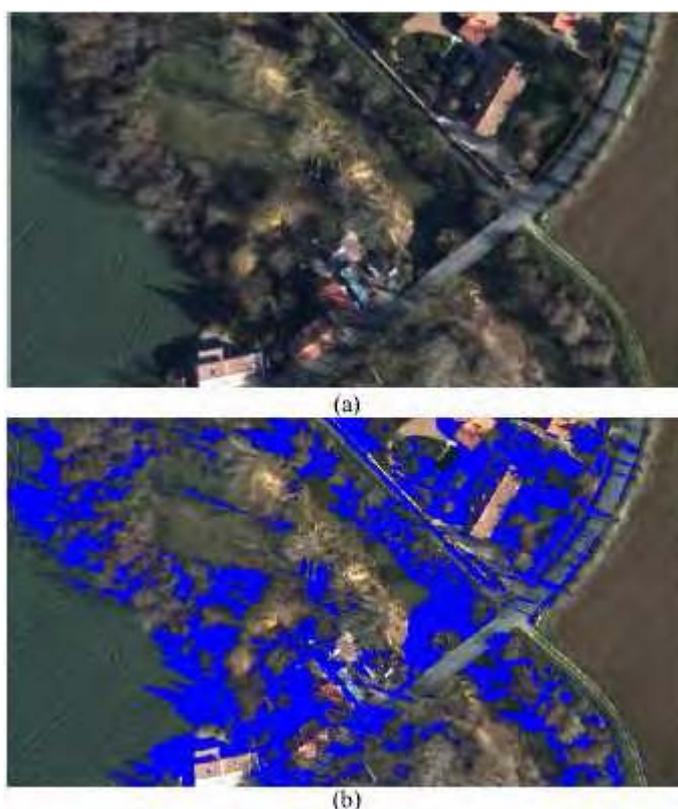


Figura 4.25 Resultado final da segmentação de sombras. (a) Imagem Original. (b) imagem temática.

As Equações 4.18 e 4.19 definem o método geral para detectar os marcadores de rodovias usando operadores entre conjuntos.

$$\begin{aligned}
 rod_{ij}^1 &= \begin{cases} 1, & \text{se } rd_{ij} < (mx - \sigma_X) \\ 0, & \text{caso contrário} \end{cases} \\
 rod_{ij}^2 &= \begin{cases} 1, & \text{se } rd_{ij} > (mn + \sigma_X) \\ 0, & \text{caso contrário} \end{cases} \\
 rod &= rod^1 \cap rod^2 - shd
 \end{aligned} \tag{4.18}$$

A primeira expressão da Equação 4.18, rod_{ij}^1 , considera que, se houverem sombras “especiais” ou corpos d’água na imagem, eles aumentam a média e a variabilidade dos valores mapeados por X . Assim, o valor de limiar para detectar os marcadores de rodovias deve estar abaixo do valor máximo (mx) observado em rd . Se a variabilidade for grande o suficiente (indicando que existe muita área de sombras ‘especiais’ ou corpos d’água) então, o valor de limiar máximo ($mx - \sigma_X$) deve ser suficiente para eliminar esses elementos indesejados.

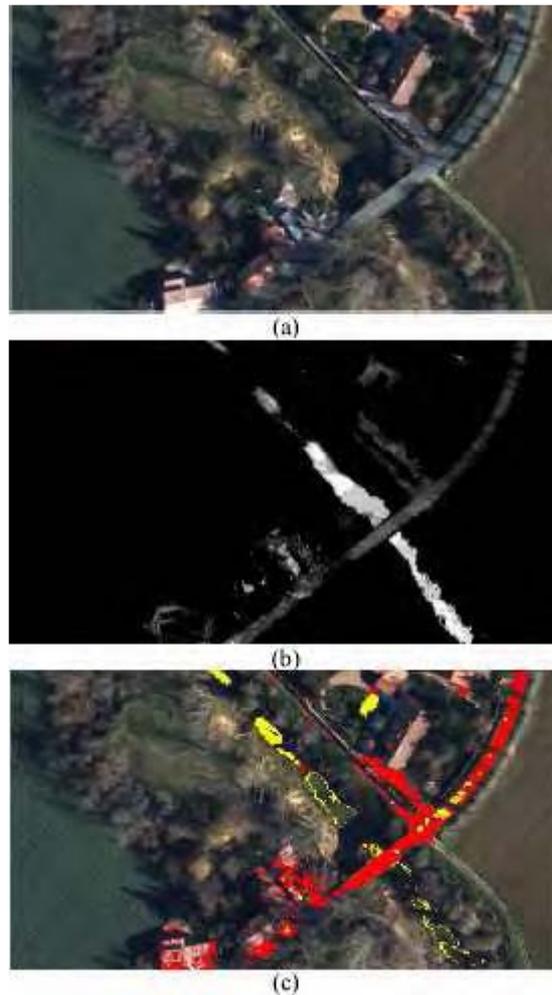


Figura 4.26 Resultados da detecção de marcadores de rodovia. (a) Imagem original (IGN). (b) Resultado do realce pela composição dos índices (rd). (c) Marcadores de rodovias detectados (regiões em amarelo e vermelho). As regiões em amarelo correspondem à confusão entre corpos d'água e rodovias.

A segunda expressão da Equação 4.18, rod_{ij}^2 , considera a possibilidade de existir, no conjunto X , fragmentos (artefatos) de outros elementos com resposta rd muito baixa. Esses artefatos são eliminados pelo valor de limiar mínimo $(mn + \sigma_X)$.

A terceira expressão da Equação 4.18 considera a presença de sombras 'normais', ou aquelas sombras que não puderam ser eliminadas pelo primeiro membro desta expressão. Então, todos os elementos detectados como sombras – shd – (Equação 4.16) devem ser eliminados do resultado.

Devido à variabilidade de tipos de sombras e corpos d'água (ou ausência de corpos d'água), pode ocorrer uma situação em que as medidas extraídas dos valores rd restritos ao vetor X estejam muito próximas uma das outras. Essa situação é verificada quando $\mu \cong \sigma$. Quando isto ocorre, deve ser aplicada a Equação 4.19.

$$\begin{aligned}
 rod_{ij}^1 &= \begin{cases} 1, & \text{se } rd_{ij} > (mn) \\ 0, & \text{caso contrário} \end{cases} \\
 rod_{ij}^2 &= \begin{cases} 1, & \text{se } rd_{ij} < (2\mu_X) \\ 0, & \text{caso contrário} \end{cases} \\
 rod &= rod^1 \cap rod^2 - shd
 \end{aligned} \tag{4.19}$$

A condição para usar exclusivamente a Equação 4.19 é dada pela relação $0.8 < \frac{\mu}{\sigma} < 1.2$, se for falsa deve ser usada a Equação 4.18.

O resultado obtido com a aplicação do método proposto pode ser filtrado para remover a maior parte das marcações erradas, entretanto, os algoritmos extratores de rodovias são complexos, e aquelas marcas verdadeiras que, eventualmente, são removidas pelo processo de filtragem podem fazer diferença no sucesso da extração completa de uma rodovia. Então, preferiu-se, neste trabalho, o resultado que apresentou a maior área de marcações positivas, mesmo cometendo uma taxa de erro de inclusão maior (Figura 4.26c).

4.2.3.4 Detecção e Discriminação de Vegetação

Em geral a discriminação da vegetação é feita através de um corte no índice *NDVI* por um valor de limiar simples. Entretanto foi mostrado, na Figura 4.24 (linha verde), que existem alguns tipos de sombras que produzem valores *NDVI* altos, e não há como separar essas sombras somente aplicando valores de limiares sem que haja comprometimento na quantidade de vegetação segmentada.

A imagem temática da Figura 4.27b mostra esse problema. Sobre o *NDVI*, correspondente a essa imagem, foi feito um corte por um valor de limiar correspondente a 80% do valor máximo produzido por esse *NDVI*. Esse valor de limiar é tão elevado que, como se pode observar (em vermelho e azul), não conseguiu segmentar completamente vegetação verde e vistosa e, mesmo usando esse valor de limiar elevado, não foi possível eliminar algumas regiões sombreadas (em azul).

Uma outra questão discutível é como se determina esse valor de limiar uma vez que os valores *NDVI* são dependentes da sensibilidade radiométrica do sensor, da resolução espacial em que a imagem foi adquirida e da distância entre o sensor e a cena imageada.

Propõe-se aqui um método para detecção de uma vasta gama de tipos e condições de folhagens de vegetação verde sem a necessidade de especificação de um valor

de limiar (Equação 4.20). Esse método apresenta qualidade similar ao corte de 40% do valor máximo do $NDVI$, mas sem incluir sombras.

$$V_{ij} = \begin{cases} 1, & \text{se } \left(NDVI_{ij} + WWI_{ij} + \frac{1}{2} NIR_{ij} \right) > 0 \\ 0, & \text{caso contrário} \end{cases} \quad (4.20)$$

$$vgt = V - (shd \cup wtr)$$

Deve ser observado, nas linhas do gráfico da Figura 4.25, que o $NDVI$ (linha verde) e o WWI (linha vermelha) sobre os elementos específicos produzem, respectivamente, valores máximos e mínimos sobre vegetação verde, bem como e valores mínimos e máximos sobre corpos d'água, ou seja, sobre esses elementos o $NDVI$ e o WWI tem correlação inversa. Basicamente, esses dois índices se anulam sobre esses dois elementos.

Para os outros elementos, exceto sombras, esses dois índices produzem valores negativos e, nas regiões sombreadas, eles têm picos opostos, ou seja, se anulam sobre uma boa parcela das sombras.

Como os valores de brilho da NIR contribuem muito pouco para as regiões de sombra e água, e contribui muito para a vegetação, a soma de $\frac{1}{2} NIR$ ao resultado $NDVI + WWI$ realça, positivamente, somente aqueles pixels que correspondem à área coberta por vegetação verde. Em todo caso, alguns valores de sombra e vegetação podem escapar dessa linha de padrões então, para evitar esse caso, optou-se por descontar do resultado as parcelas correspondentes a sombras (shd – Equação 4.15) e água (wtr – Equação 4.16).

A imagem temática apresentada na Figura 4.27c mostra o resultado da segmentação da vegetação.

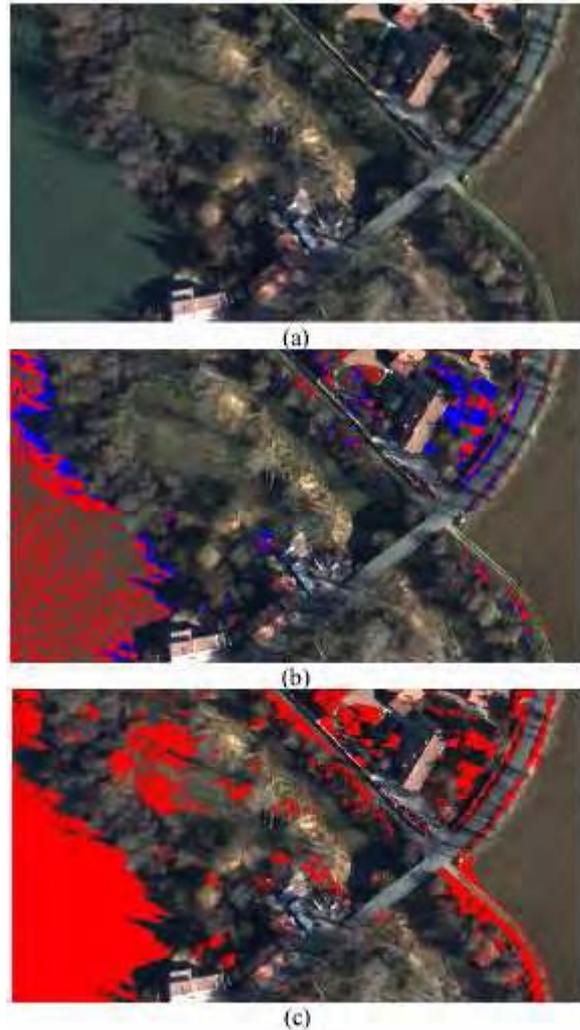


Figura 4.27 Resultado da discriminação de vegetação. (a) Imagem original (IGN). (b) Resultado do corte de 80% do valor máximo sobre o NDVI (união das áreas em vermelho e azul). Áreas em azul é o resultado da intersecção entre o resultado deste corte sobre o *NDVI* com o resultado de discriminação de sombras da Figura 4.26b. (c) Resultado da discriminação da vegetação pelo método proposto.

4.2.4 Outros Resultados

A seguir são apresentados outros resultados obtidos com os métodos propostos. As cores usadas nas imagens temáticas têm o seguinte significado:

- azul – regiões sombreadas;
- verde – rodovias;
- vermelho – vegetação e;
- amarelo – corpos d’água.

4.2.4.1 Imagens IGN

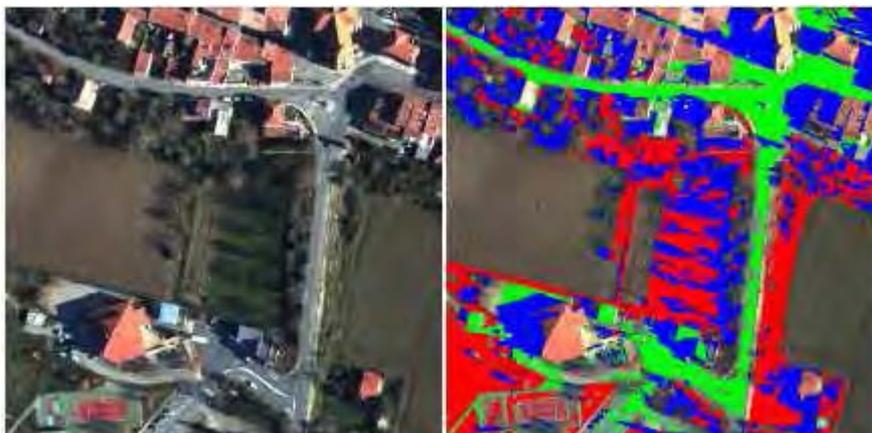


Figura 4.28 Imagem IGN original e imagem temática correspondente. Verde - vias públicas asfaltadas. Azul – sombras. Vermelho – vegetação. Amarelo – corpos d’água.

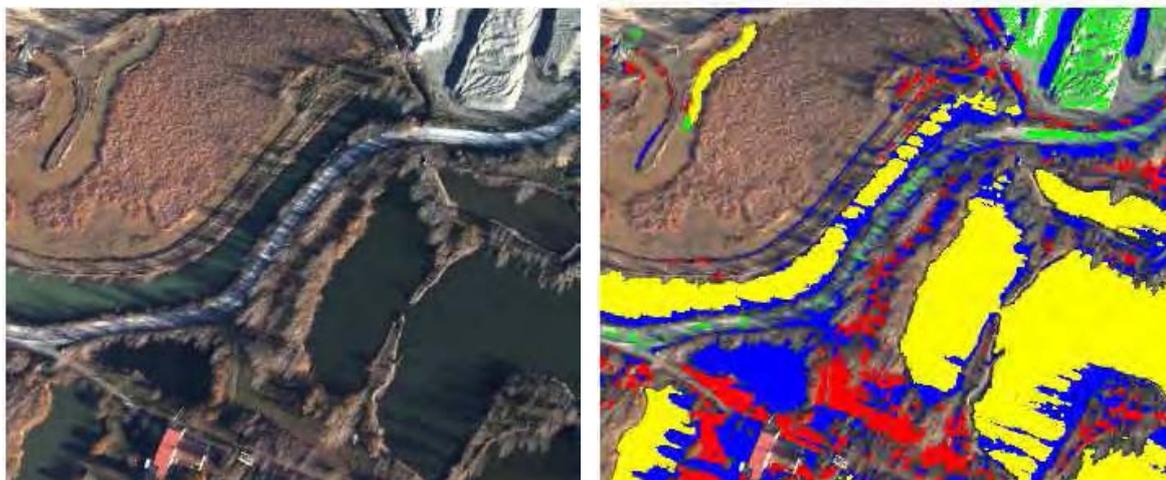


Figura 4.29 Imagem IGN original e imagem temática correspondente. Verde - vias públicas asfaltadas. Azul – sombras. Vermelho – vegetação. Amarelo – corpos d’água.



Figura 4.30 Imagem IGN original e imagem temática correspondente. Verde - vias públicas asfaltadas. Azul – sombras. Vermelho – vegetação. Amarelo – corpos d’água.

4.2.4.2 *Imagens HRSC-AX*

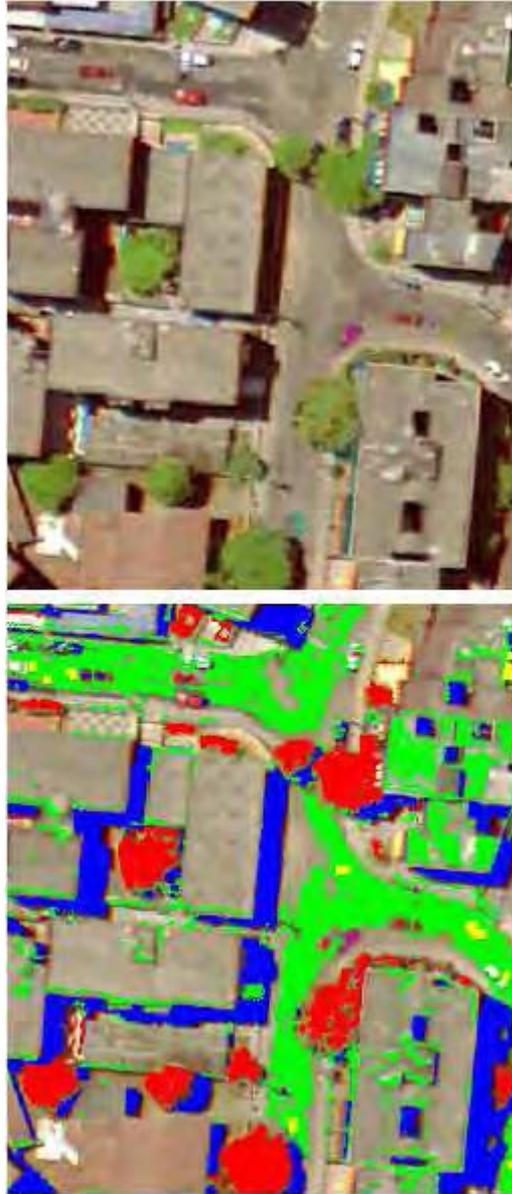


Figura 4.31 Imagem HRSC-AX original e imagem temática correspondente. Verde - vias públicas asfaltadas. Azul – sombras. Vermelho – vegetação. Amarelo – corpos d’água.



Figura 4.32 Imagem HRSC-AX original e imagem temática correspondente Verde - vias públicas asfaltadas. Azul – sombras. Vermelho – vegetação. Amarelo – corpos d’água.

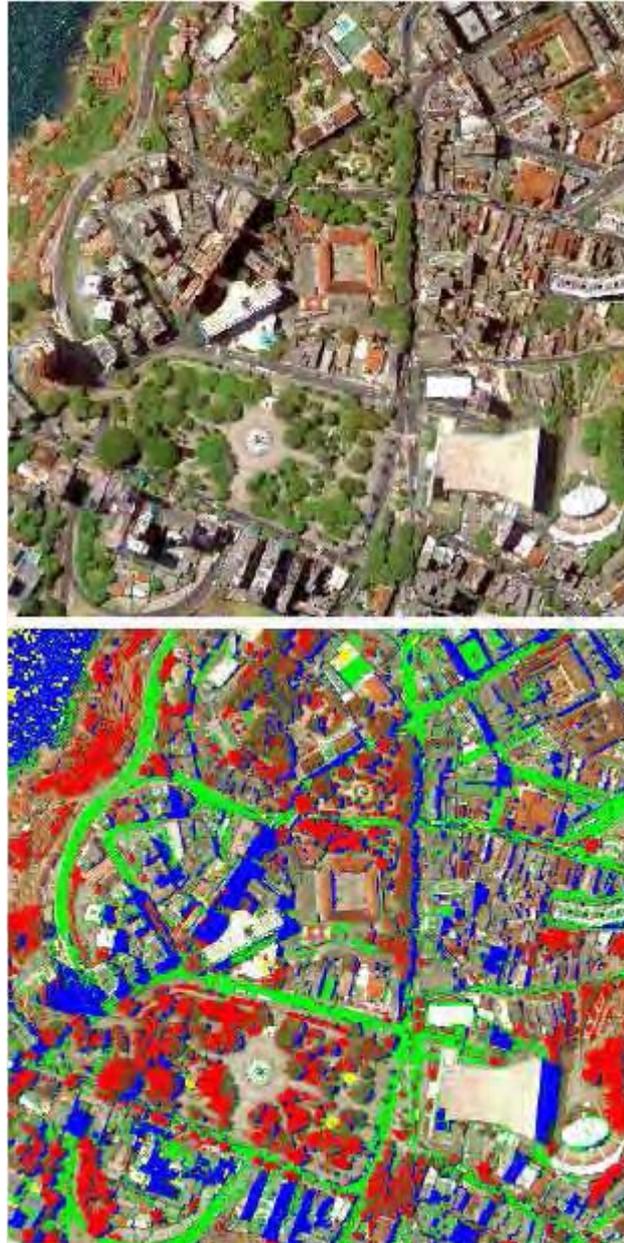


Figura 4.33 Imagem HRSC-AX original e imagem temática correspondente. Verde - vias públicas e rodovias asfaltadas. Azul – sombras. Vermelho – vegetação. Amarelo – corpos d’água.

4.2.5 Análise dos Resultados

Os resultados obtidos com a discriminação de sombras foram equivalentes nas imagens adquiridas pelas câmaras HRSC-AX e IGN, exceto para aquelas regiões das imagens adquiridas pela câmara HRSC-AX com problemas de registro e de marcas fantasmas deixadas por alvos que se movem (Seção 3.2). Os problemas de registro podem ser observados, principalmente, em torno das bordas das edificações mais altas (Figura 4.34), e as marcas fantasmas causadas por alvos que se movem (Figura 4.35).

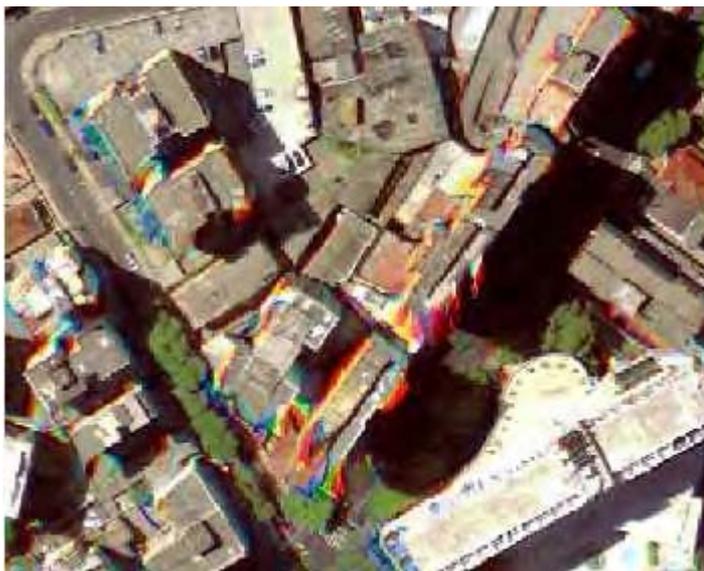


Figura 4.34 Problemas de registros entre as imagens R, G e B adquiridas pela câmara HRSC-AX.



Figura 4.35 Problemas de registros de alvos que se movem (superfície do corpo d'água) entre as imagens R, G e B adquiridas pela câmara HRSC-AX.

A discriminação de corpos d'água, pelo método proposto, é melhor em imagens IGN, pois o problema de registro entre as imagens HRSC-AX, causado pela movimentação da superfície do corpo d'água, em muitos casos, prejudica sensivelmente esse processo (Figura 4.35). Nas imagens HRSC-AX muitos pontos relativos a corpos d'água são confundidos com sombras, vegetação e rodovias.

A discriminação da vegetação, pelo método proposto, também é melhor em imagens IGN, devido ao problema causado pela geometria de imageamento usada pela câmara HRSC-AX (Seção 3.2). Como os sensores relativos às faixas do vermelho e do infravermelho do espectro eletromagnético da AX têm ângulos de visadas diferentes (diferença de 20°), os valores de radiância capturados para vegetação verde nas imagens *R* e *NIR* não estão em acordo com os padrões esperados, por serem adquiridas em referenciais radiométricos diferentes. Para os casos estudados, essas imagens apresentaram valor de brilho maior que o esperado para vegetação verde. Neste caso, os valores *NDVI* (e outros índices) também respondem em desacordo com os padrões, resultando na segmentação de uma parcela menor de vegetação pelo método proposto.

Entretanto, o método proposto consegue minimizar o problema de

segmentar vegetação nas bordas das edificações mais altas (causada pelo problema de registro – Seção 3.2 – Figura 3.3d). Para cumprir o próximo objetivo deste trabalho, detecção de telhados de edificações, a minimização desse erro é importante. Contudo, devido ao fato de que uma parcela da vegetação (árvores) pode ter valores de elevação considerável e, para detectar telhados de edificações, é necessário que essas áreas cobertas por vegetação sejam completamente eliminadas do MDS correspondente, uma outra estratégia será adotada para este fim. Assim, apesar do uso da Equação 4.20 minimizar o erro de inclusão, ela não consegue segmentar vegetação suficiente para contornar os próximos problemas. Dessa forma, para imagens adquiridas pela HRSC-AX, a Equação 4.20 será alterada para: $vgt = (NDVI > 0) - shd$, para garantir a completa segmentação de vegetação verde, mesmo com a implicação de se perder aqueles telhados com problemas de registro e que são facilmente confundidos com vegetação pelo corte realizado sobre os valores do índice *NDVI*.

Quanto aos marcadores de rodovias, foi mostrado que o método consegue, na maioria dos casos estudados, conquistar grandes extensões de pontos conectados sobre esse elemento (especialmente se unidos os resultados de discriminação de corpos d'água e rodovias).

Entretanto, foi mostrado também, que muitas marcas sobre telhados foram segmentadas como rodovias, principalmente no caso das imagens adquiridas pela AX, devido aos padrões de cor de muitos telhados serem parecidos com os da rodovia (Figura 4.36a).

O conjunto original desses marcadores de rodovias, mesmo com esses erros de inclusão, pode ser uma alternativa mais interessante para os algoritmos perseguidores de rodovias do que filtrar esse resultado para eliminar marcadores errados, uma vez que eliminar marcadores errados por um processo de filtragem implica, também, em se perder uma parcela considerável de marcadores corretos. Entretanto, considerando o próximo objetivo deste trabalho, detectar telhados de edificações, esses marcadores errados dificultam a conquista desse objetivo.

Para eliminar essas marcações erradas é necessário fazer as seguintes considerações: (a) a área da malha viária (rodovias e ruas) é muito maior que a área de qualquer edificação; (b) Os padrões das marcações erradas apresentam-se como pontos isolados, linhas finas e algumas regiões mais densas, mas com áreas restritas; (c) a maioria dos pontos das marcações corretas são 8-conectados e; (d) as marcações erradas dificilmente estão conectadas com as marcações corretas, devido aos efeitos de bordas dos telhados e das rodovias, além da presença de outros elementos entre eles (principalmente sombras e

vegetação). Todas essas considerações podem ser observadas na Figura 4.36a.

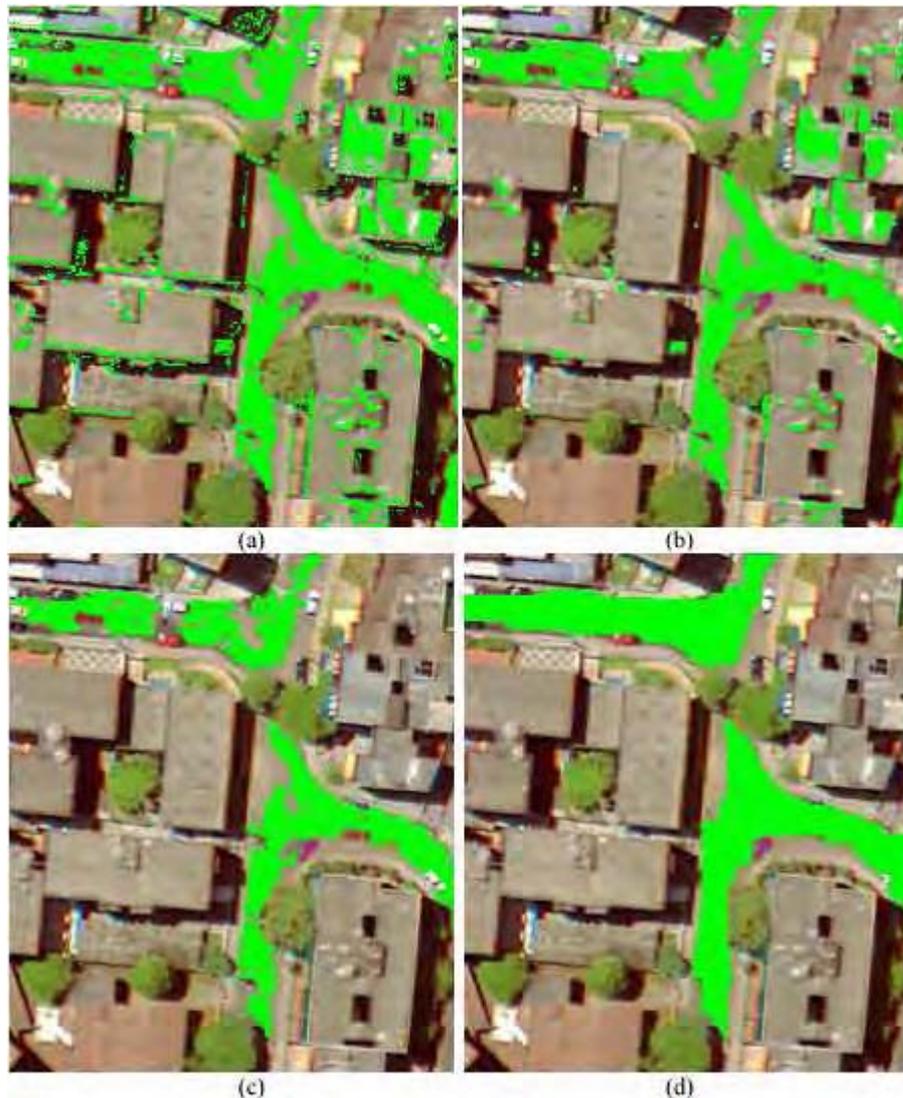


Figura 4.36 Eliminação de marcações erradas sobre rodovias. (a) Marcadores segmentados pelo método proposto sem a exclusão de áreas sombreadas. (b) Resultados da aplicação do operador morfológico de abertura. (c) Eliminação de áreas conectadas equivalentes a 2000 pixels (ou 80m^2 para GSD de 20cm) com aplicação do filtro morfológico *AreaOpen*. (d) Resultado promovido pelo fechamento seguido de restrição de área.

Para dificultar o processo de eliminação das marcações erradas, proposadamente, não foram excluídos os pontos sobre regiões sombreadas, erroneamente discriminadas como rodovias, apesar do método proposto neste trabalho fazer essa exclusão (Equações 4.17 e 4.18).

O primeiro passo para eliminar essa marcação errada consiste em erodir todo o conjunto de marcadores de rodovias, aplicando o operador morfológico de erosão \mathcal{E}_B , por um elemento estruturante B quadrado de dimensões 3×3 . O principal objetivo dessa

operação é promover desconexões de regiões que estejam conectadas por linhas mais finas que as dimensões do elemento estruturante. Como as marcações corretas são mais compactas, espera-se que essa operação cause maiores desconexões sobre os marcadores errados.

Se duas ou mais regiões, com áreas relativamente grandes, estiverem conectadas por uma linha fina e, se essas regiões, estiverem muito próximas entre si, então é preferível que elas sejam novamente conectadas. Essa operação é feita pelo operador morfológico dilatação δ_B , também usando o elemento estruturante B quadrado de dimensões 3×3 . Essa combinação seqüencial erosão-dilatação é o operador morfológico de abertura γ_B .

O resultado obtido pela aplicação da operação de abertura morfológica proposta está apresentado na Figura 4.36b. Deve ser observado que os maiores danos foram causados sobre os marcadores incorretos e que os marcadores corretos preservaram uma grande conectividade.

Para eliminar o restante dos marcadores incorretos foi aplicado o filtro morfológico de abertura por área Γ_a^{area} (*AreaOpening*), com limiar de área equivalente a dois mil pixels ($a = 2000$), aplicados em imagens com GSD de 20cm (equivalente a $80m^2$).

As operações usadas para eliminar marcadores errados de rodovias são resumidas pelas Equações 4.21 e 4.22. O resultado alcançado por essa estratégia está apresentado na imagem da Figura 4.36c.

$$rod^\gamma = \Gamma_{a=2000}^{area} (\gamma_B (rod)) \quad (4.21)$$

Nos resultados gerados pela aplicação da Equação 4.21 podem estar inclusos telhados de grandes edificações que foram completamente marcados como rodovias. Esses resultados errados, ainda persistentes, devem ser eliminados do processo, mesmo ao custo de eliminar a maior parte dos marcadores corretos de rodovias.

Os resultados corretos obtidos com a aplicação da Equação 4.21 podem estar fragmentados em diversas regiões próximas e cada região pode conter buracos em seu interior. Então, fechar esses buracos aumenta consideravelmente o número de pixels de interesse associados a cada região e, conectar diferentes regiões próximas aumenta consideravelmente a área formada por essa união. Essas duas operações (fechar-conectar) são feitas pelo operador morfológico de fechamento ϕ_B usando um elemento estruturante B quadrado de dimensões 15×15 .

$$rod^\phi = \Gamma_{a=30000}^{area} (\phi_B (rod^\gamma)) \quad (4.22)$$

Após o fechamento, é feito um corte nas regiões por restrição de área

equivalente a 30000 (trinta mil pixels), em imagens com GSD de 20cm (equivalente a 1200m²). Dessa forma somente grandes regiões conectadas permanecerão ativas (Equação 4.22). A imagem da Figura 4.36d ilustra os padrões do resultado final.

Uma alternativa para eliminar (ou reduzir) as marcações de rodovias que aparecem sobre uma parcela dos telhados consiste em considerar que a maior parte da malha viária está ao nível da superfície do terreno. Se estiver disponível um MDS correspondente a essa região então, elementos que estão ao nível da superfície do terreno podem ser detectados, através da normalização desse MDS (Seção 4.3), permitindo remover aquelas marcações que aparecem sobre elevações (telhados). Entretanto, marcadores sobre trechos de rodovias elevadas (como pontes e viadutos) podem ser perdidos com a adoção dessa estratégia. Apesar desse inconveniente, este trabalho adota essa alternativa para tratar as marcações erradas sobre rodovias.

4.3 NORMALIZAÇÃO DO MDS E DETECÇÃO DE TELHADOS

Telhado de edificação está entre os elementos mais difíceis de serem detectados, pois não existe um padrão em dados de imageamento que identifique esse elemento.

Dados de elevação derivados de imagens estereoscópicas constituem uma fonte de informação relevante para tratar esse elemento.

Este trabalho dispõe dos seguintes conjuntos de dados para detectar telhados de edificações: imagens multiespectrais adquiridas pela câmara HRSC-AX (*R*, *G*, *B*, *NIR* e *PAN*), ortorretificadas com GSD de 20cm e o MDS correspondente com GSD de 50cm. Os processos de ortorretificação das imagens e extração do MDS correspondente foram feitos pela empresa DIGIMAPAS. As imagens multiespectrais e o respectivo MDS cobrem uma área de 9km² da região urbana da cidade de Salvador.

Como as imagens multiespectrais e o MDS têm resolução espacial diferentes, GSD de 20 e 50cm, respectivamente, para se fazer o registro e sobreposições entre esses dois conjuntos de dados é necessário que ambos estejam representados com a mesma taxa de amostragem.

Além de todos os problemas relacionados com as marcas fantasmas e com o registro entre as imagens multiespectrais adquiridas pela câmara HRSC-AX, muitos pontos do MDS também estão sujeitos a erros e os processos necessários para mudar a resolução de 50cm para 20cm, caso do MDS em questão, envolve cálculos de interpolações e extrapolações, os quais podem propagar e agravar esses erros. Para reduzir a resolução de

20cm para 50cm das imagens multiespectrais, somente processos de interpolações são necessários. Dessa forma, preferiu-se, neste trabalho, a opção de modificar a resolução espacial das imagens multiespectrais ortorretificadas de 20cm para 50cm. Ou seja, como cada imagem original tem 15.000 pixels, onde cada pixel corresponde a 20cm sobre o terreno, com essa mudança de resolução para 50cm, cada imagem passa a ter 6.000 pixels, e cada pixel passa a corresponder a 50cm sobre o terreno.

Esse procedimento foi feito usando as ferramentas do software ENVI e o método de interpolação escolhido foi o do vizinho-mais-próximo.

A base do método proposto para detectar telhados de edificações consiste em usar a técnica de segmentação morfológica *watershed* com marcadores internos e externos ao alvo desejado.

4.3.1 Os Marcadores

Os marcadores são agrupados em dois conjuntos: marcadores internos, os quais marcam telhados de edificações e; marcadores externos, os quais marcam outros elementos presentes na imagem.

Os marcadores externos são constituídos de pontos de elementos que, comumente, não estão associados com telhados de edificações: vegetação, corpos d'água e pontos sobre rodovias. Os procedimentos para detectar esses elementos, bem como as regiões sombreadas, foram apresentados na Seção 4.2. Pontos provenientes de outros dois elementos integram o conjunto de marcadores externos: pontos que estão ao nível da superfície do terreno, os quais são extraídos do MDS normalizado (Seção 4.3.3) e, pontos de sombras (Seção 4.2.3.2).

Os marcadores internos são oriundos somente dos dados de elevação, extraídos de elementos elevados que não sejam correspondentes à vegetação ou regiões sombreadas. O processo de extração dos marcadores internos é discutido na Seção 4.3.3.

4.3.2 O Uso de Pontos de Sombras como Marcadores Externos

A dualidade, ou ambigüidade, das sombras nos processos Fotogramétricos e de Sensoriamento Remoto também se manifesta neste trabalho. As sombras às vezes auxiliam, às vezes dificultam a execução de determinados processos. Este trabalho chegou nesse ponto divergente (ou paradoxal). Usar ou não usar pontos de sombras como um dos marcadores?

De todas as entidades detectadas anteriormente, sombra é aquela que tem a

maior chance de estar sobre o telhado de uma edificação, seja pela projeção de outros elementos mais elevados ou por sombras próprias, como mostra a Figura 4.37a.

Além de provocar alterações na resposta espectral dos alvos, a extração de dados de elevação em regiões sombreadas constitui uma evidente fonte de erros na extração e um MDS devido à alta correlação existente entre os pixels que compõem essas regiões. Foi mostrado na Seção 3.2 como esses erros se manifestam na extração do MDS ao juntar duas elevações separadas por uma distância considerável sobre uma única cobertura de elevação (Figuras 4.37b e 4.37c). As duas edificações da Figura 4.37b estão separadas por mais de 10m.

O paradoxo que se apresenta pode ser entendido da seguinte maneira: se escolher pontos de sombras como integrantes dos marcadores externos, as partes sombreadas da edificação da Figura 4.37a estarão perdidas. Se não se fizer essa escolha, a área de vão livre entre as duas edificações da Figura 4.37b será erroneamente detectada como edificação.

Este trabalho adota como critério a preferência por deixar de detectar corretamente um determinado elemento em função do erro de inclusão passível de ser cometido nessa detecção. Assim as sombras serão incluídas como integrante do conjunto de marcadores externos.

A despeito do problema causado pelas sombras, analisou-se a seguinte situação. As imagens estéreo-fotométricas adquiridas pela câmara HRSC-AX que foram usadas para gerar o MDS correspondente têm GSD de 20cm. O MDS gerado tem GSD de 50cm, ou seja, o MDS foi gerado com resolução espacial de 2,5 pixels (50/20). Se, para distinguir um detalhe de uma feição numa imagem, esse detalhe precisa ter, no mínimo, as dimensões $(2\sqrt{2})$ GSD (aproximação empírica da fotogrametria para o Limite de Nyquist) e, como foram usados 2,5 pixels da imagem para obter um único ponto do MDS então, duas elevações separadas por uma distância de $3,5\text{m}, (2\sqrt{2}) \times 0,5 \times 2,5$, têm a possibilidade de aparecerem conectadas pela cobertura da mesma região do MDS independente de haver sombras entre elas (Figura 4.38). Isto, sem considerar os erros associados, ou intrínsecos, ao processo de geração de um MDS, que podem aumentar esse valor.

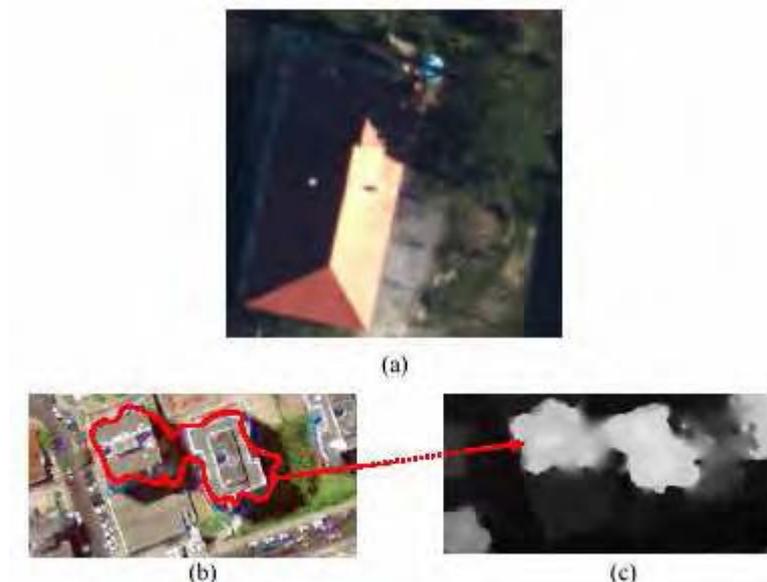


Figura 4.37 (a) Exemplo de sombra própria e sombra projetada sobre telhado. (b) Problema de extração do MDS sobre regiões sombreadas.

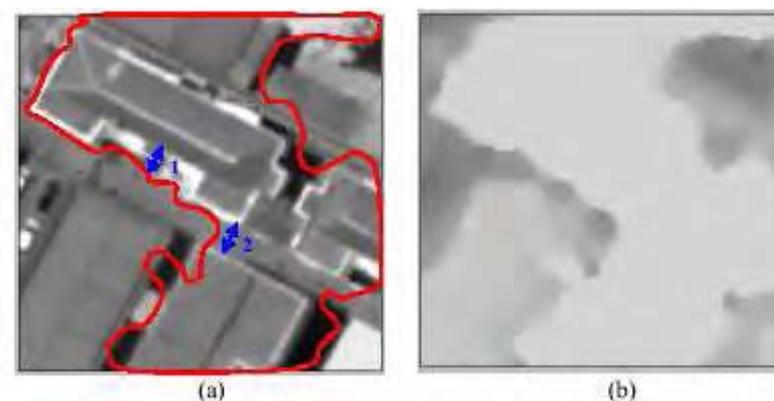


Figura 4.38 Problemas com a precisão do MDS. (a) Ilustração da extensão do MDS cobrindo duas elevações separadas por uma distância de 7m. (b) MDS correspondente.

Um exemplo desse fato é apresentado pela Figura 4.38. A distância entre a borda da edificação até a cobertura do MDS sobre a marca rotulada '1' é de 3.5m, pelo menos, e sobre o rótulo '2', indicando a separação entre as duas edificações, é de 7m (foi cometido um erro de 3.5m em cada borda das duas edificações separadas).

Mesmo havendo essa possibilidade de conexão entre duas edificações pelo MDS, se existir uma pequena sombra nas imagens espectrais separando todo o lado das edificações conectadas pelo MDS então, elas podem ser separadas pelo marcador externo originado pelas regiões de sombras.

Então, existe pelo menos dois motivos favoráveis ao uso das regiões sombreadas como marcadores externos.

4.3.3 Normalização do MDS

Os pontos do MDS têm uma entre duas naturezas possíveis. Ou um ponto está no nível da superfície do terreno, ou está no nível de um elemento elevado sobre essa superfície. A análise de um ponto isolado qualquer do MDS não permite estabelecer qualquer conclusão sobre a sua natureza, uma vez que o relevo da superfície do terreno também pode mudar a sua elevação.

A solução para esse problema é conhecer a superfície do terreno, em outras palavras, conhecer o MDT correspondente. Entretanto, em muitos casos, o MDT é parte integrante do MDS e, nesses casos, é necessário derivá-lo desse MDS. Para fazer essa derivação é necessário conhecer pontos nesse MDS que estão no nível da superfície do terreno.

Nessa situação, é necessário fazer uma análise de contexto do MDS para, através de estimativas, prever sobre os conjuntos de pontos que estão, ou não, no nível da superfície do terreno. O problema passa a ser: (a) definir estratégias de análise de contexto e; (b) definir métricas para estimar a natureza dos pontos.

Como condição simplificadora, este trabalho não está interessado em obter pontos que descrevam o MDT correspondente²³. O interesse está em detectar elementos que se elevam sobre a superfície do terreno. Assim, com essa simplificação, o novo problema passa a ser: detectar o máximo possível de pontos que não pertençam a essas elevações de interesse.

Essa simplificação permite relaxar a análise de contexto e as métricas para estimar a natureza dos pontos do MDS, pois o conhecimento local de quaisquer pontos intermediários, entre a superfície do terreno e as elevações reais, permite estabelecer os pontos desejados. O problema passa a ser: como determinar esses pontos intermediários?

4.3.3.1 *Análise de Comportamento dos Pontos do MDS*

O processo de extração do MDS através de imagens estéreo-par envolve processos de correlação entre regiões ou elementos existentes nessas imagens para determinação de pontos homólogos. Existem situações em que a determinação desses pontos não é perfeita (por exemplo, em regiões de baixa variabilidade como sombras e regiões de bordas de alta transição). Essas situações fazem com que o MDS obtido não seja exato e sim um modelo aproximado das elevações. Para muitas elevações esse modelo aproximado se

²³ Apesar do resultado final desta proposta permitir a obtenção desses pontos.

apresenta de uma forma suavizada, como mostra a ilustração da Figura 4.39.

O efeito da suavização do MDS pode ser observado nas vizinhanças das elevações (Figura 4.40b), sob a forma de degraus de níveis de cinza. Os pontos que estão sobre esses degraus constituem os pontos intermediários entre superfícies elevadas e a superfície do nível do terreno.

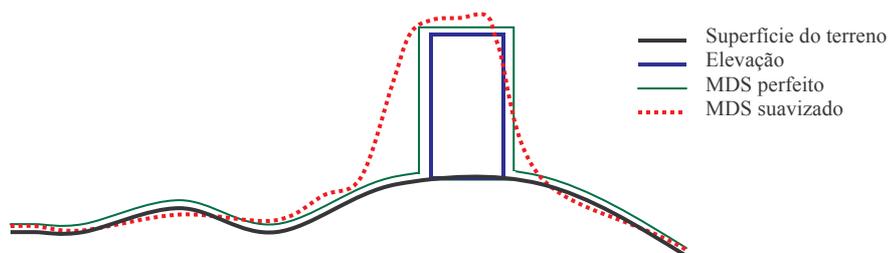


Figura 4.39 Ilustração da suavização do MDS em regiões próximas às elevações bruscas.

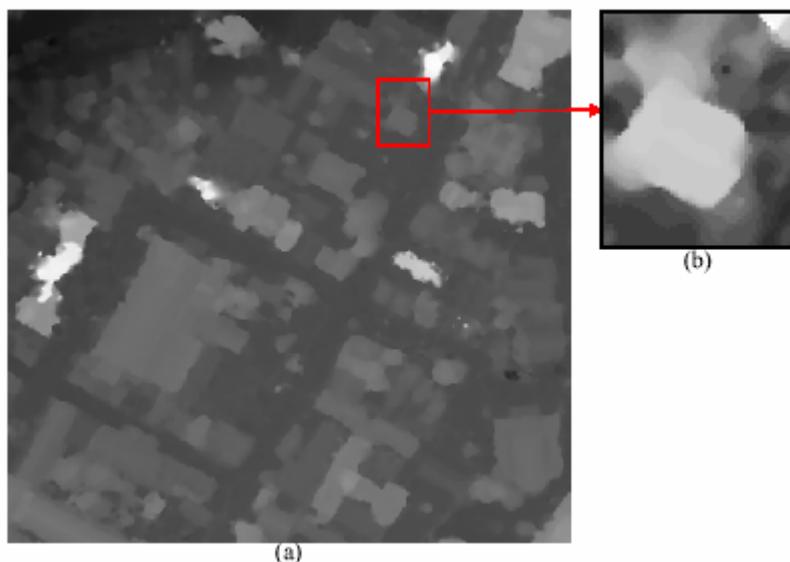


Figura 4.40 Padrão do efeito de suavização do MDS nas vizinhanças de elevações. (a) MDS original. (b) detalhe do MDS realçado para visualização do efeito da suavização.

4.3.3.2 Detecção das Regiões de Transição Sobre o MDS

Tanto o efeito de suavização como a mudança brusca de elevação na vizinhança de um elemento elevado caracteriza-se pela transição de valores de altura no MDS. Nessas regiões de transição estão os pontos intermediários procurados, os quais permitem prever a natureza dos outros pontos vizinhos.

Para detectar as regiões de transição sobre o MDS são necessários dois processos de filtragem usando os filtros da ordem de mínimo e de máximo e uma operação de

corde por valor de limiar sobre o resultado da subtração de duas superfícies (imagens, no caso).

O primeiro passo consiste em filtrar o MDS usando os filtros da ordem. Essa filtragem é feita pelo filtro de mínimo (7×7) e pelo filtro de máximo (9×9), nessa ordem. Isso é feito por dois motivos: (a) eliminar pontos do MDS que não estão em harmonia com os valores locais de elevação (*outliers*) e; (b) Estabelecer maiores zonas planas pelo agrupamento de pequenas regiões de transição vizinhas. O resultado dessa operação de filtragem seqüencial (MDS^F) está apresentado na Figura 4.41c.

O próximo passo é detectar as regiões de transição (R^T). Para esse propósito propõe-se, neste trabalho, o pseudogradiante (PG). O pseudogradiante é o resultado da limiarização da diferença entre o MDS original e o MDS filtrado, dado por $PG_{ij} = MDS_{ij} - MDS_{ij}^F$. A aplicação de um valor de limiar k sobre os valores de PG detecta as regiões de transição R^T (Equação 4.23).

$$R_{ij}^T = \begin{cases} 1, & \text{se } (MDS_{ij} - MDS_{ij}^F) < k \\ 0, & \text{caso contrário} \end{cases} \quad (4.23)$$

O valor do limiar k foi experimentalmente determinado. Os testes mostraram que valores de k pertencentes ao intervalo $\left[-3, -\frac{3}{2}\right]$ conseguem obter bons resultados (Figura 4.41d). O valor $k = -3$ foi usado em todas as aplicações da Equação 4.23 neste trabalho. Os diferentes resultados produzidos por diferentes valores de $k \in \left[-3, -\frac{3}{2}\right]$ não influenciam significativamente os resultados da próxima operação: detecção de pontos críticos.

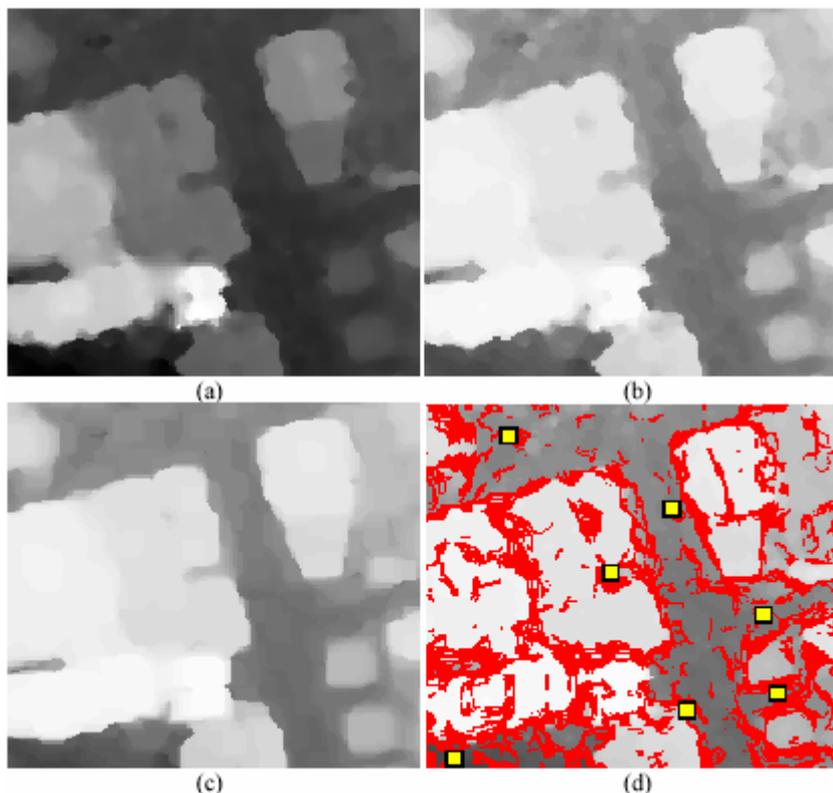


Figura 4.41 Detecção das regiões de transição. (a) MDS original. (b) MDS equalizado para melhor visualização das regiões de transição. (c) MDS filtrado pelos filtros da ordem de mínimo (7×7) e de máximo (9×9) – imagem realçada para efeito de visualização. (d) Regiões de transição (em vermelho) detectadas pelo uso do pseudogradiante. Pontos críticos detectados (em amarelo).

4.3.3.3 Detecção de Pontos Críticos Sobre o MDS

Os pontos amarelos apresentados, em tamanho exagerado para efeito de visualização, na imagem temática da Figura 4.41d são chamados de pontos críticos. Esses pontos têm importância fundamental no processo de normalização do MDS proposto neste trabalho (Seção 4.3.3.4). A maioria desses pontos é detectada numa vizinhança muito próxima de uma elevação (edificação ou árvore) e, por esse motivo, são chamados de pontos críticos.

Esses pontos críticos são detectados pelo seguinte processo: se R^T (Equação 4.23) é a matriz que indica pontos de transição de elevação e seus respectivos relacionamentos espaciais (coordenadas i, j) e, sabendo que os pontos críticos PC desejados estão diretamente associados com os pontos da região de transição que têm o valor 1 ($R_{ij}^T = 1$) então, seja

$$p_{ij} = \begin{cases} MDS_{ij}^F, & \text{se } R_{ij}^T = 1 \\ 0, & \text{caso contrário} \end{cases}$$

ou, em outras palavras, são todos os valores e seus respectivos relacionamentos espaciais extraídos do MDS filtrado restritos à matriz R^T .

Seja F_{\min}^L o filtro da ordem de mínimos que opera somente sobre os valores significativos de p (os valores significativos de p são designados pela restrição da matriz R^T , em outras palavras, se R_{ij}^T tem o valor associado 1 então o valor correspondente p_{ij} será envolvido e processado pelo filtro caso contrário, será ignorado). As dimensões do filtro F_{\min}^L são $L \times L$. O valor L é dado por.

$$L = 2 \left\lfloor \frac{1500}{GSD} \right\rfloor$$

onde: GSD é a resolução espacial do MDS em centímetros e $\lfloor x \rfloor$ é o operador que produz o maior valor inteiro menor ou igual ao valor de x . Neste trabalho o MDS tem GSD de 50cm, então L é igual a 60 e as dimensões do filtro F_{\min}^L são 60×60 , ou 3600 pixels.

Embora essa operação de filtragem possa parecer dependente das dimensões das edificações cobertas pelo MDS, deve ser considerado que ela atua somente sobre as regiões críticas detectadas sobre o MDS, as quais, geralmente, são vizinhas a essas edificações. Um exemplo dessas regiões críticas é mostrado (em vermelho) na imagem temática apresentada pela Figura 4.41d.

A detecção dos pontos críticos PC é feita pela Equação 4.24. Um exemplo de resultados obtidos está apresentado, em amarelo, na imagem da Figura 4.41d. PC é uma matriz com as mesmas dimensões do MDS original que, inicialmente só contém valores 0 (zero). Quando o filtro F_{\min}^L passar sobre uma região (de dimensões $L \times L$) de p e, se nessa região forem encontrados pontos significativos ($R_{ij}^T = 1$) então o filtro localizará um único elemento que está associado com um valor, igual ao valor mínimo extraído entre todos os pontos significativos cobertos pelo filtro, e atribuirá esse valor mínimo para a matriz PC na coordenada (l, c) correspondente em que esse valor foi encontrado na matriz p .

$$PC = F_{\min}^L(p) \quad (4.24)$$

4.3.3.4 Normalização do MDS

De posse de todos os valores associados com os pontos críticos e, conhecendo-se os relacionamentos espaciais entre eles, aplica-se o método de interpolação linear para gerar uma superfície em grade regular (com as mesmas dimensões e resolução espacial do MDS original). A superfície interpolada (Figura 4.42a) é uma estimativa de

tendência dos valores dos pontos críticos sobre o MDS. Essa superfície é chamada MDT crítico (MDT^{CRT}), por ser derivada dos pontos críticos.

Como os pontos críticos usados para gerar a superfície MDT^{CRT} estão associados com os valores do MDS^F (Figura 4.42b), a normalização do MDS, Equação 4.25, deve ser feita usando essas duas superfícies. Esse resultado é chamado MDS crítico normalizado, ou $nMDS^{CRT}$, o qual é mostrado, parcialmente, na Figura 4.42c.

$$nMDS^{CRT} = MDS^F - MDT^{CRT} \quad (4.25)$$

O MDS possui muitas instabilidades locais (observe os detalhes da Figura 4.41b) e, pode ocorrer da superfície gerada pela interpolação dos pontos críticos (MDT^{CRT}) não ser adequada para normalizá-la em regiões restritas. Entretanto, pode-se considerar que o $nMDS^{CRT}$ tem, no mínimo, uma superfície de terreno plana (Figura 4.42c). Para eliminar os possíveis resíduos, é necessário aplicar a Equação 4.26.

$$nMDS_{otm}^{CRT} = TH_{a_1}^{\Gamma}(nMDS_+^{CRT}) - 3TH_{a_2}^{\Phi}(nMDS_+^{CRT}) \quad (4.26)$$

onde:

$nMDS_{otm}^{CRT}$ é a otimização do $nMDS^{CRT}$;

$nMDS_+^{CRT}$ são os valores positivos relacionados com o $nMDS^{CRT}$. Todos os valores negativos de $nMDS^{CRT}$ são substituídos por zero;

$TH_{a_1}^{\Gamma}$ e $TH_{a_2}^{\Phi}$ são, respectivamente, os operadores residuais *TopHat* por abertura de área e fechamento de área,.

Já foi discutido na Seção 2.4 que os resultados produzidos pelas operações morfológicas tradicionais são dependentes das dimensões do elemento estruturante. As transformações *TopHat* por abertura e por fechamento não fogem a essa regra. Entretanto, a Equação 4.26 usa uma variação dos operadores abertura e fechamento que independe do elemento estruturante usado. Essa variação consiste na substituição dos filtros morfológicos de abertura γ_B e fechamento ϕ_B usados nas transformações *TopHat* pelos filtros conexos de abertura Γ_a^{area} e fechamento Φ_a^{area} por área.

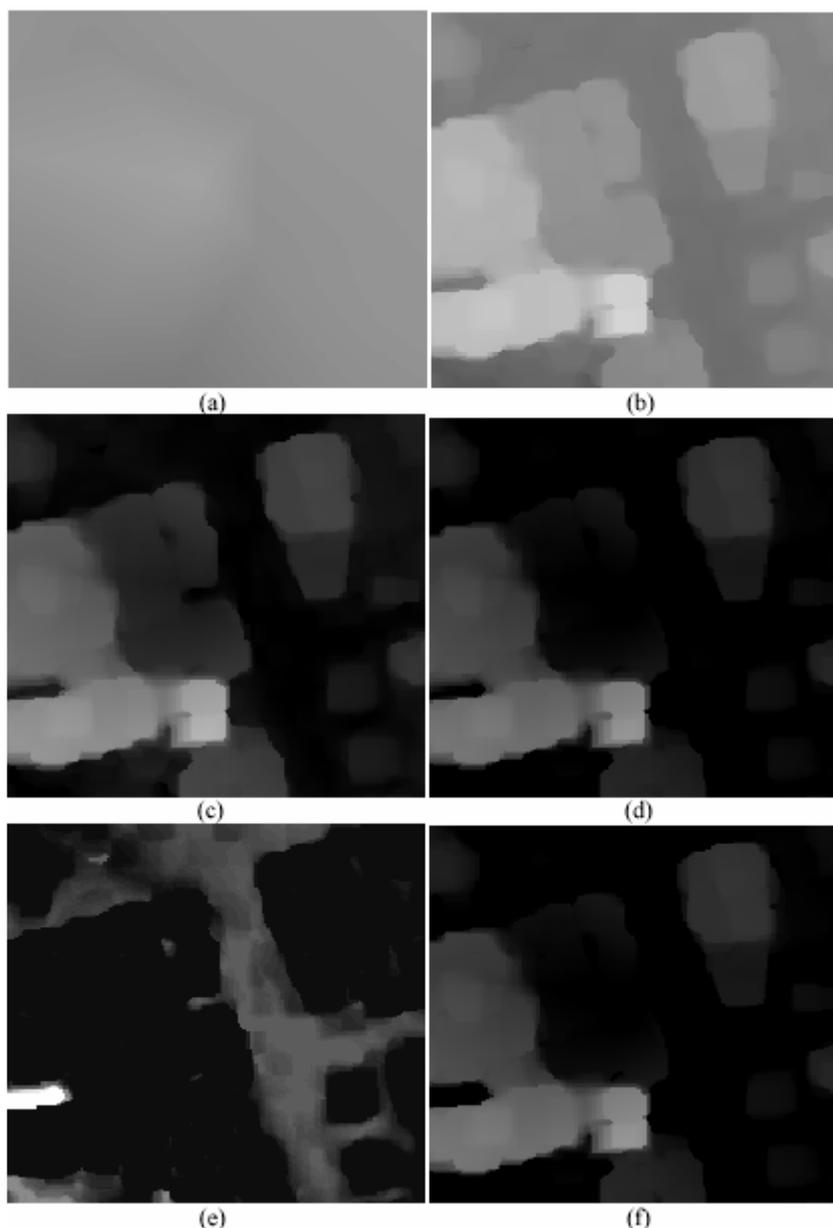


Figura 4.42 Normalização do MDS. (a) MDT gerado pela interpolação dos pontos críticos. (b) MDS filtrado pelos filtros da ordem de mínimo e de máximo. (c) Normalização do MDS filtrado. (d) *TopHat* por abertura de área. (e) *TopHat* por fechamento de área (imagem realçada para melhor visualização dos resíduos). (f) nMDS crítico otimizado.

Essa substituição define as transformações $TH_{a_1}^\Gamma$ e $TH_{a_2}^\Phi$, as quais são, respectivamente, *TopHat* por abertura de área e *TopHat* por fechamento de área, onde a_1 e a_2 são valores de limiar de área. Uma forma de otimizar o processamento computacional dos filtros Γ_a^{area} e Φ_a^{area} é fazer com que os valores do argumento desses filtros estejam definidos no intervalo $[0, 255]$, usando o alargamento linear do histograma de $nMDS_+^{CRT}$.

Os valores atribuídos aos limiares a_1 e a_2 , neste trabalho, são extremamente

altos: trinta mil pixels para a_1 e; trezentos mil pixels para a_2 . Os resíduos resultantes com a aplicação de $TH_{a_1}^\Gamma$ e com a aplicação de $TH_{a_2}^\Phi$ estão apresentados nas Figuras 4.42d e 4.42e, respectivamente.

A aplicação da Equação 4.26 produz o nMDS otimizado $nMDS_{otm}^{CRT}$. Os resultados obtidos com a aplicação desta equação estão apresentados na Figura 4.42f.

4.3.3.5 Determinação da Natureza da Elevação dos Pontos do MDS

Na Seção 4.3.3.4 foi definida uma estratégia de análise de contexto do MDS com o objetivo de realçar a natureza dos pontos que o compõe para permitir estimar com maior segurança se um ponto pertence a uma elevação ou se pertence à superfície do terreno. Nesta seção é estabelecida uma métrica para estimar a natureza desses pontos. Essa métrica é muito simples, pois, está apoiada nos resultados da normalização do MDS.

Essa métrica considera uma entre três possibilidades para cada ponto investigado: (a) o ponto pertence a uma elevação; (b) o ponto pertence à superfície do terreno e; (c) nada se pode afirmar sobre a natureza do ponto.

A terceira possibilidade, (c), é uma forma de relaxar a agressividade dos pontos críticos usados para normalizar o MDS, uma vez que eles são obtidos numa vizinhança muito próxima das edificações e, assim, devem ser tratados com certa desconfiança ou incerteza, quando são tratados pontos não-elevados. Contudo, devido a essa agressividade, há maior certeza ou confiança sobre pontos elevados.

Os pontos pertencentes a uma superfície elevada P_S^E são determinados por uma operação de limiarização sobre os valores $nMDS_{otm}^{CRT}$, feita pela Equação 4.27.

$$P_S^E = \begin{cases} 1, & \text{se } nMDS_{otm}^{CRT} > 0 \\ 0, & \text{caso contrário} \end{cases} \quad (4.27)$$

Os pontos sobre a superfície do terreno P_S^T , ou não pertencentes às elevações de interesse, precisam ser tratados com um pouco mais de cuidado devido ao maior grau de desconfiança.

Seja X o vetor que contém todos os valores negativos associados com $nMDS_{otm}^{CRT}$, ou, se $B_{ij} = \begin{cases} 1, & \text{se } nMDS_{otm}^{CRT} < 0 \\ 0, & \text{caso contrário} \end{cases}$, então $X = \mathbf{A}_p(B, nMDS_{otm}^{CRT})$. Seja μ_X o valor médio entre esses valores. Somente aqueles pontos pertencentes ao $nMDS_{otm}^{CRT}$ que têm valores inferiores a esse valor médio é que são considerados como pontos localizados sobre a

superfície do terreno, ou pontos P_S^T que são obtidos pela Equação 4.28. A imagem temática apresentada pela Figura 4.43b mostra um exemplo dos resultados da estimativa da natureza dos pontos produzidos pelas Equações 4.27 e 4.28.

$$P_S^T = \begin{cases} 1, & \text{se } nMDS_{otm}^{CRT} < \mu_x \\ 0, & \text{caso contrário} \end{cases} \quad (4.28)$$

Se a normalização da superfície do terreno for perfeita, todos os pontos com altura maior que zero pertencem a uma elevação que deve ser investigada. Todos os pontos com altura menor ou igual a zero pertencem à superfície do terreno.

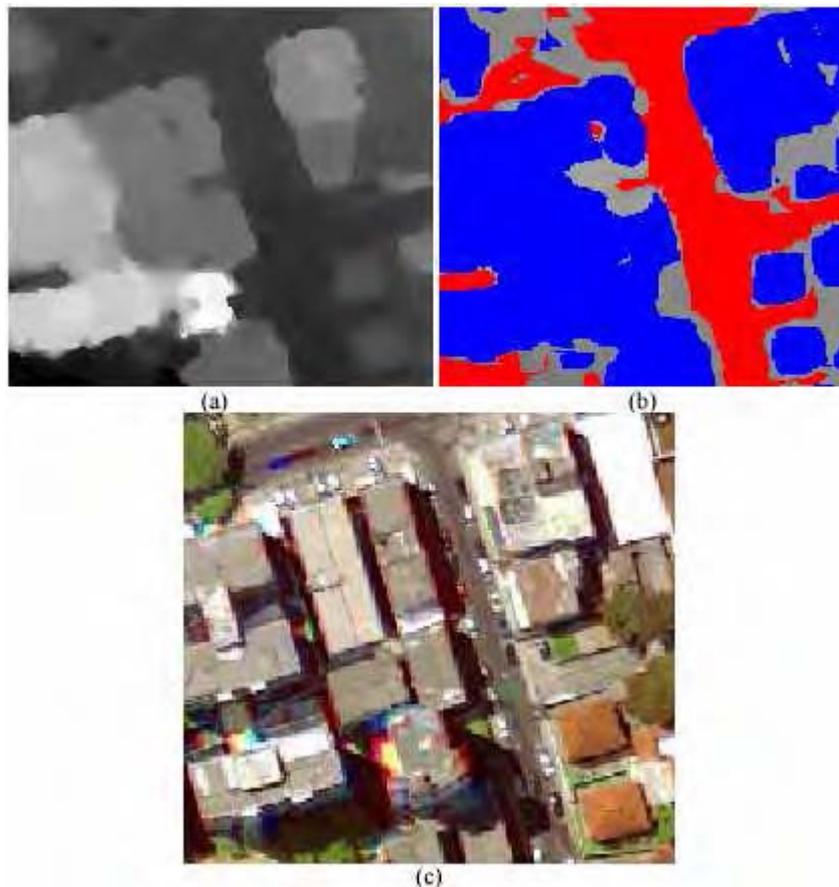


Figura 4.43 Determinação da natureza dos pontos do MDS. (a) MDS original. (b) Imagem temática sobre a natureza dos pontos. Pontos elevados (azul); pontos não elevados (vermelho) e pontos de natureza desconhecida (cinza). (c) Imagem RGB correspondente.

Entretanto, devido à agressividade dos pontos críticos, pode ocorrer que algumas edificações mais baixas, vizinhas de edificações altas, sejam eliminadas pela normalização do MDS. Geralmente, os valores da altura normalizada dessas edificações eliminadas estão próximos de zero (negativo).

Para minimizar a agressividade dos pontos críticos nesse processo de normalização, adotou-se como estratégia estabelecer o valor médio μ , entre todos os pontos

associados com valores negativos obtidos na normalização do MDS, como sendo o valor de limiar a ser usado para estabelecer os pontos P_S^T que estão sobre a superfície do terreno (Equação 4.28). Esse valor médio tem a tendência de estar fortemente deslocado para o lado negativo pois, os pontos referenciados pelo vetor X , que realmente pertencem à superfície do terreno, foram, proporcionalmente, subtraídos por valores maiores, no processo de normalização, que aqueles que pertencem às edificações ou árvores mais baixas. Assim, esse valor médio usado como limiar para estimar os pontos que estão sobre a superfície do terreno (Equação 4.28) provoca um relaxamento nessa limiarização. Esse relaxamento faz com que surjam os pontos de natureza desconhecida (pontos em tons de cinza que aparecem nas imagens temáticas apresentadas nas Figuras 4.43b e 4.44).

4.3.3.6 Análise dos Resultados

Os resultados obtidos com a estimativa da natureza dos pontos do MDS se mostraram muito consistentes pois, o método proposto para normalização do MDS, consegue superar o complexo relevo do terreno da cidade de Salvador, como mostram os resultados da Figura 4.44.

Aqueles pontos verdadeiramente elevados estimados como de natureza desconhecida, em princípio, não implica na perda das elevações correspondentes, no entanto seria mais conveniente que eles houvessem sido detectados como pontos elevados. Entretanto, relaxar o método para ampliar a extensão dessas regiões implica em maior risco na marcação de elementos que estão ao nível da superfície do terreno como sendo de natureza elevada. Então, seguindo o critério usado neste trabalho, que é preferível perder elementos de interesse a incluir, falsamente, outros elementos nos resultados finais, os resultados obtidos com as marcações de dados de elevação permanecerão inalterados.

Todas as regiões marcadas como sendo de natureza desconhecida irão concorrer no processo de segmentação feito pelo uso da técnica de segmentação morfológica *watershed* com marcadores. Se uma região não estiver marcada (ou for de natureza desconhecida), ela será segmentada em função da similaridade, no caso, pela diferença de alturas das bordas de transição entre essa região e as diferentes regiões circunvizinhas que contêm os marcadores internos e externos. Se uma região desconhecida estiver ilhada por um único tipo de marcador, ela será segmentada por esse marcador.

É mais provável que os telhados de edificações não marcados sejam

segmentados como elementos alheios ao interesse devido, principalmente, ao fato da opção que se fez em adotar pontos de sombras como marcadores externos (Seção 4.3.2) envolver a maior parte das edificações não marcadas.

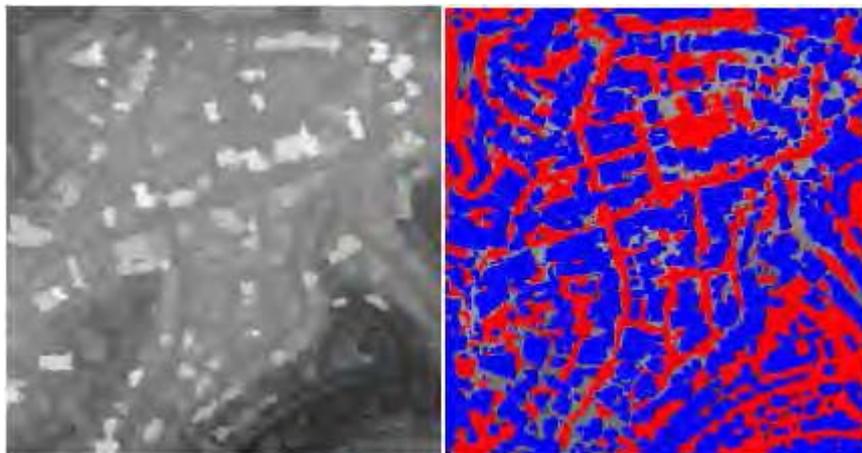


Figura 4.44 Determinação da natureza da elevação dos pontos do MDS. Pontos elevados (azul). Pontos ao nível do terreno (vermelho). Pontos de natureza desconhecida (cinza).

4.3.4 Detecção de Telhados de Edificações

Para completar a segmentação dos telhados das edificações, este trabalho propõe o uso da técnica de segmentação morfológica *watershed* com marcadores internos (representando os telhados) e marcadores externos (representando outros elementos) automaticamente definidos.

Essa técnica de segmentação é aplicada sobre a imagem pancromática adquirida pela câmara HRSC-AX. O uso do componente intensidade extraído do sistema de cor HSI também constitui uma alternativa para o emprego dessa técnica.

Os marcadores internos são formados por alguns pontos pertencentes ao conjunto de pontos P_S^E (Equação 4.27), descontados os pontos equivalentes associados com outros elementos (sombras, vegetação, corpos d'água e rodovias).

Os marcadores externos são formados por alguns pontos pertencentes aos conjuntos de pontos P_S^T (Equação 4.28), sombras, vegetação, corpos d'água e rodovias.

A escolha desses pontos marcadores, internos e externos, é feita por um processo de tratamento individual de todos os conjuntos obtidos. As operações algébricas que se seguem usam operadores de conjuntos: união (\cup), intersecção (\cap) e diferença ou complemento ($-$).

4.3.4.1 Tratamento de Pontos Oriundos de Corpos d'Água e Rodovias

Esse procedimento visa eliminar os pontos de rodovia e de corpos d'água detectados nos telhados de várias edificações. Seja X a matriz (ou imagem binária) formada por todos os pontos detectados como rodovias e como corpos d'água, $X = rod \cup wtr$. Seja Y o resultado da intersecção entre X e a matriz de pontos elevados P_S^E dilatado (\mathcal{D}_B) por um elemento estruturante B de dimensões 11×11 , $Y = X \cap \mathcal{D}_B(P_S^E)$. O resultado dessa intersecção deve ser removido dos conjuntos de marcadores internos (M_1^{Int}) e marcadores externos (M_1^{Ext}), devido à maior incerteza relacionada a esses pontos, pois num resultado foram classificados como uma edificação, em outra foram classificados como uma rodovia e podem tratar-se de parte de uma rodovia em posição mais elevada como pontes, viadutos, etc.

$$M_1^{Int} = P_S^E - Y$$

$$M_1^{Ext} = X - Y$$

4.3.4.2 Tratamento de Pontos Oriundos de Sombras

Os pontos elevados devem ser espacialmente afastados das regiões sombreadas para relaxar a ação dos marcadores externos oriundos de pontos de sombra. Todos os pontos elevados sombreados devem ser desconsiderados pelo conjunto de marcadores internos, pois pontos de sombras são marcadores externos (Seção 4.3.2). Essa desconsideração e esse afastamento dos pontos de sombras dos pontos elevados são conseguidos através da dilatação \mathcal{D}_B das regiões sombreadas por um elemento estruturante B de dimensões 9×9 . Esse afastamento é necessário para minimizar a possibilidade de concorrência entre marcadores internos e externos sobre regiões sombreadas, pois a segmentação de sombras nem sempre é perfeita (principalmente em suas bordas).

$$M_2^{Int} = P_S^E - \mathcal{D}_B(shd)$$

$$M_2^{Ext} = shd$$

4.3.4.3 Tratamento de Pontos Oriundos de Vegetação

Com relação aos marcadores internos, os pontos elevados devem ser afastados das regiões cobertas por vegetação. Como parte da vegetação (árvores) também tem elevação considerável, é necessário fechar ϕ_B os pequenos buracos causados por eventuais sombras e falhas nas estruturas das copas das árvores. Esses buracos não estão registrados nos

dados MDS correspondentes e, assim, simplesmente eliminar os pontos de vegetação dos pontos elevados não elimina essas falhas e, esses pontos residuais de vegetação elevada irão, erroneamente, fazer parte dos marcadores internos. Além disso, há o problema da suavização do MDS em torno da vegetação elevada (a área coberta pelo MDS em torno de uma árvore é maior que a área ocupada pela árvore nas imagens multiespectrais). Esses problemas podem ser contornados se esses pequenos buracos no interior da vegetação segmentada forem fechados e, se o resultado desse fechamento for dilatado. Para esse caso, o fechamento ϕ_B é feito por um elemento estruturante B de dimensões 3×3 e a dilatação δ_B é feita por um elemento estruturante B de dimensões 7×7 para garantir que seja alcançada toda a cobertura feita pelo MDS nas copas das árvores e, também, para estabelecer uma margem de segurança no afastamento dos marcadores internos da vegetação elevada.

Com relação aos marcadores externos, como existe a possibilidade de haver falsa segmentação de vegetação nas bordas e no interior das edificações altas, devido ao problema de registro de imagens adquiridas pela câmara HRSC-AX, esses pontos devem ser desconsiderados dos marcadores externos. Para eliminar, ou minimizar, esse problema, os pontos de vegetação devem ser erodidos \mathcal{E}_B por um elemento estruturante de dimensões 3×3 , para promover pequenas desconexões sobre pontos de vegetação. Espera-se que essa erosão seja mais rigorosa sobre os falsos resultados, uma vez que, regularmente, eles aparecem nas bordas das edificações na forma de padrões de linhas e como aglomerados de área pequena. Ao causar desconexões sobre esses padrões (falsos), são obtidos resíduos na forma de pontos isolados e pequenas áreas conectadas. Esses resíduos podem ser eliminados por um filtro de limiarização por área. Este trabalho usa o filtro de abertura por área (Γ_a^{area}) para eliminar áreas inferiores a 50 pixels.

$$M_3^{Int} = P_S^E - \delta_B(\phi_B(vgt))$$

$$M_3^{Ext} = \Gamma_{a=50}^{area}(\mathcal{E}_B(vgt))$$

4.3.4.4 Tratamento de Pontos Oriundos do MDS

Por falhas na extração do MDS, às vezes, partes de regiões elevadas ficam sem cobertura ou, essa cobertura é excessiva (suavização). O afastamento entre pontos de regiões elevadas e pontos da superfície do terreno elimina, ou minimiza, esse problema. O afastamento é feito pela dilatação δ_B de ambos os conjuntos por um elemento estruturante B

de dimensões 7×7 . O resultado da intersecção X entre os dois conjuntos dilatados deve ser descontado tanto do conjunto dos marcadores internos e como dos externos. Seja

$X = \delta_B(P_S^T) \cap \delta_B(P_S^E)$, então:

$$M_4^{Int} = P_S^E - X$$

$$M_4^{Ext} = P_S^T - X$$

4.3.4.5 Tratamento Final dos Marcadores

A composição dos respectivos conjuntos de marcadores M_j definidos anteriormente estabelece os dois conjuntos de marcadores necessários (internos e externos) para aplicar a técnica de segmentação morfológica *watershed* com marcadores (Equações 4.29 e 4.30).

$$M^{Int} = M_1^{Int} \cap M_2^{Int} \cap M_3^{Int} \cap M_4^{Int} \quad (4.29)$$

$$M^{Ext} = M_1^{Ext} \cup M_2^{Ext} \cup M_3^{Ext} \cup M_4^{Ext} \quad (4.30)$$

Para o conjunto de marcadores internos (M^{Int}), todos os subconjuntos M_j^{Int} foram obtidos por aplicação de restrições sobre os pontos estabelecidos como sendo de natureza elevada (P_S^E). Essas restrições são baseadas nas características dos elementos detectados (sombras, vegetação, corpos d'água e rodovias). Como os resultados da aplicação dessas restrições para se obter o conjunto M_i^{Int} não são as mesmas que aquelas aplicadas para o conjunto M_k^{Int} ($i \neq k$), pode ocorrer de pontos que foram rejeitados no conjunto M_k^{Int} estejam incluídos no conjunto M_i^{Int} . Como quaisquer pontos rejeitados devem ser descartados do conjunto final de marcadores internos, somente pontos de intersecção entre todos os subconjuntos M_j^{Int} devem compor o conjunto de marcadores M^{Int} (Equação 4.29).

Para se obter o conjunto de marcadores externos, as restrições foram aplicadas diretamente sobre alvos específicos e, como a natureza desses alvos permite inferir que os mesmos não correspondem ao elemento desejado (telhados), a união de todos os subconjuntos M_j^{Ext} , resulta no conjunto M^{Ext} (Equação 4.30), o qual inclui somente pontos relativos aos marcadores externos.

Esses dois conjuntos, M_j^{Ext} e M^{Ext} , possuem grandes áreas formadas por pontos conexos, principalmente entre os marcadores externos. Pode ocorrer de alguns pontos de cada um desses conjuntos marcarem elementos diferentes daqueles a que se destina

(principalmente, pontos de fronteiras entre diferentes elementos). Esse problema é minimizado se uma quantidade substancial de pontos for eliminada, de forma sistemática, desses dois conjuntos. Vários procedimentos foram experimentados para realizar essa eliminação de pontos. A alternativa que produziu os melhores resultados foi o operador morfológico binário de última erosão \mathcal{E}_B^∞ .

A idéia básica do funcionamento desse operador está na aplicação sucessiva (iterativa) do operador erosão \mathcal{E}_B , até que todos os pontos da imagem binária sejam totalmente consumidos. A cada visita do elemento estruturante sobre os pontos da imagem binária, é verificado se o subconjunto de pontos envolvido está totalmente contido, mas não igual, no elemento estruturante. Se isso ocorrer, então esse subconjunto será definitivamente removido na próxima iteração com o elemento estruturante. Assim, antes de ser eliminado, esse subconjunto de pontos é armazenado como resultado da última erosão. Esse procedimento é feito para todas as regiões da imagem. Na prática, o operador de última erosão é implementado por processos de reconstrução, pela função distância geodésica ou como um subconjunto do resultado da esqueletização das regiões (FACON, 1996).

A aplicação do operador de última erosão sobre os conjuntos de marcadores M^{Int} e M^{Ext} (Equação 4.31) reduz significativamente a quantidade de pontos envolvidos e, pela sistemática de atuação desse operador de eliminar pontos no sentido da fronteira para o interior do objeto, os pontos resultantes dessa operação, são aqueles que compõem os centros de cada região. Esses pontos centrais são mais confiáveis que outros mais periféricos. Logo, essa operação aumenta a confiabilidade dos marcadores.

Para aplicar a técnica de segmentação *watershed*, os marcadores devem estar associados com valores de rótulos inteiros, positivos e diferentes para cada conjunto marcador. O valor zero deve estar associado com pontos de natureza desconhecida, os quais devem ser segmentados pela aplicação da técnica *watershed*. No caso deste trabalho, existem apenas duas classes de interesse: telhado e não-telhado. Portanto, deve haver três valores de rótulos possíveis $\{0, r_1, r_2\}$, com $r_1 \neq r_2 \neq 0$. Cada pixel da imagem deve ser associado com um único valor de rótulo.

Os conjuntos M^{Int} e M^{Ext} são compostos de valores binários (0 e 1), o valor '1' indica o objeto de interesse e '0' indica que o objeto não interessa ou tem natureza desconhecida, a Equação 4.31 define o conjunto final de marcadores M a ser usado pela técnica de segmentação morfológica *watershed* com marcadores definidos. Essa equação define o valor de rótulo '1' para os marcadores externos, o valor de rótulo '2' para os

marcadores internos e o valor ‘0’ para os pontos de natureza desconhecida, os quais serão segmentados pelo uso do *watershed*.

$$M = \mathcal{E}_B^\infty(M^{Ext}) \cup 2\mathcal{E}_B^\infty(M^{Int}) \quad (4.31)$$

Um exemplo de resultado produzido pela Equação 4.31 está apresentado na Figura 4.45. Essa figura também mostra alguns detalhes para subsidiar algumas análises.

O detalhe (a) da Figura 4.45 mostra as diferentes marcações que ocorreram nas duas partes do telhado de uma mesma edificação. Nesse caso, somente metade do telhado marcado com o valor de rótulo do marcador interno (vermelho) será detectada. Essa marcação ambígua sobre uma mesma edificação foi causada por pontos de sombras e pelo tratamento severo que os pontos do conjunto dos marcadores internos foram submetidos (afastamentos, erosões, subtrações, prioridade para os pontos de sombras, etc.).

O detalhe (b) da Figura 4.45 mostra a manifestação do problema de registro entre as imagens multiespectrais adquiridas pela câmara HRSC-AX. Devido aos desvios radiométricos provocados pelo registro imperfeito, todos os pontos do telhado dessa edificação foram discriminados como sombras e, dessa forma ela não será detectada. Em toda a área da imagem, Figura 4.45, há outras dezesseis (16) edificações apresentando problemas semelhantes (5% do total de edificações nessa imagem).

O detalhe (c) da Figura 4.45 mostra o problema da falta de cobertura do MDS sobre a superfície do telhado dessa edificação (canto superior marcado em azul). Onde esse problema ocorre, uma parte do telhado foi marcada como sendo um elemento indesejado (caso do detalhe (c)). Nessa situação, as diferentes marcas competirão entre si para tomar essa superfície.

Entre os marcadores externos, aquele que mais ocorre sobre telhados é ponto de sombra. Quando esses marcadores são originados de sombras verdadeiras, eles terão poucas chances de se expandirem além das regiões sombreadas, devido ao fato das regiões de sombras formarem bacias de retenção profundas (ou, em outras palavras, as bordas das regiões de sombras são altas).

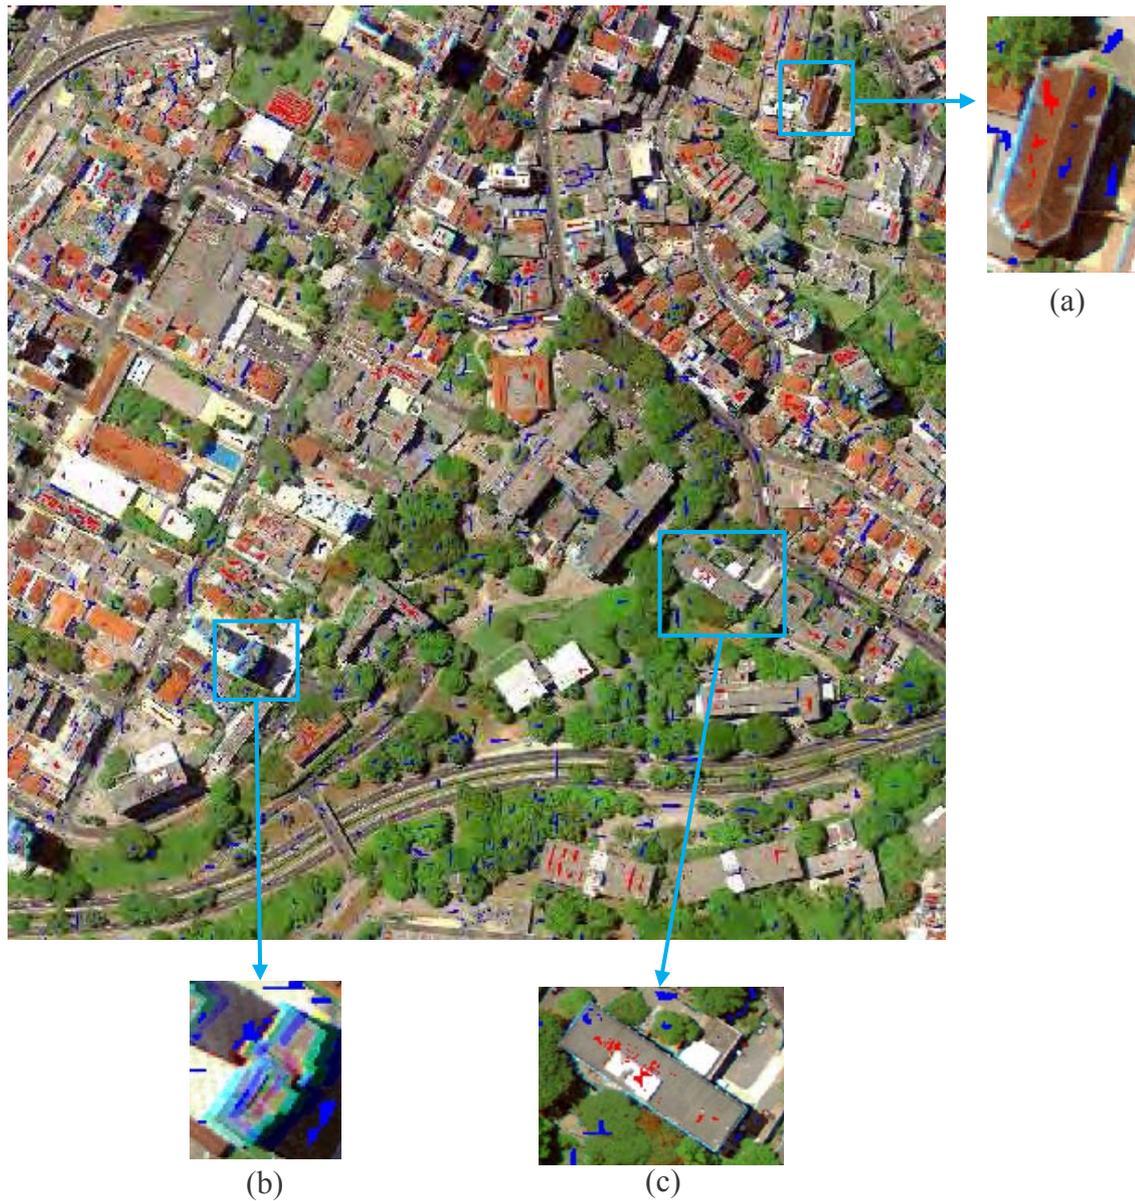


Figura 4.45 Exemplo do resultado final do tratamento dos marcadores internos (vermelho) e externos (azul).

Na imagem apresentada, Figura 4.45, há seis telhados de edificações sem marcação (interna ou externa) e existem mais seis marcados somente pelos marcadores externos. A maioria dos problemas da falta de marcação, ou de marcação errada, é consequência da qualidade do MDS utilizado, o qual conduziu à obtenção do MDS normalizado sem pontos equivalentes para essas edificações, também, devido à agressividade dos pontos críticos. Essas doze edificações não foram detectadas pelo processo proposto neste trabalho.

4.3.4.6 Aplicação da Segmentação Morfológica Watershed com Marcadores

O operador *watershed* é uma ferramenta eficaz no processo de segmentação de regiões de imagens, pois, consegue tratar ao mesmo tempo o interior e os contornos dessas regiões e os resultados produzidos pela segmentação sempre têm contornos fechados. Quando o operador watershed é usado com um conjunto de marcadores se estabelece o paradoxo do paradigma da segmentação de regiões com o uso de marcadores definido por Beucher-Meyer.

Existem várias formas de implementar esse operador. Algumas são baseadas no gradiente da imagem e, entre essas, algumas exigem a transformação de homotopia das linhas do gradiente. Lotufo e Falcão (2000) propuseram uma implementação do *watershed* baseado em listas hierárquicas ordenadas que operam diretamente sobre os valores de nível de cinza (o gradiente é obtido implicitamente). A base conceitual dessa implementação consiste em aplicar algoritmos seqüenciais que simulam a inundação da superfície através de ‘furos’ localizados no fundo de cada bacia de retenção (mínimos locais) rotulada pelos marcadores. Esse conceito foi estabelecido por Beucher e Meyer (1992) que propuseram um algoritmo baseado em listas ordenadas aplicado sobre valores do gradiente.

Uma imagem em tons de cinza pode ser vista como uma superfície topográfica. As coordenadas de cada pixel (linha, coluna) representando as coordenadas planimétricas e o valor do nível de cinza a altura do relevo. Considere então a existência de dois conjuntos marcadores com rótulos distintos (um vermelho, outro azul), definidos sobre diferentes regiões dessa ‘imagem-superfície’, como mostra a imagem 4.46. Nos pontos de mínimo da imagem-superfície, relativos a cada conjunto de marcadores, deve ser feito um furo na linha da superfície da imagem. Então, toda a superfície é gradativamente afundada em um compartimento de água e, quando a superfície da água atinge o furo mais baixo, o processo de inundação começa a ocorrer.

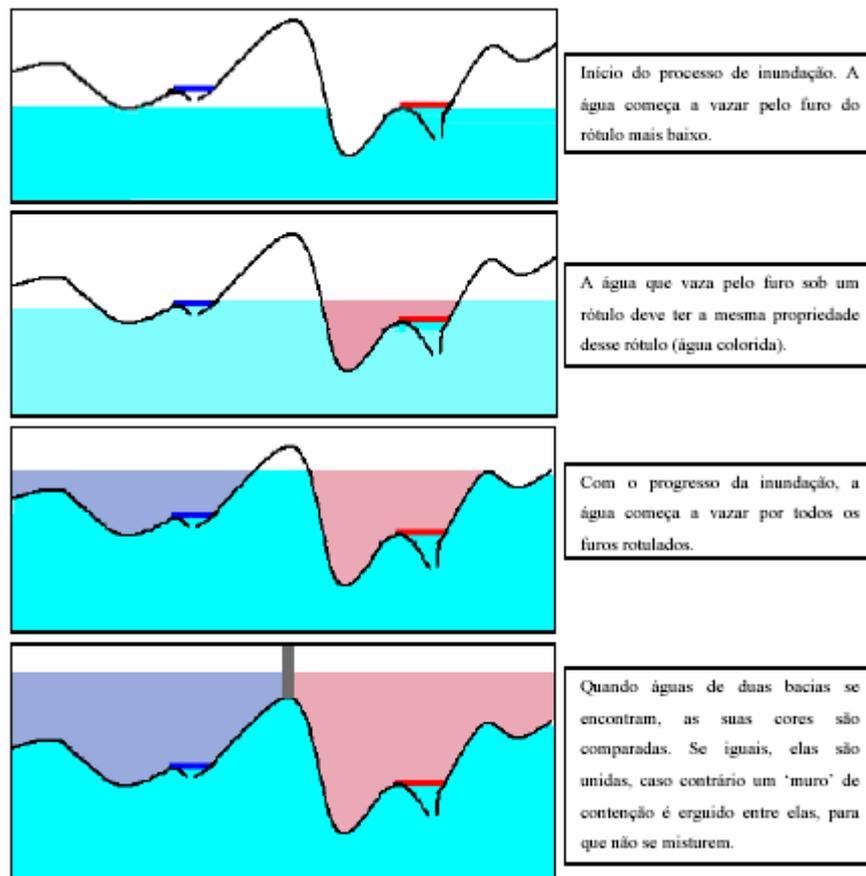


Figura 4.46 Simulação da segmentação *watershed* com marcadores pelo conceito de inundação.

Com o progresso da inundação, essas bacias começam a transbordar para bacias vizinhas. Quando há o encontro de águas de duas bacias vizinhas, são comparadas as propriedades (cor, no caso) dessas duas águas vindas de regiões diferentes. Se elas tiverem as mesmas propriedades, elas serão unidas, caso contrário, um 'muro' de retenção é erguido entre elas, impedindo que essas águas se misturem. A união de todos os muros forma as linhas que separam os diferentes elementos rotulados na imagem. O processo termina quando toda superfície é inundada.

O conjunto de marcadores internos e externos M definidos pela Equação 4.31 são os rótulos de cada bacia de retenção da imagem associada. A princípio, a imagem pode ser oriunda de qualquer faixa espectral, ou ser os valores de brilho do componente intensidade do sistema de cor HSI. Este trabalho faz uso da imagem pancromática (*PAN*).

Antes de aplicar essa técnica de segmentação, a imagem deve ser filtrada com o propósito de eliminar ruídos de altas e baixas frequências e, ainda, para produzir zonas planas, ou próximas de uma. Esse processo de filtragem não pode deslocar e nem inserir novas bordas nas áreas das imagens (filtros conexos).

Para este propósito, este trabalho faz uso dos filtros morfológicos de abertura e fechamento por área, com valor de limiar de área igual a 100 pixels, aplicado a uma imagem com resolução de 50cm (Equação 4.32).

$$F_{\Phi}^{\Gamma}(x) = \Gamma_{a=100}^{area} \left(\Phi_{a=100}^{area}(x) \right) \quad (4.32)$$

Um exemplo de resultado da aplicação desse filtro sobre a imagem *PAN*, $F_{\Phi}^{\Gamma}(PAN)$, é apresentado na Figura 4.47b. Pode-se observar, nesse exemplo, que pequenas áreas de altas e baixas frequências são eliminadas, além de produzir zonas mais planas, sem deslocar e sem acrescentar novas bordas.

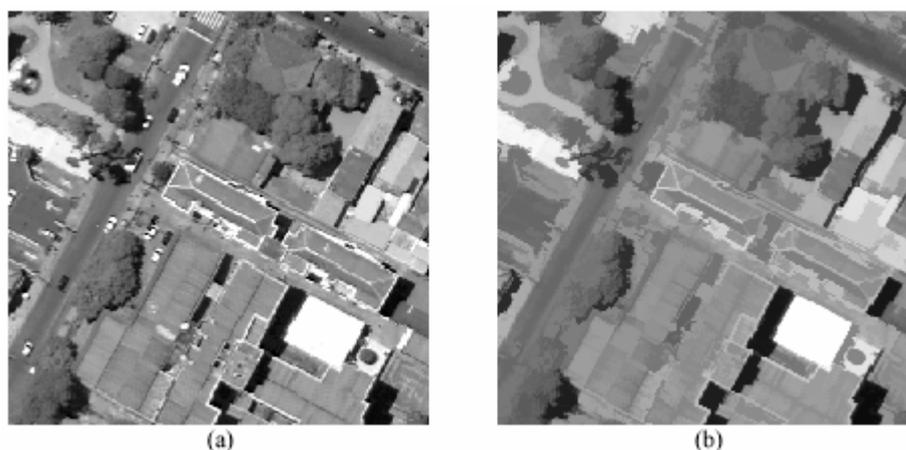


Figura 4.47 Filtragem da imagem pancromática (HRSC-AX). (a) Imagem original. (b) Imagem filtrada $F_{\Phi}^{\Gamma}(PAN)$.

Usando o conjunto de marcadores M (Equação 4.31) e a imagem filtrada $F_{\Phi}^{\Gamma}(PAN)$ (Equação 4.32), a técnica de segmentação morfológica com marcadores definidos pode ser aplicada.

Resultados obtidos com a aplicação da metodologia de segmentação proposta são apresentados na imagem temática da Figura 4.48c. As regiões em amarelo sobre essa imagem correspondem às áreas recuperadas, com contornos fechados, que foram eliminadas dos respectivos telhados por pontos de sombras com áreas inferiores a 500 pixels.

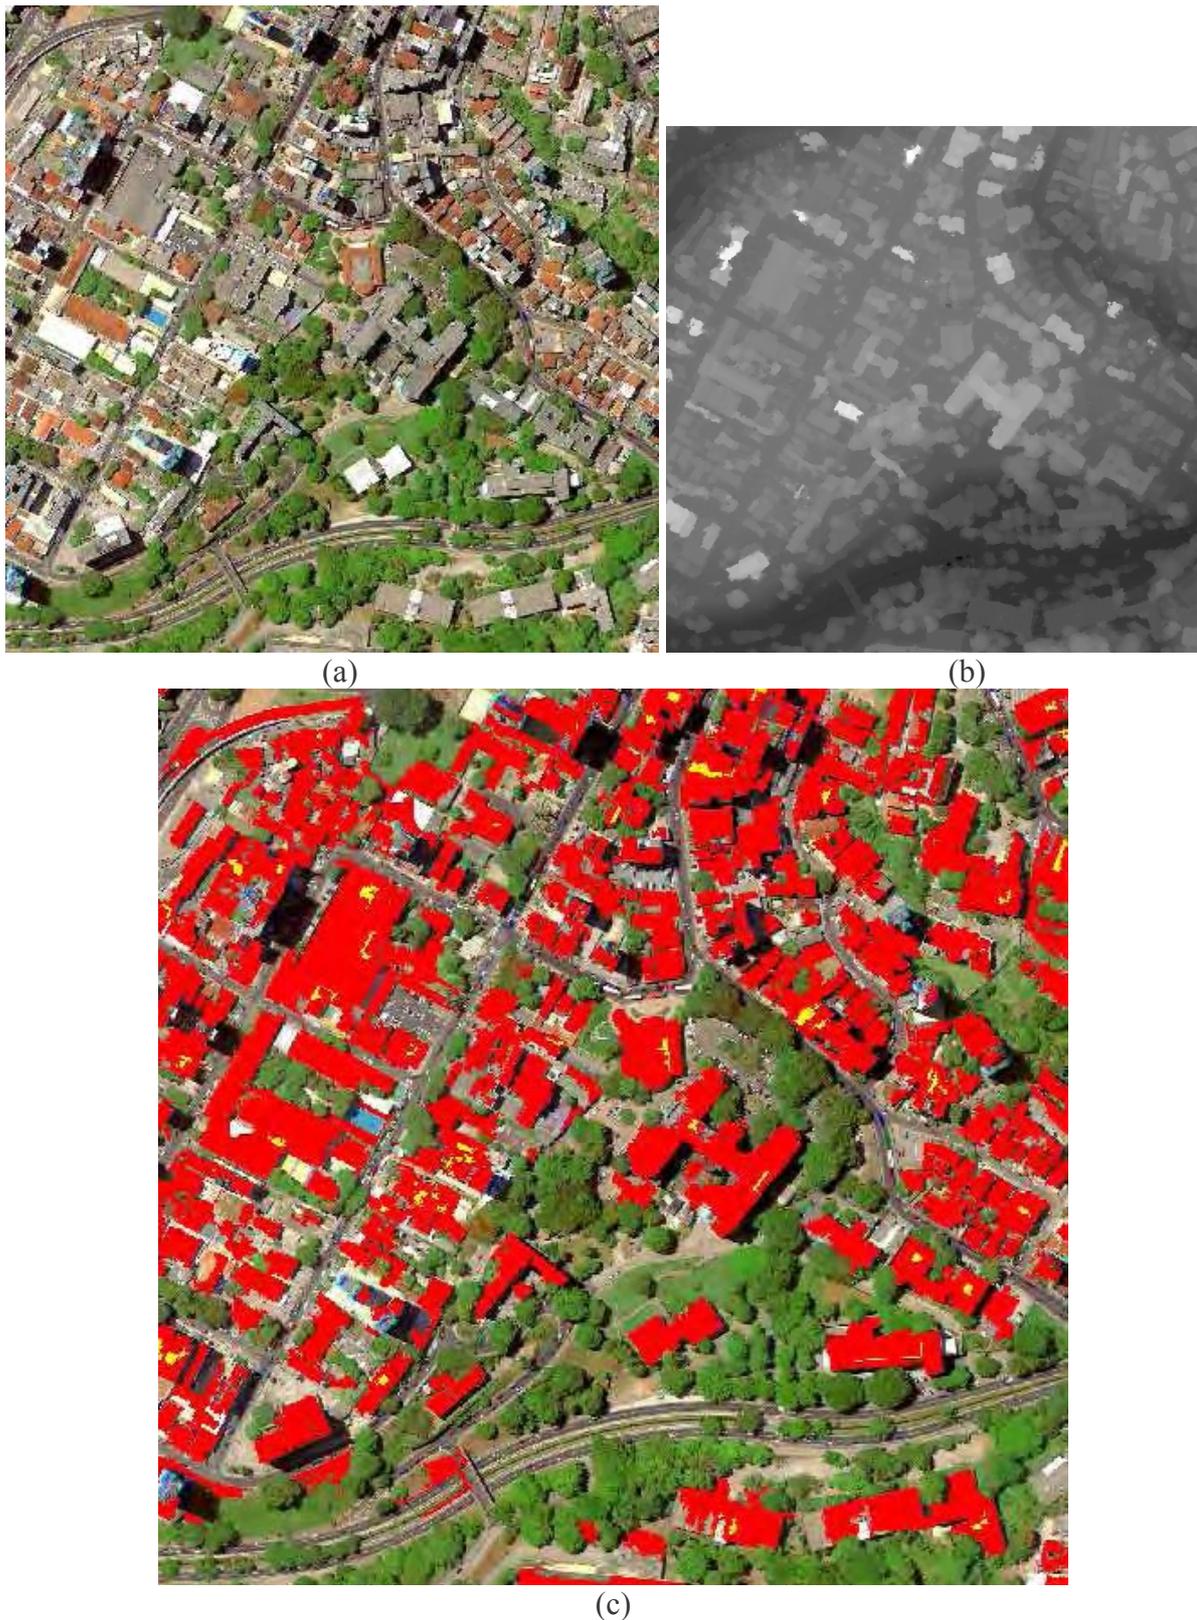


Figura 4.48 Segmentação de telhados de edificações. Resultados obtidos com a metodologia proposta. (a) Imagem RGB original. (b) MDS original. (c) Resultados obtidos (regiões em vermelho e amarelo).

4.3.4.7 Análise dos Resultados

Para possibilitar uma análise mais acurada, baseado em fotointerpretação, foi segmentado um padrão de referência para os telhados de edificações correspondentes aos resultados apresentados na Figura 4.48c. Esse padrão de referência está apresentado na imagem temática da Figura 4.49.

Alguns dados gerais sobre o padrão de referência são: a imagem da Figura 4.49 tem 1.440.000 pixels, sendo 413.180 pixels associados com telhados de edificações (29% da área da imagem). Existem, pelo menos, 343 edificações nessa imagem.

Considerando que um subconjunto de pontos sobre o telhado de uma edificação, detecta esse telhado e, sabendo que na imagem resultado (Figura 4.48c) foram detectados 331 telhados de edificações (12 foram perdidos) entre 343 possíveis então, mais de 96% dos telhados de edificações foram detectados.

Dos 413.180 pixels associados com telhados de edificações no padrão de referência, 327.716 foram corretamente detectados. Dos 1.026.820 pixels associados com outros elementos, 929.199 foram detectados corretamente.

A Tabela 4.2 apresenta a matriz de confusão entre o resultado obtido e o padrão de referência.

Tabela 4.2 Matriz de confusão dos resultados de detecção de telhados

	Telhado	Outros	Total
Telhado	327.716	85.464	413.180
Outros	97.621	929.199	1.026.820
Total	425.337	1.014.663	1.440.000

A matriz de confusão permite calcular o índice de qualidade global (acurácia), os índices de erros de omissão e inclusão e o coeficiente de concordância Kappa (Centeno, 2004).

O índice de qualidade global da detecção é 87,3% $\left(\frac{327.716 + 929.199}{1.440.000}\right)$. O coeficiente de concordância Kappa é 0,69, o qual classifica os resultados como muito bons. Os índices de erros de omissão e inclusão estão dispostos na Tabela 4.3.

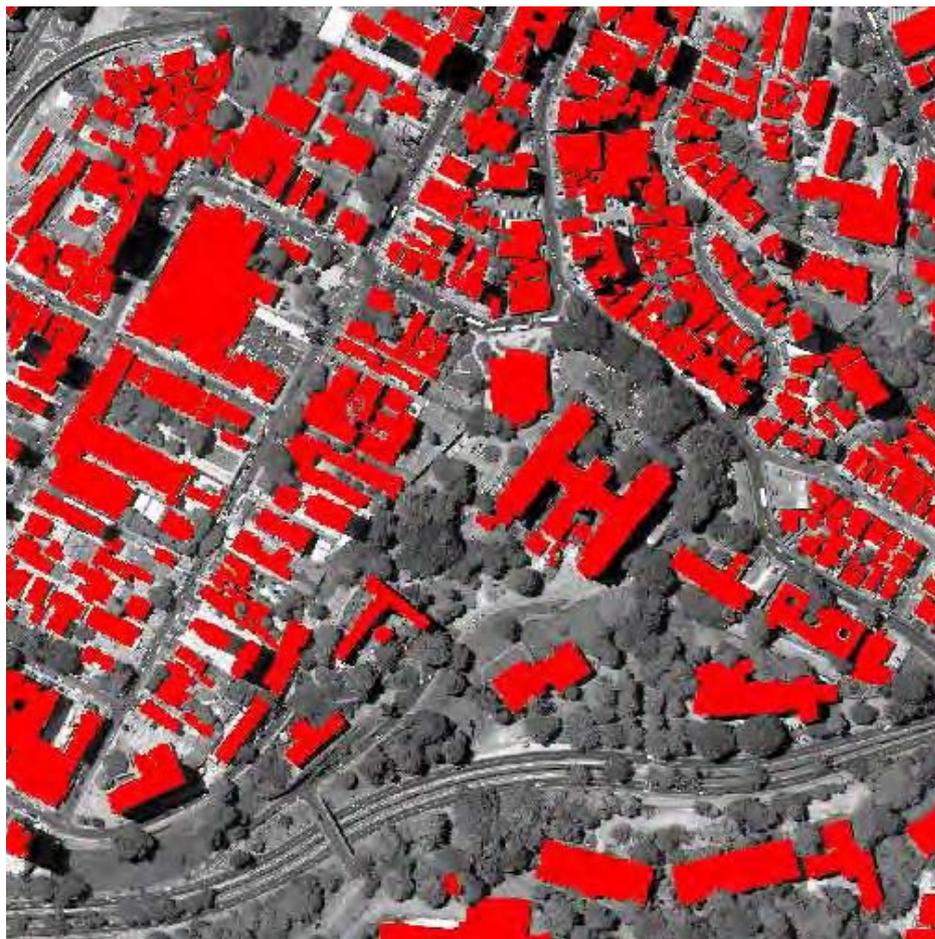


Figura 4.49 Padrão de referência obtido através de fotointerpretação contendo demarcações dos telhados.

Tabela 4.3 Índices de erro de inclusão e omissão.

	Omissão	Inclusão
Telhado	0,21	0,23
Outros	0,10	0,08

O erro de omissão de telhados (21%) se refere a pontos de telhados não detectados. A maior contribuição para o valor desse erro é advindo dos pontos de sombras e, em segundo lugar, do problema de registro das imagens multiespectrais adquiridas pela HRSC-AX e, em terceiro lugar, da normalização do MDS, pela agressividade dos pontos críticos.

O erro de inclusão de telhados (23%) se refere aos pontos de outros elementos incluídos como telhado. A maior fonte desse erro está na normalização do MDS, principalmente, em regiões onde há uma mudança brusca na elevação do relevo. Uma outra fonte de erro de inclusão tem origem em outros elementos elevados como, por exemplo, viadutos e pontes. No canto superior esquerdo da imagem da Figura 4.48a tem um viaduto, o

qual foi quase que completamente detectado como telhado de uma edificação. Esse viaduto contribuiu com 5.000 pixels para o aumento desse erro. Apesar da maior parte do mesmo haver sido detectado como rodovia, ele tem elevação considerável e, como os pontos detectados, ao mesmo tempo, como pontos de rodovias e pontos de elementos elevados são excluídos tanto do conjunto de marcadores externos como dos internos, a informação de se tratar de uma rodovia, verdadeira neste caso, não foi convenientemente aproveitada.

CAPÍTULO V

CONSIDERAÇÕES FINAIS

A eficiência dos métodos propostos neste trabalho é altamente dependente da qualidade dos dados usados, especialmente dos dados de elevação, apesar de se haver contornado grande parte dos problemas de registro entre imagens adquiridas pela câmara HRSC-AX. Testes mostraram que a qualidade dos dados de resposta espectral dos alvos é fundamental para o cálculo dos índices de realce. Formatos de arquivo de imagem que realizam compactação com perda ou compressão dos dados da imagem em detrimento da qualidade dos valores radiométricos originalmente registrados, como JPEG, não são adequados para serem usados pela metodologia proposta neste trabalho.

O método proposto para detectar e discriminar sombras e vegetação verde em imagens RGB mostrou-se muito eficiente, mais de 95% das regiões sombreadas foram perfeitamente detectadas com pouco erro de inclusão associado. A detecção de vegetação verde, em muitos casos, também foi quase integral, entretanto, a eficiência dessa detecção depende das condições da folhagem da vegetação, principalmente pela sua variação sazonal.

A inserção da imagem infravermelha no processo de detecção dos elementos de interesse permitiu diferenciar sombras e vegetação e minimizar a confusão entre sombras e corpos d'água, além de permitir modelar o processo de detecção e de discriminação desses elementos mais facilmente. O uso adequado das imagens multiespectrais permitiu ainda a detecção de corpos d'água e a extração extensiva e conectada de pontos marcadores de rodovias.

Todos esses resultados foram conquistados através de modelos matemáticos muito simples, tanto do ponto de vista do entendimento, como do ponto de vista do esforço computacional necessário para realizar os processamentos necessários. Isto somente foi possível com o uso dos índices propostos: *Nanda*, *nSI*, *sSI*, *WWI*, *mWI*, *RWSI*, *nRI*, além do *NDVI*. Esses índices podem ser combinados de diferentes formas, além das apresentadas neste trabalho e, ainda assim, continuarem a produzir resultados adequados para outras aplicações, no que se refere ao problema de detecção de alvos com comportamento espectral previsível.

Quanto aos dados de elevação usados neste trabalho, deve ser registrada a

qualidade superior do MDS derivado das imagens estéreo-fotométricas da câmara HRSC-AX, quando comparado com MDSs derivados das tradicionais imagens estéreo-pares com 60% de sobreposição através da aplicação de métodos tradicionais. Entretanto, seria mais conveniente se o MDS usado neste trabalho fosse gerado com resolução espacial de 20cm (GSD), uma vez que as imagens estéreo-fotométricas foram adquiridas com 20cm de resolução espacial, pois, se assim fosse, haveria uma maior precisão na separação de edificações vizinhas, separadas por pequenas distâncias, na normalização do MDS e, considerando essa possibilidade, os pontos de sombras poderiam ser usados somente como apoio para refinar esse processo de separação.

5.1 PROPOSTAS PARA TRABALHOS FUTUROS

A continuidade natural deste trabalho é o desenvolvimento de métodos para extrair e o delinear os elementos que compõem a paisagem urbana. Este trabalho considera que vegetação verde e sombras foram praticamente extraídas pelos métodos propostos, talvez, devam ser incorporados aos métodos propostos tratamentos restritivos específicos para casos extremos, como o problema de detectar sombras na presença de outros elementos muito escuros como aqueles que foram apresentados na imagem da Figura 4.12a, apesar de que, neste caso, o método detectou mais de 95% dos pontos de sombras existentes, mas, uma parcela de pontos de outros elementos muito escuros foi confundida como pontos de sombras. Mas para esse caso não estava disponível a imagem infravermelha correspondente, portanto, foi usada somente a imagem colorida, e dessa forma não há como se avaliar se o segundo método proposto para detecção de sombras, o qual usa os índices nSI , sSI e $NDVI$, poderia solucionar mais eficazmente a complexidade da cena registrada pela imagem mostrada na Figura 4.12a.

Para extrair rodovias e a malha viária urbana a seguinte estratégia pode ser adotada pelos algoritmos perseguidores de rodovias: (1) minimizar a quantidade de pontos do conjunto de marcadores de rodovias, de tal forma que se consiga aumentar o grau de certeza desses pontos pertencerem, exclusivamente, às rodovias. (2) Usar os outros elementos detectados, principalmente sombras e vegetação, como informação contextual e, também por serem capazes de interromper a marcação e a extração de uma rodovia. (3) Extrair o máximo possível de rodovias usando somente esses pontos de elevada certeza. (4) Escolher novos pontos do conjunto de pontos excluídos no passo 1, agora definidos por um grau de certeza mais relaxado, e juntá-los ao resultado parcial obtido no passo 3 e, em função desse resultado

mais confiável, estabelecer relações e restrições geométricas e espectrais capazes de inferir sobre a natureza desses novos pontos inseridos no processo de extração. Esse processo é encerrado quando todas as hipóteses de rodovias forem testadas (cada ponto marcador gera uma hipótese).

A confusão entre corpos d'água e marcadores de rodovias deve ser minimizada, talvez considerando um processo de classificação (redes neurais, métodos de classificação fuzzy ou estatísticos) envolvendo somente pontos detectados sobre esses dois elementos, usando como atributos os valores produzidos pelos índices propostos neste trabalho.

Quanto aos telhados de edificações, o processo de detecção pode ser refinado, a partir dos resultados obtidos, para completar os resultados das edificações que não foram integralmente cobertas pela detecção e, para eliminar os pontos ao nível da superfície do terreno que foram erroneamente detectados como telhados.

Na Seção 4.3.3.6 foi apresentado o problema causado pela agressividade dos pontos críticos usados para normalizar o MDS, os quais provocaram a não detecção de algumas edificações.

Este trabalho propõe um conjunto de medidas, as quais devem ser criteriosamente estudadas, para minimizar as perdas de marcações de elementos elevados.

A primeira alternativa trata do relaxamento dos pontos críticos. O problema da agressividade desses pontos não está associado com a distribuição espacial dos mesmos, mas sim com os seus respectivos valores associados. Após detectar todos os pontos críticos, pode-se fazer uma análise de vizinhança entre eles, por exemplo, considerando apenas os três primeiros vizinhos mais próximos de um ponto crítico qualquer, o qual terá o seu valor associado substituído por um valor avaliado entre o seu próprio valor e os valores dos pontos vizinhos considerados (valor mínimo, valor médio, mediana, interpolação, etc.). Adotando essa estratégia, os valores de altura de muitos pontos críticos podem ser diminuídos, diminuindo assim a agressividade dos mesmos. Sugere-se, a princípio, que sejam considerados três vizinhos e que o novo valor a ser associado com um determinado ponto seja dado pela média aritmética simples entre o seu valor e o valor mínimo observado entre os quatro pontos envolvidos. Entretanto, esse relaxamento não pode implicar no aumento da taxa de erro de inclusão de elementos não-elevados como elevados.

A segunda alternativa é aumentar a densidade de pontos que são usados para gerar a superfície que normaliza o MDS. No contexto deste trabalho, somente os pontos críticos são usados nesta tarefa. Esses pontos extras podem ser oriundos das bordas, ou das

vizinhanças, de corpos d'água com valores de áreas significativos e pontos de rodovias extraídos de grandes áreas conectadas. Esses elementos podem contribuir com pontos de máximo, considerando um determinado espaçamento entre eles.

A terceira alternativa envolve a desconsideração de pontos de sombras como marcadores. Uma ou mais regiões sombreadas próximas podem contribuir com um ponto de mínimo para aumentar a densidade dos pontos críticos usados na normalização do MDS e, em seguida todos os pontos de sombras correspondentes ao MDS normalizado devem ser desconsiderados como pontos de elevação ou como pontos ao nível da superfície do terreno. Após a detecção de todos os telhados de edificações possíveis, os pontos das regiões sombreadas devem ser processados, usando critérios mais refinados, os quais devem ser estabelecidos, para se verificar as suas respectivas pertinências como telhados de edificações.

Uma quarta alternativa é usar o resultado da detecção de telhados, sombras e vegetação com elevação, obtidos com a metodologia proposta neste trabalho, como um conhecimento adquirido e fazer uso desse conhecimento para detectar outros pontos sobre o MDS que sejam capazes de normalizá-lo e, ao mesmo tempo, contornar o problema existente na derivação do MDS sobre regiões sombreadas.

A melhor alternativa, para esse caso, é extrair um novo MDS, com maior resolução espacial e com maior precisão. A solução ideal é obter um novo MDS que tenha a mesma resolução espacial das imagens multiespectrais, 20cm no caso deste trabalho.

Para tornar isto possível, pode-se utilizar o resultado obtido na detecção de elementos como um conhecimento adquirido e, para cada tipo de elemento detectado adotar uma estratégia apropriada de tratamento particular. Por exemplo, para corpos d'água somente pontos de borda, ou de sua vizinhança, e alguns pontos do seu interior são necessários para representar a sua elevação. No entanto, para outros elementos é necessário um estudo preliminar para determinar as melhores estratégias de abordagem.

O problema para aplicar essa estratégia está em como reconhecer pontos que detectam edificações nas respectivas imagens do estéreo-par, uma vez que elas estão em perspectiva central e a detecção dos telhados é feita em uma imagem ortorretificada (projeção ortogonal). Mas, se isto for possível e viável, a extração de um novo MDS, com maior precisão altimétrica e planimétrica, permitirá refinar todo o processo: detecção, extração de atributos e reconstrução das edificações.

5.2 CONCLUSÕES

Neste trabalho foram propostos métodos para detectar elementos específicos presentes na paisagem urbana contidos em imagens aéreas multiespectrais e em dados de elevação, os quais foram testados em situações que representam contextos complexos como: região urbana densa; relevo de terreno não suavizado; imagens adquiridas por diversos sensores em diversas condições de iluminação, nas quais estão presentes variados tipos de alvos, cada um deles com diferentes formas geométricas; padrões de cores e; comportamentos espectrais.

Quanto aos métodos propostos para detectar elementos presentes na paisagem urbana usando imagens radiométricas, este trabalho considerou a disponibilidade de dois conjuntos de imagens: (1) imagens coloridas adquiridas na faixa do visível do espectro eletromagnético e; (2) imagens coloridas adquiridas na faixa do visível e infravermelho próximo do espectro eletromagnético. Para cada um desses conjuntos foram propostos métricas para realçar separadamente cada um dos elementos de interesse. Baseado nas análises dessas métricas, foram propostas técnicas determinísticas capazes de detectar esses elementos, as quais produziram bons resultados sobre os conjuntos de dados manipulados.

A opção pela aplicação de técnicas determinísticas para realizar a detecção dos elementos de interesse, talvez não seja a melhor forma de abordar a solução dos problemas envolvidos com essa detecção, embora a opção por essas técnicas constitua uma alternativa interessante, pois, no caso deste trabalho, essa alternativa mostrou que as métricas propostas para avaliar os elementos de interesse foram bem definidas.

Essas métricas, definidas na forma de realce de alvos específicos, como *Nanda*, *nSI*, *sSI*, *mWI* e *nRI* junto com o *NDVI*, se mostraram consistentes e robustas, uma vez que foi usada uma grande variedade de dados na experimentação (imagens adquiridas por oito sensores diferentes, de diferentes superfícies e em diferentes condições atmosféricas e de iluminação). As métricas propostas e avaliadas neste trabalho podem ser usadas como atributos na aplicação de outras abordagens de solução para o problema de detecção de elementos específicos presentes em dados de imageamento aéreo e, por isso, constituem uma importante contribuição deste trabalho para o desenvolvimento do estado da arte.

Com referência aos problemas de normalização do MDS e detecção de telhados de edificação, este trabalho considera que o campo de desenvolvimento de soluções ainda é muito amplo. Entretanto, mostrou-se neste trabalho, a alta dependência dessas soluções de dados radiométricos e de elevação obtidos com alta precisão. Além disso, há a

necessidade de se explorar, de forma mais coerente, ferramentas de processamento de imagens mais sofisticadas para contornar casos complexos que fazem parte desses dois problemas. Para o problema de normalização do MDS, este trabalho propôs uma metodologia de detecção de pontos críticos sobre os dados do próprio MDS, os quais são usados para gerar uma superfície capaz de normalizar esse MDS. Entretanto, é necessário que seja feito um estudo mais detalhado para determinar, com melhor precisão, quais são efetivamente os pontos críticos relevantes para esse processo. Para o problema de detecção de telhados, este trabalho propôs uma nova abordagem que usa o conhecimento contextual adquirido com a detecção de elementos específicos usando as imagens radiométricas e pelo estabelecimento da natureza da elevação dos elementos que compõem a paisagem urbana. Mesmo com o uso desse conhecimento contextual, a solução do problema de detecção de telhados de edificações não foi possível de se realizar com a aplicação de técnicas de processamento de imagens mais simples. Recorreu-se então a dois métodos de processamento de imagens provenientes da Morfologia Matemática: a filtragem conexa (abertura e fechamento por área) e a segmentação por linhas de partição de águas (*watershed*) com marcadores automaticamente definidos. A aplicação dessas duas ferramentas mostrou ser consistente e robusta e conseguiu superar casos particulares com alto grau de dificuldade inerentes a esse problema. Os testes realizados e os resultados produzidos com a aplicação dessas ferramentas da Morfologia Matemática mostraram que pode haver uma exploração mais adequada dos recursos da área de Processamento de Imagens em problemas relacionados com problemas inerentes à área de Fotogrametria.

O estabelecimento de pontos críticos usados na normalização do MDS e o uso de técnicas de processamento de imagens mais sofisticadas usadas neste trabalho, muito pouco exploradas²⁴ em Fotogrametria e Sensoriamento Remoto, constituem uma outra contribuição deste trabalho.

Os elementos detectados: corpos d'água; marcadores de rodovias; vegetação verde; sombras e telhados de edificações, bem como a normalização do MDS, estabelecem um nível elevado de conhecimento sobre o contexto dessas imagens. O uso desse conhecimento contextual pode gerar novas abordagens de tratamento de imagens aéreas com propósitos de otimizar processos relacionados com Fotogrametria, Sensoriamento Remoto, Cartografia e Sistemas de Informação Geográfica.

Essa otimização refere-se tanto ao esforço humano empregado, como à

²⁴ Considerando os trabalhos publicados com referência neste trabalho, nenhum deles faz uso dessas ferramentas.

precisão dos resultados obtidos, além da redução do tempo e dos custos envolvidos nesses processos. Ainda, caso essa otimização seja possível, dados como aqueles adquiridos por sensores de sistemas de varredura laser podem ser dispensados, evitando, dessa forma, custos extras relacionados com sistemas desse tipo, como: aquisição, manutenção, operação e com a adaptação especial de aeronaves (complexas e caras). Entretanto, muito trabalho de pesquisa é necessário para fomentar esse grau de automação e otimização.

Este trabalho relacionou diversas áreas do conhecimento humano, especialmente: Processamento de Imagens, Morfologia Matemática, Sensoriamento Remoto e Fotogrametria e, em retorno para essas áreas, foram desenvolvidos métodos (detecção), foram propostas métricas (índices de realce) e foram alcançados resultados, dos quais se espera haver uma real contribuição para o avanço do estado da arte dessas áreas e de outras correlatas com a Geodésia: Cartografia e Sistemas de Informação Geográfica.

REFERÊNCIAS BIBLIOGRÁFICAS

ALHARTHY, A; BETHEL, J. Heuristic filtering and 3d feature extraction from LIDAR data. In: ISPRS SYMPOSIUM PCV02 – PHOTOGRAMMETRIC COMPUTER VISION, 2002, Graz, September 9-13, commission III, pp. 34 – 40.

AKEL, N. A.; ZILBERSTEIN, O.; DOYTSHER, Y. A robust method used with orthogonal polynomials and road network for automatic terrain surface extraction from lidar data in urban areas. In: XXTH ISPRS CONGRESS: GEO-IMAGERY BRIDGING CONTINENTS, 2004, Istanbul, July 12-23, Commission 3, pp. 243 – 248.

ANDERSEN, H.; REUTEBUCH, S. E.; SCHREUDER, G. F. Bayesian object recognition for the analysis of complex forest scenes in airborne laser scanner data. In: ISPRS SYMPOSIUM PCV02 – PHOTOGRAMMETRIC COMPUTER VISION, 2002, Graz, September 9-13, commission III, pp. 42 – 49.

AREFI, H.; HAHN, M. A morphological reconstruction algorithm for separating off-terrain points from terrain points in laser scanning data. IN: ISPRS: WORKSHOP – LASER SCANNING 2005, Enschede, the Netherlands, 2005, September 12-14, WG III/3, III/4, V/3, pp. 120 – 125.

BAUMGARTNER, A.; STEGER, C.; MAYER, H.; ECKSTEIN, W.; EBNER, H. Automatic road extraction in rural areas. In: IASPR, Munich, Germany, 1999, September 8 – 10, vol. 32, part 3-2W5, pp. 107 – 112.

BANON, G. J. F.; BARRERA, J. 1998. **Bases da morfologia matemática para análise de imagens binárias**. 2.ed. São José dos Campos: INPE, 1998. 227p.

BEUCHER, S.; MEYER, F. **The morphological approach to segmentation: the watershed transformation**. In: DOUGHERTY, E. R. Mathematical Morphology in image processing. New York: Marcel Dekker Inc, 1992. Chapter 12, pp. 433 – 482.

BRAUN A. Automatic detection and 2-D reconstruction of buildings from orthoimages using vectorized map information. Diploma thesis, Institute of Geodesy and Photogrammetry, ETH

Zürich. 1999. (*appud* Niederöst, (2000)).

CAUSEY, R.; KEHOE, J.; SLATTON, K. C. **Airborne laser intensity measurements for vegetation studies: a comparison to passive imagery techniques**. University of Florida, ASPL, Report, Nº Rep_2005-07-001, 2005, 66p.

CENTENO, J. A. S. **Sensoriamento remoto e processamento de imagens digitais**. Curitiba, Editora Curso de Pós Graduação em Ciências Geodésicas da UFPR, 2004. 209p.

CHUVIECO, E. **Fundamentos de teledetección espacial**. Madrid: Ediciones RIALP S. A., 1990. 453p.

CLODE, S.; KOOTSOOKOS, P.; ROTTENSTEINER, F. The automatic extraction of roads from LIDAR data. In: XXTH ISPRS CONGRESS: GEO-IMAGERY BRIDGING CONTINENTS, Istanbul, 2004, July 12-23, Commission 3, pp. 231 – 236.

CORD, M.; JORDAN, M.; COCQUEREZ, JP.; PAPANODITIS, N. Automatic extraction and modeling of urban buildings from high resolution aerial images. In: ISPRS CONFERENCE: AUTOMATIC EXTRACTION OF GIS OBJECTS FROM DIGITAL IMAGERY, Ebner, H., Eckstein, W., Heipke, C. and Mayer, H. editors, Munich, 1999, September 8 – 10, vol. 32, part B3-2w5, pp. 187 – 192.

D'ORNELLAS, M. C. **Algorithmic patterns for morphological image processing**. Amsterdam: Universiteit van Amsterdam, 2001. 190p.

DAL POZ, A. P.; AGOURIS, P. Um algoritmo de otimização global para extração de rodovias em imagens digitais. **Revista Brasileira de Cartografia**, n. 53, pp. 65 – 72, 2001.

DARE, P. M. Shadow analysis in high-resolution satellite imagery of urban areas. **Photogrammetric Engineering & Remote Sensing**. v. 71, n. 2, pp. 169 – 178, 2005.

DOUGHERTY, E. R. 1992. **An introduction to morphological image processing**. Bellingham: SPIE Press, 1992. 530p.

ELAKSHER, A.; BETHEL, J.; MIKHAIL, E. Building extraction using multiple images, In:

PROCEEDINGS OF ACSM-ASPRS 2002 ANNUAL CONFERENCE, Washington DC, 2002, May.

ELBERINK, S. O.; MAAS, HG. The use of anisotropic height texture measures for the segmentation of airborne laser scanner data. In: PROCEEDINGS OF THE XIX INTERNATIONAL SOCIETY FOR PHOTOGRAMMETRY AND REMOTE SENSING, Amsterdam, 2000, 16-23 July. Vol. XXXIII, Part B3/2, pp. 678 – 684.

EIDENBENZ, C.; KÄSER, C.; BALTSAVIAS, E. Atomi: automated reconstruction of topographic objects from aerial images using vectorized map information. In: PROCEEDINGS OF THE XIXTH INTERNATIONAL SOCIETY FOR PHOTOGRAMMETRY AND REMOTE SENSING, Amsterdam, 2000, 16-23 July. Vol. XXXIII, Part B3/1, pp. 462 – 471.

FACON, J. 1996. **Morfologia Matemática: teoria e exemplos**. Curitiba: Editora Universitária Champagnat da Pontifícia Universidade Católica do Paraná, 1996. 299p.

FELGUEIRAS, C. A.; CÂMARA, G. Modelagem Numérica de Terreno. In Introdução à Ciência da Geoinformação. 2001. Disponível em <<http://www.dpi.inpe.br/gilberto/livro/introd/cap7-mnt.pdf>>. Data de acesso: 18 de agosto de 2006.

FÖRSTNER, W., 3D-City Models: Automatic and semiautomatic acquisition methods. 1999. Disponível em: <<http://www.ifp.uni-stuttgart.de/publications/phowo99/foerstner.pdf>>. Acessado em 14 de Julho de 2003.

FRADIKIN, M.; ROUX, M.; MAITRE, H. Building detection from multi views. In: ISPRS CONFERENCE: AUTOMATIC EXTRACTION OF GIS OBJECTS FROM DIGITAL IMAGERY, Ebner, H., Eckstein, W., Heipke, C. and Mayer, H. editors, Munich, 1999, September 8 – 10, vol. 32, part B3-2w5, pp. 81 – 86.

FUKUNAGA, K; HOSTETLER, L. D. The estimation of the gradient of a density function, with applications in pattern recognition. **IEEE Transaction on Pattern Analysis and Machine Intelligence**, v. IT21, n.1, pp. 32 – 40, 1975.

GAO, B. NDWI – A Normalized Difference Water Index for Remote Sensing of Vegetation Liquid Water from Space. **Remote Sensing of Environment**, n. 58, pp. 257–266, 1996.

GONZALES, R. C.; WOODS, R. E. **Digital image processing**. New York: Addison-Wesley Publishing Company, 1992. 716p.

GOUTSIAS, J.; BATMAN, S. **Morphological methods for biomedical image analysis**. In FITZPATRICK, J. M.; SONKA, M. Handbook of medical imaging: progress in medical image processing and analysis. Vol. 3. Bellingham: SPIE Press, 1999. Chapter 3, pp. 1 – 102.

GRUEN, A.; BALTSAVIAS, E. Automated extraction of man-made objects from aerial and space images. In: PROCEEDINGS OF THE MONTE VERITA WORKSHOP, Basel, 1997, May.

GRUEN, A. TOBAGO-a semi-automated approach for the generation of 3-D building models. **ISPRS Journal of Photogrammetry & Remote Sensing**, v. 53, pp.108-118, 1998.

GRÜN, A Semi-automated approaches to site recording and modeling. In: PROCEEDINGS OF THE XIXTH INTERNATIONAL SOCIETY FOR PHOTOGRAMMETRY AND REMOTE SENSING, Amsterdam, 2000, 16-23 July, Vol. XXXIII, Part B5/1, pp. 309 – 318.

GÜLCH, E. **Application of Semi-Automatic Building Acquisition**. In A. GRUEN, BALTSAVIAS, E. P.; HENRICSSON, O. Automatic Extraction of Man-Made Objects from Aerial and Space Images(II), Birkhäuser Verrlag, Basel.

HALTRIN, V. I. Water-leaving radiance of deep and shallow wind-roughened water body illuminated by sun and sky. In: PROCEEDINGS OF THE III ONW INTERNATIONAL CONFERENCE: CURRENT PROBLEMS IN OPTICS OF NATURAL WATERS, Levin, I. and Gilbert, G. (editors), St. Petersburg, 2005, pp. 30 – 36.

HEIJMANS, H. J. A. M. **Morphological image operators**. Boston: Academic Press, 1994. 452p.

HEIJMANS, H. J. A. M. **Introduction to Connected Operators**. In DOUGHERTY, E. R.; ASTOLA, J. T. Nonlinear filters for image processing. New York: SPIE – The International Society for Optical Engineering, 1999. pp. 207-235.

HIRATA, R. Segmentação de Imagens por Morfologia Matemática. 1997. Dissertação (Mestrado em Matemática Aplicada). Instituto de Matemática e Estatística – IME/USP.

HU, X.; TAO, C. V.; HU, Y. Automatic road extraction from dense urban area by integrated processing of high resolution imagery and LIDAR data. XXth ISPRS CONGRESS: GEO-IMAGERY BRIDGING CONTINENTS, Istanbul, 2004, July 12-23, Commission 3, pp. 320 – 324

HUANG, J.; XIE, W.; TANG, L. Detection of and compensation for shadows in colored urban aerial images, In: PROC. 5TH WORLD CONGR. INTELLIGENT CONTROL AND AUTOMATION, Hangzhou, 2004, Jun. 15–19, pp. 3098–3100.

HUET, A.; JUSTICE, C.; LEEUWEN, W. MODIS. Vegetation index (MOD 13): Algorithm Theoretical Basis Document. Version 3, 1999, 129 p. Disponível em: <http://modis.gsfc.nasa.gov/data/atbd/atbd_mod13.pdf>. Data de acesso 6 de janeiro de 2007.

JENSEN, J. R. **Remote sensing of the environment: an Earth resource perspective**. New Jersey: Prentice Hall, 2000. 544p.

JIANG, B. Extraction of spatial objects from laser-scanning data using a clustering technique. In: XXth ISPRS CONGRESS: GEO-IMAGERY BRIDGING CONTINENTS, Istanbul, 2004, July 12-23, Commission 3, pp. 219 – 224.

JORDAN, M.; CORD, M.; BELLI, T. Building Detection From High Resolution Digital Elevation Models In Urban Areas. ISPRS COMMISSION III, SYMPOSIUM, Graz, 2002, September 9 – 13, part B, pp. 96 – 99.

KANDA, F.; KUBO, M.; MURAMOTO, K. Watershed segmentation and classification of tree species using high resolution forest imagery. In: PROCEEDINGS 2004 IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM IGARSS'04, 2004, September 20-24, Vol. 6, pp. 3822 – 3825.

KHOSHELHAM, K. Building extraction from multiple data sources: a data fusion framework for reconstruction of generic models. In: PROCEEDINGS OF THE XXth INTERNATIONAL SOCIETY FOR PHOTOGRAMMETRY AND REMOTE SENSING, Istanbul, 2004, 12–23 July, Commission 3, pp. 980 – 986.

KILIAN, J.; HAALA, N.; ENGLICH, M. Capture and evaluation of airborne laser scanner data. In: INTERNATIONAL ARCHIVES OF PHOTOGRAMMETRY & REMOTE SENSING, Viena, 1996, Vol. XXXI, Part B3, pp.383-388.

KRAUS, K.; OTEPKA, J. **DTM modelling and visualization: the SCOP approach**. In FRITSCH, D. Photogrammetric Week 05. Heidelberg: Wichmann Verlag, 2005. pp. 241–252.

KRAUS, K.; PFEIFER, N. Determination of terrain models in wooded areas with airborne laser scanner data, **ISPRS Journal of Photogrammetry & Remote Sensing**, n. 53, 1998, pp. 193-203.

KRAUS, K.; RIEGER, W. 1999. **Processing a laser scanning data for wooded areas**. In FRITSCH, D.; SPILLER, R. Photogrammetric Week 99. Heidelberg: Wichmann Verlag, 1999. pp. 221 – 331.

LEE, H; YOUNAN, N. H. DEM extraction of LIDAR returns via adaptive processing. **IEEE Transaction on Geoscience and Remote Sensing**, v.41, n.9, 2003, pp. 2063-2069.

LI, Y.; SASAGAWA, T.; GONG, P. A system of the shadow detection and shadow removal for high resolution city aerial photo. In: XXth ISPRS CONGRESS: GEO-IMAGERY BRIDGING CONTINENTS, Istanbul, 2004, July 12-23, Commission 3, pp. 802 – 807.

LILLESAND, T. M.; KIEFER, R. W. **Remote sensing and image interpretation**. 4th ed. New York: John Wiley & Sons Inc, 2000. 724p.

LOHMANN, P.; KOCH, A. Quality assessment of laser-scanner-data. In: ISPRS JOINT WORKSHOP “SENSORS AND MAPPING FROM SPACE 1999, University of Hanover, Institute for Photogrammetry and Engineering Surveys, 1999, WG I/1 & I/3 & IV/4, Disponível em CD-ROM, não paginado.

LOTUFO, R.; FALCÃO, A. **The ordered queue and the optimality of the watershed approaches**, in GOUTSIAS, J.; VINCENT, L.; BLOOMBERG, D. Computational imaging and vision: Mathematical Morphology and its application to image and signal processing, v. 12. Dordrecht: Kluwer Academic Publishers, 2000, pp. 341-350.

MA, RUIJIN. 2004. Building model reconstruction from LIDAR data and aerial photographs.

2004. 166p. PhD Dissertation. Graduate Program of Geodetic Science of the Ohio State University.

MADHAVAN, B. B.; TACHIBANA, K.; SASAGAWA, T.; OKADA, H.; SHIMOZUMA, Y. Automatic extraction of shadow regions in high-resolution aerial images - by robust approach of feature spaces analysis. XXth ISPRS CONGRESS: GEO-IMAGERY BRIDGING CONTINENTS, Istanbul, 2004, July 12-23, Commission 3, pp. 808 – 810.

MATIKAINEN, L.; HYYPPÄ, J.; HYYPPÄ, H. Automatic detection of buildings from laser scanner data for map updating. In: IAPRS, Dresden, 2003, Vol. 34, Part 3W13, pp. 218-224.

MASSALABI, A.; HE, D. C.; BÉNIÉ, G. B.; BEAUDRY, E. Restitution of information under shadow in remote sensing high space resolution images: application to Ikonos data of Sherbrooke city. In: XXth ISPRS CONGRESS: GEO-IMAGERY BRIDGING CONTINENTS, Istanbul, 2004, July 12-23, Commission 3, pp. 173 – 178.

MAYER, S. Extraction of tree groups from high-resolution digital surface models. In: ICIP 2000, Vancouver, 2000, September 10–13, 2000, pp. 1-4.

MCFEETERS, S. K. The use of normalized difference water index (NDWI) in the delineation of open water features. **International Journal of Remote Sensing**, v. 17, 1988, pp.281-293.

MCKEOWN, D. M.; BULWINKLE, T.; COCHRAN, S.; HARVEY, W.; MCGLONE C.; SHUFELT, J. A. Performance evaluation for automatic feature extraction. In: INTERNATIONAL ARCHIVES OF PHOTOGRAMMETRY AND REMOTE SENSING, Amsterdam, 2000, vol. XXXIII, Part B2, pp. 379 – 393.

MEYER, F.; BEUCHER, S. Morphological segmentation. **Journal of Visual Communication and Image Representation**, v.1, n.1, 1990, pp. 21 – 46.

MEYER, F. **From connected operators to leveling**. In HEIJMANS, H. J. A. M.; ROERDINK, J. B. T. M. Mathematical Morphology and its applications to image and signal processing. Dordrecht: Kluwer Academic Publishers, 1998. pp. 191-198.

MYLER, H. R.; WEEKS, A. R. **The pocket handbook of imaging processing algorithms in**

C. New York: Prentice-Hall Inc, 1993. 303p.

NIEDERÖST, M. Reliable reconstruction of buildings for digital map revision. In: PROCEEDINGS OF THE XIXth INTERNATIONAL SOCIETY FOR PHOTOGRAMMETRY AND REMOTE SENSING, Amsterdam, 2000, 16-23 July. Vol. XXXIII, Part B3/2, pp. 635 – 642.

OPITZ, D. W. An intelligent user interface for feature extraction from remotely sensed images. In: ASPRS-1999 ANNUAL CONFERENCE PROCEEDINGS: FROM IMAGE TO INFORMATION, Portland, 1999, May 17-21, pp. 171 – 177.

OTSU, N. A threshold selection method from gray level histograms. **IEEE Transactions on Systems, Man, and Cybernetics**, v.9, 1979, pp. 62-69.

PATERAKI M.; BALTSAVIAS, E. Analysis and performance of the adaptive multi-image matching algorithm for airborne digital sensor ADS40. 2003a. Proceedings of ASPRS Annual Conference 2003, Anchorage, AK, USA. Disponível em: <<http://www.photogrammetry.ethz.ch/general/persons/maria/pub/pub.htm>>. Data de acesso: 26 de agosto de 2006.

PATERAKI, M.; BALTSAVIAS, E., 2003b. **Analysis of a DSM generation algorithm for the ADS40 Airborne Pushbroom Sensor**. In: GRUEN A., KAHMEN H. (Eds.), Proceedings of Conference on Optical 3-D Measurement Techniques VI, ETH Zurich, Switzerland, 1999, 22-25 September, Vol. I, pp. 83-91.

PEROCHE, B. **Alguns desenvolvimentos sobre traço de raio**. In: THALMANN, N. M.; THALMANN, D. Mundos Virtuais e Multimídia. Rio de Janeiro: Livros Técnicos e Científicos Ltda, 1993. pp. 225 – 239.

PHONG, B. T. Illumination for computer generated pictures. **Commun. ACM**, v.18, n.6, 1975, pp. 311–317.

POLIDORIO, A. M.; IMAI, N. N.; TOMMASELLI, A. M. G.; FLORES, F. C.; FRANCO, C. **Realce do grau de artificialidade de feições em imagens aéreas coloridas**. In: MITISHITA, E. A. Séries em Ciências Geodésicas: novos desenvolvimentos em Ciências Geodésicas. Curitiba: Universidade Federal do Paraná, vol. 3, 2003a. pp. 277 – 291, 495p.

POLIDORIO, A. M.; FLORES, F. C.; IMAI, N. N.; TOMMASELLI, A. M. G.; FRANCO, C. Automatic shadow segmentation in aerial color images. In: PROCEEDINGS OF THE IEEE XVth BRAZILIAN SYMPOSIUM ON COMPUTER GRAPHICS AND IMAGE PROCESSING, São Carlos, 2003b, 12 – 15 October, pp. 270 – 277.

POLIDORIO, A. M.; IMAI, N. N.; TOMMASELLI, A. M. G. Índice indicador de corpos d'água para imagens multiespectrais. In: I SIMPÓSIO DE CIÊNCIAS GEODÉSICAS E TECNOLOGIAS DA GEOINFORMAÇÃO, Recife, 2004, Setembro 1 – 3, disponível em CD-ROM não paginado.

POLIDORIO, A. M.; FLORES, F. C.; FRANCO, C.; IMAI, N. N.; TOMMASELLI, A. M. G. Detecção automática de sombras e nuvens em imagens CBERS e Landsat 7 ETM. In: ANAIS XII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, Goiânia, 2005a, 16-21 abril, pp. 4233-4240.

POLIDORIO, A. M.; FRANCO, C.; IMAI, N. N.; TOMMASELLI, A. M. G.; GALO, M. L. B. T. Correção radiométrica de imagens multiespectrais CBERS e Landsat ETM usando atributos de reflectância e de cor. In: ANAIS XII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, Goiânia, 2005b,, 16-21 abril, pp. 4241-4248.

POLIDORIO, A. M.; FRANCO, C.; IMAI, N. N.; TOMMASELLI, A. M. G.; GALO, M. L. B. T. Segmentação de corpos d'água em imagens multiespectrais e temporais usando watershed com marcadores automaticamente definidos. In: ANAIS XII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, Goiânia, 2005c, 16-21 abril, pp. 4249-4257.

PRATT, W. K. **Digital image processing**. New York: John Wiley & Sons Inc, 1991. 698p.

QIU, Z. G.; ZHANG, S. T.; ZHANG, C. L.; FANG, J. Y. Automatic building detection from high resolution images based on multiple features. In: XXth ISPRS CONGRESS: GEO-IMAGERY BRIDGING CONTINENTS, Istanbul, 2004, July 12-23, Commission 2, pp. 616 – 620.

QUACKENBUSH, L. J.; HOPKINS, P. F. Using template correlation to identify individual trees in high resolution imagery. In: ASPRS-2000 ANNUAL CONFERENCE

PROCEEDINGS, Washington DC, 2000, May 22-26. Disponível em CD-ROM, não paginado.

RAVIV, D.; PAO, Y.; LOPARO, K. A. Reconstruction of three-dimensional binary images. **IEEE Transaction on Robotics and Automation**, v.5, n.5, 1989, pp. 701-710.

REIS, E. **Estatística Multivariada**. Lisboa: Edições Sílabo Lda., 1997. 343p.

ROGGERO, M. Airborne laser scanning: clustering in raw data. In: INTERNATIONAL ARCHIVES OF PHOTOGRAMMETRY & REMOTE SENSING, Annapolis, 2001, October 22-24, vol. 34, part 3W/4, pp. 227–232.

ROUSE, J.W.; HAAS, R.H.; SCHELL, J.A.; DEERING, D.W. Monitoring Vegetation Systems in the Great Plains with ERTS. In: PROCEEDINGS OF THE THIRD EARTH RESOURCES TECHNOLOGY SATELLITE-1 SYMPOSIUM, Greenbelt, NASA SP-351, U.S. Government Printing Office, Washington, D.C., 1973, vol. 1, pp. 309–317.

SALVADOR, E.; CAVALLARO, A.; EBRAHIMI, T. Cast shadow segmentation using invariant colour feature. **Computer Vision and Image Understand**, v.95, 2004, pp. 238-259.

SANTOS, D. R. Extração semi-automática de edificações com análise do modelo numérico de elevações. 2002. 150f. Dissertação (Mestrado em Ciências Cartográficas). Programa de Pós-graduação em Ciências Cartográficas, FCT/UNESP

SANTOS, D. R.; DALMOLIN, Q.; BASSO, M. A. Detecção automática de sombras em imagens de alta resolução . **Boletim de Ciências Geodésicas**, v.12, n.1, 2006, pp.87-99.

SCHIEWE, J. Improving the integration of digital surface models. In: INTERNATIONAL ARCHIVES OF PHOTOGRAMMETRY AND REMOTE SENSING, Amsterdam, 2000 Vol. 33, Part B3, pp. 806 – 814.

SERRA, J. **Image analysis and Mathematical Morphology**. London: Academic Press, 1982. 610p.

SHUFELT, J. A. Performance evaluation and analysis of monocular building extraction from

aerial imagery. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v.21, n.4, 1999, pp. 311–326.

SITHOLE, G.; VOSSSELMAN, G. Filtering of airborne laser scanner data based on segmented point clouds. In: ISPRS: WORKSHOP – LASER SCANNING 2005, Enschede, the Netherlands, 2005, September 12-14, WG III/3, III/4, V/3, pp. 66 – 71.

SOHN, G. Extraction of buildings from high-resolution satellite data and LIDAR. In: PROCEEDINGS OF THE XXTH INTERNATIONAL SOCIETY FOR PHOTOGRAMMETRY AND REMOTE SENSING, Istanbul, 2004, 12–23 July, Commission 3, pp. 343 – 348.

SOILLE, P. **Morphological image analysis: principles and applications**. Berlin: Springer-Verlag, 1999. 316p.

STITELER, W. M. Using genetic algorithms to select tree crown templates for finding trees in digital imagery. In: ASPRS-2000 ANNUAL CONFERENCE PROCEEDINGS, Washington DC, 2000, May 22-26. Disponível em CD-ROM, não paginado.

SUSUKI, A.; SHIO, A.; ARAI, H.; OHTSUKA, S. Dynamic shadow compensation of aerial images based on color and spatial analysis. In: PROCEEDINGS OF 15TH INT. CONF. PATTERN RECOGNITION, Barcelona, 2000, September 3–7, pp. 317–320.

TAILLANDIER, F.; DERICHE, R. Automatic building reconstruction from aerial images: a generic Bayesian framework. In: PROCEEDINGS OF THE XXTH INTERNATIONAL SOCIETY FOR PHOTOGRAMMETRY AND REMOTE SENSING, Istanbul, 2004, Commission 3. 12–23 July, pp. 343 – 348.

TSAI, V. J. D. Automatic shadow detection and radiometric restoration on digital Aerial images. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS): LEARNING FROM EARTH'S SHAPES AND COLOURS, Toulouse, 2003, July 21-25, vol. 2, pp. 732-733.

TSAI, V.J.D. A comparative study on shadow compensation of color aerial images in invariant color models. **IEEE Transactions on Geoscience and Remote Sensing**, v.44, n.6,

2006. pp.1661- 167.

TSO, B.; MATHER, P. M. **Classification methods for remotely sensed data**. New York: Taylor & Francis Inc, 2001. 332p.

VINCENT, L. Morphological grayscale reconstruction in image analysis: applications and efficient algorithms. **IEEE Transactions on Image Processing**, v. 2, n.2, 1993, pp. 176-201.

VINCENT, L.; SOILLE, P. Watersheds in digital spaces: an efficient algorithm based on immersion simulations. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v.13, 1991, pp. 583 – 598.

VÖGTLE, T.; STEINLE E. 3D modelling of buildings using laser scanning and spectral information. In: PROCEEDINGS OF THE XIXTH INTERNATIONAL SOCIETY FOR PHOTOGRAMMETRY AND REMOTE SENSING, Amsterdam, 2000, 16-23 July. Vol. XXXIII, Part B3/2, pp. 926 – 933.

VOSSelman, G. Slope based filtering of laser altimetry data. In: INTERNATIONAL ARCHIVES OF PHOTOGRAMMETRY & REMOTE SENSING, Amsterdam, 2000, vol. 33, part B3, pp. 935–942.

WANG, Y.; MADANI, M. Automatic detection of shadow points in digital images for automatic triangulation. In: XXTH ISPRS CONGRESS: GEO-IMAGERY BRIDGING CONTINENTS, Istanbul, 2004, July 12-23, Commission 3, pp. 91 – 95.

WANG, Z. Building extraction and reconstruction from LIDAR data. In: PROCEEDINGS OF THE XIXth INTERNATIONAL SOCIETY FOR PHOTOGRAMMETRY AND REMOTE SENSING, Amsterdam, 2000, 16-23 July. Vol. XXXIII, Part B3/2, pp. 957 – 964.

WEIDNER, U.; FÖRSTNER, W. Towards automatic building extraction from high-resolution digital elevation models, **ISPRS Journal of Photogrammetry & Remote Sensing**, v.50, 1995, pp. 38 – 49.

WOESTYNE, V.; JORDAN, M.; MOONS, T.; CORD, M. A software system for efficient DEM segmentation and DTM estimation in complex urban areas. In: XXth ISPRS CONGRESS: GEO-IMAGERY BRIDGING CONTINENTS, Istanbul, 2004, July 12-23,

Commission 3, pp. 134 – 139.

ZANIN, R. B.; VALE, G. M.; DAL POZ, A. P.; POLIDORIO, A. M. A utilização de índices de artificialidade para extração de rodovias em imagens coloridas. 2005. IV Colóquio Brasileiro de Ciências Geodésicas, Curitiba, maio 16 – 20. Disponível em CD-ROM não paginado.

ZHANG, K.; CHEN, S.; WHITMAN, D.; SHYU, M.; YAN, J.; ZHANG, C. A progressive morphological filter for removing non-ground measurements from airborne LIDAR data. **IEEE Transaction on Geoscience and Remote Sensing**, v.41, n.4, 2003, pp. 872-882.

ZHANG, Y.; WANG, R. Multi-resolution and multi-spectral image fusion for urban object extraction. XXth ISPRS CONGRESS: GEO-IMAGERY BRIDGING CONTINENTS, Istanbul, 2004, July 12-23, Commission 3, pp. 960 – 966.

ZIMMERMANN, P. A new framework for automatic building detection analysing multiple cue data. In: PROCEEDINGS OF THE XIXth INTERNATIONAL SOCIETY FOR PHOTOGRAMMETRY AND REMOTE SENSING, Amsterdam, 2000, 16-23 July. Vol. XXXIII, Part B3/2, pp. 1063 – 1070.