

Universidade Federal do Ceará
Centro de Tecnologia
Departamento de Engenharia de Teleinformática
Programa de Pós-Graduação em Engenharia de Teleinformática

Eduardo Alves de Carvalho

**SEGMENTAÇÃO DE IMAGENS DE RADAR DE ABERTURA SINTÉTICA POR
CRESCIMENTO E FUSÃO ESTATÍSTICA DE REGIÕES**

Fortaleza/CE
Maio, 2005



Universidade Federal do Ceará
Centro de Tecnologia
Departamento de Engenharia de Teleinformática
Programa de Pós-Graduação em Engenharia de Teleinformática

Eduardo Alves de Carvalho

**SEGMENTAÇÃO DE IMAGENS DE RADAR DE ABERTURA SINTÉTICA POR
CRESCIMENTO E FUSÃO ESTATÍSTICA DE REGIÕES**

Orientadora:

Fátima Nelsizeuma Sombra de Medeiros

Dissertação submetida à Coordenação do Programa de Pós-graduação em Engenharia de Teleinformática da Universidade Federal do Ceará, como requisito para obtenção do grau de *Mestre em Engenharia de Teleinformática - Área de Concentração em Sinais e Sistemas*.

Fortaleza/CE
Maio, 2005

Esta dissertação foi julgada adequada para a obtenção do título de *Mestre em Engenharia de Teleinformática*, área de concentração em *Sinais e Sistemas*, e aprovada em sua forma final pelo Programa de Pós-graduação em Engenharia de Teleinformática da Universidade Federal do Ceará.

A citação e a reprodução do todo ou de qualquer parte desta obra são permitidas, desde que feitas em conformidade com as normas da ética científica.

Eduardo Alves de Carvalho

SEGMENTAÇÃO DE IMAGENS DE RADAR DE ABERTURA SINTÉTICA POR CRESCIMENTO E FUSÃO ESTATÍSTICA DE REGIÕES

Membros da Banca Examinadora:

Profa. Dra. Fátima Nelsizeuma Sombra de Medeiros
Universidade Federal do Ceará - UFC

Prof. Dr. Marcos Cordeiro D'Ornellas
Universidade Federal de Santa Maria - UFSM

Prof. Dr. Paulo César Cortez
Universidade Federal do Ceará - UFC

Prof. Dr. Sérgio Antenor de Carvalho
Universidade Federal do Ceará - UFC

Fortaleza/CE, 25 de maio de 2005.

Dedico esta obra à minha família.

Agradecimentos

Agradeço a meus pais, irmãs e irmãos, pelos ensinamentos e o apoio dedicados a mim, apesar da distância.

A Deus, a quem confiamos a direção de nossas vidas, pela força nos momentos mais difíceis e pela harmonia nos momentos de tranquilidade.

À Lúcia Maria, pelo carinho e companhia que a mim tem dedicado, a quem desejo muito sucesso, paz, amor e felicidade.

Agradeço à Profa. Fátima Sombra pela orientação e atenção prestadas durante a preparação deste trabalho. Gostaria também de agradecer a todos os funcionários da UFC, ao Governo Brasileiro e ao CNPq, pelo apoio financeiro durante a vigência deste trabalho.

Agradeço ao Prof. Alejandro Frery (UFAL) por ceder algumas amostras de imagens SAR e aos membros das bancas examinadoras pelas sugestões, elogios e críticas: Profs. Cortez, Rubens, Sérgio Antenor e Marcos D’Ornellas. A todos os demais professores dos cursos de graduação e de pós-graduação em Eng. Elétrica e Eng. de Teleinformática da UFC, pela convivência e dedicação ofertada. Muito obrigado!

A todos os integrantes e ex-integrantes do Grupo de Processamento de Imagens, pelos anos de convivência e amizade, em especial Cornélia Janayna, Priscila Calíope, Régia Talina, Régis Marques. Ao amigo Rodrigo Costa, que muito ajudou no desenvolvimento do algoritmo chave de análise de vizinhança deste trabalho. Não poderia esquecer-me também de Jilseph, com quem partilhei boas conversas ao entrar no GPI. Gostaria de mencionar ainda os que conheci logo após: Iális, Gilson, Iury e Karinne. Aquele abraço aos “quânticos” do Laboratório de Comunicações Quânticas – Prof. Rubens, George e Fábio. Sucesso a todos!

Obrigado também aos amigos mais próximos, com quem tive bons momentos em casa, em especial a Criscila Alexandre, Carla Gondim, Aminadabe, DJ Flávio Mancini e Cláudio Barbosa. Aquele abraço aos amigos Mardem, Marcos Gomes, Adilson, Fareid e Rita. Felicidades a todos.

Àqueles que porventura não tenha mencionado, meus sinceros agradecimentos.



Resumo

A cobertura regular de quase todo o planeta por sistemas de radar de abertura sintética (*synthetic aperture radar* – SAR) orbitais e o uso de sistemas aerotransportados têm propiciado novos meios para obter informações através do sensoriamento remoto de várias regiões de nosso planeta, muitas delas inacessíveis. Este trabalho trata do processamento de imagens digitais geradas por radar de abertura sintética, especificamente da segmentação, que consiste do isolamento ou particionamento dos objetos relevantes presentes em uma cena. A segmentação de imagens digitais visa melhorar a interpretação das mesmas em procedimentos subsequentes. As imagens SAR são corrompidas por ruído coerente, conhecido por *speckle*, que mascara pequenos detalhes e zonas de transição entre os objetos. Tal ruído é inerente ao processo de formação dessas imagens e dificulta tarefas como a segmentação automática dos objetos existentes e a identificação de seus contornos. Uma possibilidade para efetivar a segmentação de imagens SAR consiste na filtragem preliminar do ruído *speckle*, como etapa de tratamento dos dados. A outra possibilidade, aplicada neste trabalho, consiste em segmentar diretamente a imagem ruidosa, usando seus pixels originais como fonte de informação. Para isso, é desenvolvida uma metodologia de segmentação baseada em crescimento e fusão estatística de regiões, que requer alguns parâmetros para controlar o processo. As vantagens da utilização dos dados originais para realizar a segmentação de imagens de radar são a eliminação de etapas de pré-processamento e o favorecimento da detecção das estruturas presentes nas mesmas. É realizada uma avaliação qualitativa e quantitativa das imagens segmentadas, sob diferentes situações, aplicando a técnica proposta em imagens de teste contaminadas artificialmente com ruído multiplicativo. Este segmentador é aplicado também no processamento de imagens SAR reais e os resultados são promissores.

Palavras-chave: radar de abertura sintética, segmentação, imagens SAR, crescimento de regiões, fusão de regiões, testes de hipóteses, simulação estocástica, ruído *speckle*.

Abstract

The regular coverage of the planet surface by spaceborne synthetic aperture radar (SAR) and also airborne systems have provided alternative means to gather remote sensing information of various regions of the planet, even of inaccessible areas. This work deals with the digital processing of synthetic aperture radar imagery, where segmentation is the main subject. It consists of isolating or partitioning relevant objects in a scene, aiming at improving image interpretation and understanding in subsequent tasks. SAR images are contaminated by coherent noise, known as *speckle*, which masks small details and transition zones among the objects. Such a noise is inherent in radar image generation process, making difficult tasks like automatic segmentation of the objects, as well as their contour identification. To segment radar images, one possible way is to apply speckle filtering before segmentation. Another one, applied in this work, is to perform noisy image segmentation using the original SAR pixels as input data, without any preprocessing, such as filtering. To provide segmentation, an algorithm based on region growing and statistical region merging has been developed, which requires some parameters to control the process. This task presents some advantages, as long as it eliminates preprocessing steps and favors the detection of the image structures, since original pixel information is exploited. A qualitative and quantitative performance evaluation of the segmented images is also executed, under different situations, by applying the proposed technique to simulated images corrupted with multiplicative noise. This segmentation method is also applied to real SAR images and the produced results are promising.

Keywords: synthetic aperture radar, segmentation, SAR images, region growing, region merging, hypothesis tests, data simulation, *speckle* noise.

Lista de Figuras

1.1	Emissão de pulsos de radar e suas interações com os alvos	4
1.2	Esquema de varredura e imageamento simplificado de radares SAR.	6
1.3	Obtenção das componentes em fase e em quadratura de sinais de radar.	8
2.1	Imagens de teste <i>kk</i> , <i>imgcartoon</i> e respectivos mapas de bordas	16
2.2	Imagens de teste contaminadas com ruído multiplicativo	17
2.3	Imagem de teste <i>codbarras</i> e suas versões ruidosas	18
2.4	Visão 3D de um detalhe da imagem <i>codbarras</i>	19
3.1	Diagrama de blocos do algoritmo de segmentação proposto.	22
3.2	Vizinhança de um pixel semente de coordenadas (i, j)	23
3.3	Representação de uma janela adaptativa	26
3.4	Exemplo de matriz de rótulos	29
3.5	Visualização de uma máscara gerada pelo algoritmo de crescimento de regiões	29
3.6	Esquema proposto para processamento de pixels isolados	30
3.7	Detalhe da imagem <i>Caçapava</i> e o mapa de bordas com 3982 segmentos	31
3.8	União de segmentos por análise hierárquica	32
3.9	Exemplo de partição de uma imagem.	33
3.10	Exemplo de segmentação hierárquica	34
3.11	Árvore representando a seqüência de uniões dos nós.	35
3.12	Diagrama representativo do processo de segmentação	39
3.13	Exemplo de segmentação aplicando o teste t de Student	40
3.14	Exemplo de segmentação aplicando o teste t de variâncias desiguais e segmentação com <i>crinkle</i>	41
3.15	Amostras locais de pixels de fronteira	42
3.16	Segmentação realizada com o novo critério de custo e teste t	43
3.17	Segmentação com o novo critério de custo e teste t de variâncias desiguais	44
3.18	Gráfico ilustrativo do teste de Kolmogorov-Smirnov	45
3.19	Fusão de regiões usando o critério de custo proposto, combinado ao teste de Kolmogorov-Smirnov	46
4.1	Distorções produzidas por três segmentadores fictícios	49
4.2	Exemplo de distorções provocadas por segmentadores	52
4.3	Bordas ideais e bordas reais geradas por um segmentador	52
4.4	Distâncias euclidianas entre pixels de borda de duas segmentações	53
4.5	Identificação dos objetos das imagens sintéticas <i>kk</i> e de <i>imgcartoon</i>	54
4.6	Metodologia de avaliação de segmentadores	55
4.7	Segmentações geradas com $p_0 = 10^{-3}$ para as imagens com $n = 1$ visada	56
4.8	Detecção de bordas nas imagens simuladas com 1 visada	57
4.9	Segmentações geradas com $p_0 = 10^{-3}$ e $n = 3$ visadas	58
4.10	Detecção de bordas nas imagens simuladas com 3 visadas	59

4.11	Segmentações geradas com $p_0 = 10^{-3}$ e $n = 5$ visadas	60
4.12	Detecção de bordas nas imagens simuladas com 5 visadas	60
4.13	Medidas de segmentação de <i>kk</i> para $p_0 = 10^{-3}$ e $n = 1, 3, 5$ visadas	61
4.14	Medidas de macroajuste de <i>kk</i> para $p_0 = 10^{-3}$ e $n = 1, 3, 5$ visadas	62
4.15	Medidas de segmentação de <i>imgcartoon</i> para $p_0 = 10^{-3}$ e $n = 1, 3, 5$ visadas	63
4.16	Medidas de macroajuste de <i>imgcartoon</i> para $p_0 = 10^{-3}$ e $n = 1, 3, 5$ visadas	64
4.17	Detalhe ampliado da imagem <i>imgcartoon</i>	64
4.18	Medidas de ajuste geral das imagens de teste com $p_0 = 10^{-3}$	65
4.19	Segmentações das imagens de teste geradas com $p_0 = 10^{-5}$ e $n = 1$ visada	66
4.20	Segmentações das imagens de teste geradas com $p_0 = 10^{-5}$ e $n = 3$ visadas	66
4.21	Segmentações das imagens de teste geradas com $p_0 = 10^{-5}$ e $n = 5$ visadas	67
4.22	Medidas de segmentação de <i>kk</i> com $p_0 = 10^{-5}$ e $n = 1, 3$ e 5 visadas	68
4.23	Medidas de macroajuste de <i>kk</i> com $p_0 = 10^{-5}$ e $n = 1, 3$ e 5 visadas	69
4.24	Medidas de segmentação de <i>imgcartoon</i> com $p_0 = 10^{-5}$ e $n = 1, 3$ e 5 visadas	70
4.25	Medidas de macroajuste de <i>imgcartoon</i> com $p_0 = 10^{-5}$ e $n = 1, 3$ e 5 visadas	71
4.26	Medidas de ajuste geral de <i>kk</i> e de <i>imgcartoon</i> com $p_0 = 10^{-5}$	71
4.27	Segmentações das imagens de teste geradas com $p_0 = 10^{-6}$ e $n = 1, 3$ e 5 visadas	72
4.28	Medidas de segmentação de <i>kk</i> com $p_0 = 10^{-6}$ e $n = 1, 3$ e 5 visadas	73
4.29	Evolução da quantidade de pixels mal segmentados para a imagem <i>kk</i>	74
4.30	Medidas de macroajuste de <i>kk</i> com $p_0 = 10^{-6}$ e $n = 1, 3$ e 5 visadas	74
4.31	Medidas de segmentação de <i>imgcartoon</i> com $p_0 = 10^{-6}$ e $n = 1, 3$ e 5 visadas	75
4.32	Medidas de ajuste geral para <i>kk</i> e <i>imgcartoon</i> com $p_0 = 10^{-6}$	76
4.33	Imagem <i>codbarras</i> contaminada com ruído multiplicativo	78
4.34	Resultados da segmentação de <i>codbarras</i> com $p_0 = 10^{-4}$	78
4.35	Resultados da segmentação de <i>codbarras</i> com $p_0 = 10^{-5}$	79
4.36	Resultados da segmentação de <i>codbarras</i> com $p_0 = 10^{-6}$	79
4.37	Imagens-razão e histogramas das segmentações de <i>codbarras</i>	80
4.38	Medida de ajuste geral para a segmentação de <i>codbarras</i>	80
4.39	Mapas de bordas correspondentes às segmentações de <i>Caçapava</i>	82
4.40	Imagem SAR <i>Caçapava</i> , 1 visada, amplitude.	83
4.41	Imagem SAR <i>Stanwick</i> , com número de visadas estimado em $n = 3, 36$	84
4.42	Imagem temática da segmentação da imagem SAR <i>Stanwick</i> , com $p_0 = 0, 0001$	85
4.43	Mapa de bordas da imagem SAR <i>Stanwick</i> com 1728 segmentos, $p_0 = 0, 0001$	86
4.44	Imagem SAR <i>Stanwick</i> , de dimensões 768×538 pixels, gerada em amplitude.	87
4.45	Imagem temática da segmentação da imagem SAR <i>Stanwick</i> , com $p_0 = 10^{-7}$	88
4.46	Mapa de bordas da imagem SAR <i>Stanwick</i> , com 671 segmentos ($p_0 = 10^{-7}$).	89
4.47	Imagem SAR <i>Stanwick</i>	90
4.48	Segmentações da imagem SAR <i>Pedazo</i> , com $p_0 = 10^{-5}$ e $p_0 = 10^{-6}$	91
4.49	Segmentações da imagem SAR <i>Pedazo</i> , com $p_0 = 10^{-7}$ e $p_0 = 10^{-8}$	92
4.50	Segmentações de imagem SAR contendo uma mancha de óleo	93
4.51	Segmentações da imagem SAR <i>Zone</i>	94
4.52	Mapa de bordas de um detalhe da imagem <i>Flevoland</i>	95
4.53	Recorte de 512×512 pixels da imagem <i>Flevoland</i>	96
4.54	Imagem temática relativa à segmentação da imagem <i>Flevoland</i> , com $p_0 = 10^{-5}$	97
4.55	Mapa de bordas da imagem <i>Sar580</i> , com $p_0 = 10^{-7}$ e $p_0 = 10^{-8}$	98
4.56	Imagem <i>Sar580</i> , gerada em banda L, 512×512 pixels.	99
4.57	Mapas de bordas da imagem <i>Sar580</i> com $p_0 = 10^{-6}$ e $p_0 = 10^{-8}$	100
4.58	Imagem <i>Sar580</i> , gerada em banda X, 512×512 pixels.	101

Lista de Tabelas

2.1	Tipos de regiões e modelos para os retornos SAR em amplitude, n visadas . . .	13
2.2	Valores do parâmetro α da distribuição G-Amplitude Zero	16
3.1	Exemplo de tabela de custos	36
4.1	Medidas de discrepância para avaliação de segmentadores	54
4.2	Tipos de alvos encontrados na imagem simulada <i>imgcartoon</i>	55
4.3	Número estimado de visadas da imagem contaminada <i>imgcartoon</i>	55
A.1	Parâmetros de simulação da imagem <i>kk</i> , amplitude, $n = 1$ visada.	112
A.2	Parâmetros de simulação da imagem <i>kk</i> , amplitude, $n = 3$ visadas.	112
A.3	Parâmetros de simulação da imagem <i>kk</i> , amplitude, $n = 5$ visadas.	112
A.4	Parâmetros de simulação da imagem <i>imgcartoon</i> , amplitude, $n = 1$ visada. . . .	113
A.5	Parâmetros de simulação da imagem <i>imgcartoon</i> , amplitude, $n = 3$ visadas. . . .	113
A.6	Parâmetros de simulação da imagem <i>imgcartoon</i> , amplitude, $n = 5$ visadas. . . .	114
A.7	Medidas de segmentação de <i>kk</i> para $n = 1, 3$ e 5 visadas e $p_0 = 10^{-3}$	115
A.8	Medidas de segmentação de <i>imgcartoon</i> , $n = 1$ visada, $p_0 = 10^{-3}$	116
A.9	Medidas de segmentação de <i>imgcartoon</i> , $n = 3$ visadas, $p_0 = 10^{-3}$	116
A.10	Medidas de segmentação de <i>imgcartoon</i> , $n = 5$ visadas, $p_0 = 10^{-3}$	117
A.11	Medidas de segmentação de <i>kk</i> para $n = 1, 3$ e 5 visadas e $p_0 = 10^{-5}$	117
A.12	Medidas de segmentação de <i>imgcartoon</i> , $n = 1$ visada, $p_0 = 10^{-5}$	118
A.13	Medidas de segmentação de <i>imgcartoon</i> , $n = 3$ visadas, $p_0 = 10^{-5}$	118
A.14	Medidas de segmentação de <i>imgcartoon</i> , $n = 5$ visadas, $p_0 = 10^{-5}$	119
A.15	Medidas de segmentação de <i>kk</i> para $n = 1, 3$ e 5 visadas e $p_0 = 10^{-6}$	120
A.16	Medidas de segmentação de <i>imgcartoon</i> , 1 visada, $p_0 = 10^{-6}$	120
A.17	Medidas de segmentação de <i>imgcartoon</i> , 3 visadas, $p_0 = 10^{-6}$	121
A.18	Medidas de segmentação de <i>imgcartoon</i> , 5 visadas, $p_0 = 10^{-6}$	121

Sumário

1	Visão Geral Sobre Imagens SAR	4
1.1	Formação de Imagens de Radar	4
1.2	O Conceito de Abertura Sintética	7
1.3	Tipos de Imagens SAR	7
2	Modelagem de Dados SAR	10
2.1	Introdução	10
2.2	O Modelo Multiplicativo	10
2.3	Geração de Variáveis Aleatórias e Imagens Simuladas em Amplitude	12
2.3.1	Modelagem de áreas homogêneas	14
2.3.2	Modelagem de áreas heterogêneas	14
2.3.3	Modelagem de áreas homogêneas, heterogêneas ou extremamente heterogêneas	15
2.3.4	Imagens de teste contaminadas artificialmente por ruído <i>speckle</i>	16
3	Segmentação de Imagens SAR por Crescimento e Fusão Estatística de Regiões	20
3.1	Introdução	20
3.2	Crescimento de Regiões Guiado pela Análise do Coeficiente de Variação	22
3.3	Desenvolvimento do Algoritmo de Crescimento de Regiões Estatístico	25
3.4	Restrições para o Crescimento de Regiões	27
3.5	Segmentação Hierárquica de Imagens	31
3.6	Fusão de Regiões por Testes de Hipóteses	37
3.6.1	Testes de hipóteses	37
3.6.2	Teste t de Student	37
3.6.3	Teste t de variâncias desiguais	38
3.6.4	Segmentação empregando diferentes critérios de custo e testes de hipóteses	38
3.6.5	Proposta de um critério de custo baseado em médias locais	41
3.6.6	Teste de Kolmogorov-Smirnov	44
4	Avaliação e Discussão dos Resultados de Segmentação	48
4.1	Introdução	48
4.2	Medidas de Avaliação de Segmentação	48
4.2.1	Medidas de discrepância baseadas no ajuste de regiões	49
4.2.2	Medidas de discrepância baseadas no ajuste de bordas	51
4.3	Descrição das Imagens Simuladas e Metodologia de Avaliação	54
4.4	Avaliação de Segmentação - Etapa I	56
4.4.1	Resultados de segmentação com parâmetro $p_0 = 10^{-3}$	56
4.4.2	Medidas de desempenho com parâmetro $p_0 = 10^{-3}$	61
4.4.3	Resultados de segmentação com parâmetro $p_0 = 10^{-5}$	65

4.4.4	Medidas de desempenho com parâmetro $p_0 = 10^{-5}$	67
4.4.5	Resultados de segmentação com parâmetro $p_0 = 10^{-6}$	72
4.4.6	Medidas de desempenho com parâmetro $p_0 = 10^{-6}$	73
4.5	Avaliação de Segmentação - Etapa II	77
4.6	Análise da Segmentação de Imagens Sintéticas	80
4.7	Segmentação de Imagens SAR Reais	81
4.8	Discussão Geral do Método Proposto	102
5	Conclusões e Perspectivas	104
5.1	Conclusões	104
5.2	Contribuições e Trabalhos Futuros	105
A	Parâmetros das Imagens Simuladas e Medidas de Segmentação	112
A.1	Parâmetros Descritivos das Imagens Simuladas <i>kk</i> e <i>imgcartoon</i>	112
A.2	Medidas de Discrepância para as Segmentações de <i>kk</i> e <i>imgcartoon</i>	115
A.2.1	Medidas de discrepância com $p_0 = 10^{-3}$	115
A.2.2	Medidas de discrepância com $p_0 = 10^{-5}$	117
A.2.3	Medidas de discrepância com $p_0 = 10^{-6}$	120

Introdução

As imagens de sensoriamento são captadas por sistemas de imageamento instalados em satélites, sondas e em aeronaves. Devido à ampla cobertura realizada a partir de altitudes que variam de centenas de metros a centenas de quilômetros, estas imagens contribuem para a melhor compreensão de fenômenos atmosféricos, mapeamento e monitoração do uso do solo, avaliação da extensão de desmatamento em regiões, evolução geográfica, avaliação de crescimento urbano, acompanhamento e discriminação de diferentes cultivos, gerenciamento de recursos naturais, entre outras aplicações.

Depois de adquiridas, estas imagens precisam ser processadas para que as informações relevantes sejam extraídas. O processamento digital de imagens pode ser definido como a manipulação e análise de imagens adquiridas por sistemas imageadores, com o objetivo de alteração e entendimento dos dados (pixels) representativos das cenas. Este processamento consiste de técnicas computacionais e de algoritmos usados para gerar novas imagens, as quais particularizam um tipo de informação que se deseja analisar. Este tipo particular de informação consiste, por exemplo, na identificação dos objetos importantes que existem na imagem, com vistas a facilitar a compreensão de sua estrutura. Uma vez identificados tais objetos relevantes, seus contornos podem ser obtidos e podem ainda ser classificados como água, plantações, floresta, etc. Em muitas situações, antes de serem extraídas as informações, as imagens requerem um pré-processamento ou restauração de dados. Estes procedimentos visam produzir imagens com melhor aspecto visual, recuperar informações e facilitar outros processamentos seguintes.

Quando se menciona as palavras ‘sensoriamento remoto’, vem logo em mente o processamento de imagens, tais como aquelas obtidas de uma região qualquer do planeta. Tipicamente, estas imagens são fotografias aéreas ou imagens obtidas por satélites em órbita. No entanto, o sensoriamento remoto utiliza-se de uma gama de dispositivos (sensores) e técnicas de processamento da informação.

Um destes tipos de sensores ou dispositivos de imageamento é o radar. Nas últimas décadas, as imagens de radar têm atraído crescente interesse da comunidade científica, devido às características peculiares que as mesmas apresentam para alguns tipos de aplicações. Uma grande vantagem do imageamento realizado por radar é sua capacidade de operação independente de ser dia ou noite, ou de condições climáticas adversas que porventura haja no local imageado, como constante encobrimento por nuvens. É possível ainda citar sua capacidade de ressaltar a rugosidade superficial do local imageado e penetrar o solo em alguns casos [1].

No entanto, devido à natureza das emissões eletromagnéticas de radar, estas imagens estão sempre associadas a um tipo de ruído conhecido como *speckle*, também denominado ruído de coerência, por estar associado a interferências geradas no sensor do radar. Este ruído causa dificuldades na extração automática das informações contidas nas imagens. Quando possível, faz-se uso de outros tipos de imagens geradas por outros sensores (como os óticos, por exemplo), para facilitar a extração de informações de imagens de radar adquiridas de uma determinada região. Algumas linhas de pesquisa têm se preocupado com a integração de dados de radar com aqueles gerados por outros sensores.

Na extração de informações de imagens digitais, a segmentação possui um papel muito importante. Ela pode ser definida como uma etapa de alto nível no processamento de imagens para realizar a decomposição de uma cena em seus elementos principais. Daí, outras etapas podem usufruir das informações geradas pela segmentação, como é o caso da classificação, da extração de bordas e contornos, além do reconhecimento de padrões. Este procedimento permite identificar qual é a natureza dos objetos segmentados com base em características previamente conhecidas.

Um importante aspecto do desenvolvimento de novos algoritmos de segmentação é sua vasta aplicação nas áreas de avaliação e gerenciamento de recursos hídricos [2, 3], avaliação da eficiência de sistemas de irrigação, planejamento e monitoração de safra agrícola [4], mapeamento de reflorestamento, identificação de áreas com construções [5], detecção de alvos tais como navios [6, 7], entre outras.

Entre as aplicações mais conhecidas para imagens de radar, pode-se relacionar a identificação de contornos em regiões costeiras, a detecção de manchas de óleo nas proximidades de costa e em alto mar, o levantamento de redes de rodovias e a detecção de navios em atividades de pesca ilegal. Em regiões costeiras, este tipo de imagem permite também o estudo evolutivo da deposição de materiais nos estuários de grandes rios [8], para os quais as mudanças morfológicas provocadas nestas áreas são de grande interesse. Os estudos sobre a evolução de mudanças nestas regiões têm utilidade em mapeamento e navegação, acompanhamento de inundações e proteção de áreas ambientais costeiras. As mudanças em áreas de estuário ocorrem com maior velocidade do que em áreas costeiras comuns [9]. Desse modo, uma constante monitoração destes fenômenos faz-se necessária, a fim de que medidas sejam tomadas para reverter este quadro, caso as influências sejam antropogênicas¹ e prejudiciais ao meio ambiente.

Objetivos e Estrutura do Trabalho

O objetivo deste trabalho é estudar, desenvolver e implementar técnicas de segmentação lineares e não-lineares para imagens de radar de abertura sintética (ou abreviadamente SAR), oriundas do sensoriamento remoto de áreas terrestres.

A segmentação é uma vertente do processamento de imagens digitais e objetiva particionar uma imagem digital em seus objetos constituintes, de modo a definir a estrutura da mesma. Uma vez localizados os objetos relevantes em uma imagem segmentada, muitas vezes é necessário verificar se suas dimensões e contornos condizem com uma imagem denominada segmentação de referência (ou verdade terrestre). Esta avaliação é imprescindível para analisar o desempenho e a robustez do algoritmo de segmentação perante imagens reais. Para isso, várias medidas de segmentação são propostas na literatura para avaliar o desempenho de segmentadores e, possivelmente, compará-los entre si.

Este trabalho se restringe a segmentação de imagens SAR, sendo que para este fim é desenvolvido um algoritmo de segmentação que utiliza a estatística do ruído *speckle* associado a técnicas conhecidas de segmentação de imagens. Para a melhor apresentação do estudo desenvolvido, o restante deste trabalho está estruturado da seguinte maneira:

- No Capítulo 1 é realizada uma breve apresentação do processo de imageamento por radar de abertura sintética (SAR) e como este dispositivo é capaz de gerar imagens de alta resolução de áreas terrenas (e até de outros planetas), o que lhe propicia certo destaque em aplicações na área de sensoriamento remoto;

¹Ações que são causadas por atividades humanas.

- O Capítulo 2 introduz os modelos utilizados nesta dissertação para contaminar artificialmente imagens sintéticas com ruído *speckle*, sendo abordadas algumas distribuições advindas do modelo multiplicativo. Este modelo é comumente adotado para explicar como são gerados os pixels ruidosos de imagens SAR e as distribuições utilizadas permitem simular pixels característicos de diferentes tipos de superfícies, particularmente na detecção em amplitude;
- O Capítulo 3 trata da metodologia proposta nesta dissertação para o desenvolvimento de um segmentador baseado em crescimento e fusão estatística de regiões;
- No Capítulo 4 são descritas algumas medidas de avaliação de desempenho de segmentação para o método proposto, utilizando as imagens contaminadas artificialmente. A segmentação ideal de cada imagem de teste é conhecida, sendo comparada com as versões segmentadas, segundo a metodologia proposta. Este capítulo também apresenta alguns resultados de segmentação de imagens SAR reais;
- Para finalizar, as conclusões e perspectivas de trabalhos futuros estão apresentadas no Capítulo 5.

Capítulo 1

Visão Geral Sobre Imagens SAR

1.1 Formação de Imagens de Radar

A palavra radar é o acrônimo de *radio detection and ranging*, que significa detecção e medição por meio de ondas de rádio [10]. O radar é um dispositivo eletrônico para detecção e localização de objetos, que emite ondas eletromagnéticas em direção a uma região contendo alvos ou objetos dos quais se deseja obter informações. A utilização atual dos radares é bem mais diversificada e não contempla somente as funções de detecção de alvos e obtenção de medidas de distância. O conceito de radar lembra de imediato os dispositivos para controle de tráfego aéreo ou para controle de velocidade em rodovias. Dentre outras aplicações, destaca-se a capacidade de imageamento de áreas remotas.

As imagens de radar são obtidas por sistemas chamados de radares imageadores, que podem estar embarcados em aeronaves ou em satélites. O transmissor do radar emite ondas eletromagnéticas (pulsos na faixa de microondas) e estas chocam-se contra alvos terrenos existentes na região ‘iluminada’. Os alvos provocam uma série de fenômenos nos pulsos emanados do sistema radiante do radar, tais como a absorção, a difração e a reflexão. O fenômeno de reflexão está ilustrado na Figura 1.1¹, que representa um radar embarcado em um satélite.




Figura 1.1: Emissão de pulsos por um radar imageador e as interações dos mesmos com alvos terrenos.

Um sistema de radar convencional deve ser capaz de captar as ondas refletidas pelos alvos e, a partir dos retornos, medir a distância dos mesmos até o radar; ele deve ainda calcular suas velocidades de aproximação ou de afastamento. Isto é essencial, caso os alvos estejam se movimentando em relação ao sistema de medição. Alguns tipos especiais de radares podem até mesmo formar imagens dos objetos existentes em uma região iluminada, cuja classe é conhecida como imageadores. Entre eles, destaca-se o radar de abertura sintética.

Antes da invenção do sistema imageador de abertura sintética no início da década de 50, o radar já tinha reconhecimento e utilização prática para a detecção, lo-

¹Figura obtida de www.asf.alaska.edu/user_serv/sar_faq.html, visitada em 29.out.02.

calização e rastreamento de alvos, tais como aeronaves e navios. Os sistemas de radar imageadores surgiram a partir do desenvolvimento dos dispositivos que apresentavam os alvos detectados de uma região remota em tubos de raios catódicos (CRTs) [11]. Os primeiros radares, equipados com tais dispositivos de exibição, representavam os alvos sob forma de picos de amplitude do sinal emitido e dos ecos recebidos e processados, semelhantes às formas de onda mostradas em um osciloscópio. Estes sinais eram gerados através de uma varredura denominada *A-scan*, em que o tempo de atraso entre o pulso emitido e os ecos recebidos era tratado como uma dimensão. A outra dimensão, nesta representação ondulatória, corresponde à amplitude dos pulsos envolvidos. Esta técnica de varredura não oferecia informações sobre a localização direcional dos alvos, pois era apresentada somente como tempo (eixo horizontal) *versus* amplitude dos sinais (emitidos e recebidos - eixo vertical).

Melhorias no formato de representação da tela *A-scan* levaram à criação do CRT de varredura angular ou *B-scan*. Neste formato de exibição, uma imagem é apresentada na tela à medida que o radar varre o espaço à procura de alvos, por meio de sua antena giratória. Mais tarde, outros aprimoramentos neste tipo de indicador angular levaram à criação do PPI (indicador plano de posição). Depois, telas de fósforo foram desenvolvidas para a apresentação de imagens em tons de cinza, por meio de circuitos eletrônicos de conversão de sinais, anexados ao PPI [11]. Este tipo de tela talvez seja a interface visual mais amigável ao operador, sendo bastante comum sua aplicação em previsão do tempo (meteorologia), controle de tráfego aéreo e em aplicações de navegação. Entretanto, os sistemas PPI não são apropriados para a maioria das aplicações em sensoriamento remoto, por apresentarem baixa resolução [1].

Os avanços na representação de regiões varridas por emissões de radar, sob a forma de imagens, impulsionaram o desenvolvimento dos radares imageadores. No início da década de 50, os engenheiros verificaram que, ao invés de girar a antena de radar para emitir microondas em direção a uma área contendo alvos, ela poderia ser fixada na fuselagem de uma aeronave. Segundo o esquema de varredura mostrado pela Figura 1.2, os feixes oriundos da antena e direcionados ao solo permitem a identificação de alvos. Deste modo, seriam propiciadas maiores aberturas (o termo abertura está relacionado com as dimensões da antena e a quantidade de sinais que ela pode captar) e resoluções de imagens melhoradas nas direções de alcance e de vôo (azimute). Uma melhoria adicional introduzida foi o registro em filme dos ecos observados no CRT [12]. Assim, as informações provenientes dos alvos eram armazenadas, podendo ser processadas e analisadas posteriormente.

Desde então, este sistema de imageamento sofreu grandes avanços tecnológicos, incluindo suas versões instaladas a bordo de satélites e sondas espaciais (como a sonda Magellan [13]). O esquema de imageamento ilustrado na Figura 1.2 representa o tipo de varredura clássica para radares de visada lateral, tais como aqueles dotados da tecnologia SAR.

O modo de transmissão e recepção do radar imageador é semelhante àquele existente nos radares convencionais, em que são emitidos vários pulsos eletromagnéticos (chamados de *chirp*) durante um curto período de tempo pelo transmissor, através da antena. Depois que o transmissor pára de emitir pulsos, os circuitos da antena e do receptor são conectados para receber e processar os ecos (fase de escuta). As versões mais modernas destes dispositivos permitem varreduras direcionais mais precisas e propícias à detecção de alvos ou imageamento fino de uma região específica.




Figura 1.2: Esquema de varredura e imageamento simplificado de radares SAR.

Inicialmente, os radares imageadores tinham uso restrito às operações estratégicas militares mas, a partir dos anos 60, os geocientistas procuraram aplicar estes radares no levantamento de recursos naturais, quando surgiram novas aplicações civis.

A grande vantagem do radar imageador reside na independência de seu funcionamento em relação às condições climáticas adversas que porventura afetem o local sensoriado. O radar gera suas próprias ondas eletromagnéticas (ou seja, é um sensor ativo) e, conseqüentemente, pode ser usado durante o dia ou à noite, ou em condições em que o clima não é favorável ao processo de imageamento óptico, como em regiões com constante encobrimento de nuvens [1].

A formação de imagens no radar depende da capacidade reflexiva da matéria existente na região imageada [11]. Outros fenômenos também ocorrem durante a emissão de microondas, tais como a absorção e mudanças na polarização das ondas refletidas, cujas influências no processo de imageamento são de considerável importância. No esquema de varredura do radar de abertura sintética, o transmissor emite alguns kilowatts de energia eletromagnética em direção aos alvos distantes, e uma parte desta energia é refletida, como ilustram as Figuras 1.1 e 1.2. Ao retornarem ao radar, os ecos já possuem pouca energia e o receptor deve ser capaz de lidar com os baixíssimos níveis de sinal em meio ao ruído. Os sinais processados são transformados em tensões elétricas, cujas amplitudes e fases relativas são meticulosamente registradas como pontos claros e escuros. Assim, são geradas imagens complexas, relativas às componentes real e imaginária dos sinais elétricos associados aos ecos recebidos.

Em síntese, para produzir imagens de cenas terrestres, as ondas refletidas passam por um elaborado processamento de sinais a bordo do radar. A intensidade de reflexão dos ecos está ligada ao brilho do pixel na imagem digital resultante. O deslocamento relativo entre o radar e os alvos contidos no local sensoriado provoca desvios de frequência (fenômeno Doppler). O processamento dos sinais Doppler permite a localização dos alvos como pontos na imagem, identificados por pares de coordenadas (i, j) [11, 14].

A imagem digital é formada por este conjunto de pontos, cujo brilho $f(i, j)$ depende das intensidades de reflexão das ondas eletromagnéticas provocadas pelos alvos. Outras etapas de processamento seguem a geração preliminar dos dados a bordo do sistema de radar, sendo realizadas em estações terrenas equipadas com *hardware* e programas dedicados, de forma a tornar as imagens disponíveis comercialmente e para uso científico.

1.2 O Conceito de Abertura Sintética

Geralmente, as antenas de radares imageadores possuem formato retangular, em que seu comprimento (L) é maior que a largura (D), como indica a Figura 1.2. Sua configuração consiste de um conjunto de pequenas antenas dispostas sob forma de uma grade. Os sinais coletados por cada elemento da antena são encaminhados a um processador central, em que é realizado o somatório coerente de sinais captados pelo conjunto [11, 14].

Existem quatro princípios tecnológicos que caracterizam o sensoriamento por radar, a saber: 1) habilidade de uma antena em emitir curtos pulsos eletromagnéticos em uma direção precisa; 2) habilidade de detectar, também com precisão direcional, grande parte dos ecos atenuados e espalhados pelo alvo; 3) habilidade de medir o tempo de atraso entre emissão e detecção e calcular o alcance de um objeto e 4) habilidade de varrer através do feixe direcional e examinar uma extensa área à procura de alvos. Um quinto princípio baseia-se na análise espectral de sinais cujas fases são precisamente controladas, o que permite melhorias na aplicação dos quatro princípios anteriormente destacados. É nesta última metodologia que se concentra a essência do radar de abertura sintética.

Quando o radar está disposto em uma plataforma em movimento (satélite ou aeronave), então é possível combinar os sinais refletidos, ao longo da direção de vôo, para sintetizar uma antena de grandes dimensões (centenas de metros, por exemplo). A abertura, ou área usada para receber os ecos (sinais de retorno), é criada artificialmente durante o processamento de sinais.

É bastante custoso e proibitivo instalar grandes antenas embarcadas em plataformas no espaço, além de ser difícil manter a estabilidade das mesmas. No entanto, os pesquisadores encontraram outra maneira de obter excelente resolução, que consiste em usar o movimento da plataforma e avançadas técnicas de processamento de sinais para simular o aumento de antena. A abertura corresponde à distância que a antena física percorre, enquanto coleta informações dos alvos, sendo sintetizada a partir da combinação dos sinais armazenados ao longo da direção de vôo. Deste modo, a antena recebe ondas refletidas para formar um conjunto de imagens independentes, que são combinadas através de um elaborado processamento de sinais.

1.3 Tipos de Imagens SAR

A conversão da energia eletromagnética refletida pelos alvos terrenos em um par de tensões elétricas, a componente em fase (F) e a componente em quadratura ou imaginária (Q), permite a criação dos pixels da imagem. O sistema de radar encarrega-se de processar convenientemente os sinais recebidos e gerar este par de tensões, de modo a convertê-los em informações geofísicas correspondentes à refletividade complexa, denominado RCS (seção cruzada de radar) ou coeficiente de retroespalhamento da cena. Assim, as medidas realizadas pelo sistema SAR são fundamentalmente determinadas pelo mecanismo de espalhamento das ondas eletromagnéticas e pela calibração realizada no sistema antes de ser posto em operação.

Com base nas medidas das componentes elétricas, é possível gerar diferentes tipos de dados e isto recai em um problema de como as imagens devem ser exibidas. A primeira fonte de informação é a refletividade complexa. Qualitativamente, este conceito expressa a interação entre os espalhadores localizados em cada ponto (i, j) na superfície da Terra, cujas propriedades físicas (geometria, constante dielétrica, entre outras) provocam mudanças tanto no ângulo de fase $\phi(i, j)$, quanto na amplitude $A(i, j)$ das ondas emitidas pelo radar. O par de tensões é derivado dos canais em fase e em quadratura ($a \cos \phi, a \sin \phi$) estabelecidos no receptor (Figura 1.3).

O esquema simplificado do receptor de radar ilustrado na Figura 1.3 representa como as componentes em fase e em quadratura são obtidas². O sinal de radiofrequência (RF) proveniente do receptor do radar é composto de dois sinais, que são extraídos e deslocados noventa graus entre si. Isto é feito usando um circuito especial existente no sistema de radar.

A estimativa da refletividade local em cada pixel pode também ser representada por um número complexo $a \exp(j\phi)$, em que estes dados formam a imagem complexa de visada única (SLC) [15], na qual nenhuma redução de ruído *speckle* é realizada.

A partir da imagem complexa, vários produtos são formados, como as imagens em amplitude, imagens em intensidade e imagens log intensidade. A imagem log intensidade é obtida aplicando a transformação logarítmica $\log_{10}(\cdot)$ na imagem intensidade. Esta imagem também é conhecida como imagem dB. Tomando a componente em fase como sendo $F = a \cos \phi$ e a componente em quadratura como $Q = a \sin \phi$, cada ponto da imagem em detecção linear (ou em amplitude) possui amplitude:

$$A = \sqrt{(a \cos \phi)^2 + (a \sin \phi)^2} = \sqrt{F^2 + Q^2} = |a|, \quad (1.1)$$

enquanto cada ponto da imagem gerada por detecção quadrática possui intensidade dada por $I = F^2 + Q^2 = |a|^2$.

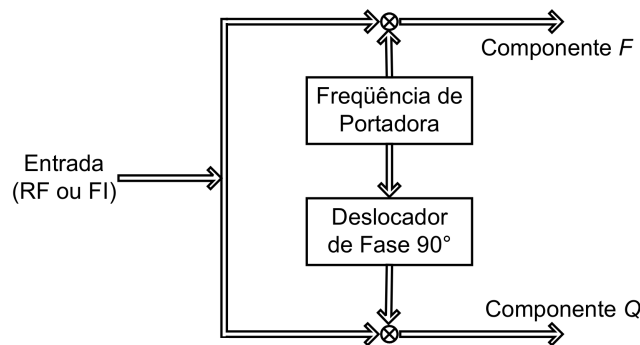


Figura 1.3: Obtenção das componentes em fase e em quadratura de sinais de radar.

As partes real e imaginária da imagem complexa têm aparência bastante ruidosa e são de difícil interpretação, pois muitas vezes é impossível detectar visualmente a presença de alvos em meio ao ruído. Por sua vez, nas imagens em intensidade, amplitude e log intensidade é possível a detecção visual de estruturas. As imagens em amplitude ($A = \sqrt{I}$) e log intensidade ($\log_{10} I$) têm faixa dinâmica reduzida, sendo preferíveis por causa da representação e percepção de detalhes na faixa de cinza $[0, 255]$. Nestes tipos de imagens, a informação de fase é descartada.

²Adaptado de Alaska SAR Facility (ASF), em <http://www.asf.alaska.edu/>, visitada em 05.jan.2005.

Quando a resolução espacial das imagens não é de grande importância, as imagens SAR são geralmente fornecidas sob múltiplas visadas, objetivando a redução no volume de dados e do nível de ruído *speckle* por um fator proporcional a $1/\sqrt{n}$, em que n é o número de visadas ou a quantidade de imagens obtidas da mesma cena (na mesma polarização e frequência) que são combinadas para formar uma imagem resultante. O radar de abertura sintética do ERS-1³ é um exemplo de sistema SAR que realizava processamento de múltiplas visadas. Os dados fornecidos eram imagens de precisão (PRI), com 3 visadas e detecção linear (amplitude) [16].

³Este satélite foi lançado em 17 de julho de 1991 pela Agência Espacial Européia (ESA) e ficou fora de serviço em 10 de março de 2000, devido a uma falha no sistema de controle de atitude. Sua antena física possuía dimensões de 10m×1m.

Capítulo 2

Modelagem de Dados SAR

2.1 Introdução

O propósito deste capítulo é introduzir algumas propriedades estatísticas básicas do ruído *speckle*, do retroespalhamento (*backscatter* ou cena não ruidosa) e da combinação dos mesmos para originar os sinais de retorno que, processados pelo sistema de radar, geram os pixels nas imagens SAR. Trata-se também da simulação de imagens digitais contaminadas artificialmente. Esta contaminação obedece ao modelo multiplicativo, cuja abordagem é a mais conhecida e adotada para representar dados SAR e estes dados caracterizam os pixels de zonas homogêneas, heterogêneas e extremamente heterogêneas, tipicamente encontradas nas cenas. O entendimento destes modelos de degradação e sua implementação algorítmica permitem a geração de imagens ruidosas, que podem ser usadas na avaliação de segmentadores e de filtros redutores de *speckle*.

A formulação e o desenvolvimento de segmentadores aplicados a imagens SAR parte de algumas premissas para os tipos de cenas encontradas. Uma delas é que tais imagens são constituídas de zonas homogêneas e que o segmentador deverá identificá-las, sendo sua formulação baseada em estatísticas definidas para tais regiões. Outro caso é o desenvolvimento de algoritmos voltados para a segmentação de imagens com textura, em que outros critérios estão envolvidos. Em casos práticos, as imagens SAR apresentam-se raramente constituídas totalmente de regiões homogêneas. Em decorrência disso, as simulações de outros tipos de alvos permitem avaliar a atuação de segmentadores perante superfícies com diferentes graus de homogeneidade, criadas artificialmente a partir de modelos matemáticos-estatísticos.

Dentro do contexto do modelo multiplicativo adotado para dados SAR, existem algumas distribuições que se aplicam a certos tipos de regiões. Isto significa dizer que os retornos (que geram os pixels) são caracterizados pela combinação de distribuições particulares que modelam o ruído *speckle* e aquelas relativas às cenas desprovidas de ruído. Algumas destas distribuições são assunto de interesse da seção seguinte, sendo elas de grande importância para a simulação de imagens com ruído multiplicativo. As distribuições estatísticas apresentadas são interdependentes e obtidas através de transformações matemáticas sobre variáveis aleatórias.

2.2 O Modelo Multiplicativo

O processamento coerente dos retornos pelo radar torna as imagens suscetíveis ao ruído *speckle*, cujo nível de cinza dos pixels é dependente do sinal, ou seja, as áreas contendo alvos bastante reflexivos são mais afetadas que aquelas em que existem alvos que

propiciam baixa reflexão nos pulsos eletromagnéticos. Por isso, o modelo multiplicativo é comumente adotado para explicar como os pixels de imagens de radar são originados [17].

Esta metodologia consiste na atribuição de distribuições particulares para modelar o retroespalhamento do pulso incidente no terreno e o ruído *speckle*, que surge das interferências entre as ondas eletromagnéticas refletidas que retornam ao sensor. Assim, o registro da informação é matematicamente expresso por:

$$Z = XY, \quad (2.1)$$

em que Z representa a variável aleatória referente aos pixels registrados na imagem digital e X e Y referem-se, respectivamente, ao retroespalhamento provocado pelas superfícies imageadas e ao ruído de coerência.

Analisando Z como uma transformação de variáveis, sua distribuição depende das distribuições que modelam X e Y . A variável aleatória X é muitas vezes considerada real e positiva, enquanto Y pode ser complexa (quando a imagem possui formato complexo) ou real positiva (nos formatos de amplitude ou intensidade), consoante [18, 19].

A variável aleatória Y representativa do ruído *speckle*, utilizada nesta dissertação, é a distribuição Raiz de Gama com parâmetros n e n , $Y \sim \Gamma^{1/2}(n, n)$, sendo n o número equivalente de visadas. Esta distribuição é uma das mais adotadas na literatura para modelar o ruído coerente que ocorre em regiões homogêneas de imagens SAR geradas em amplitude.

Na prática, de acordo com [20], o número equivalente de visadas n pode apresentar valor diferente do nominal, o qual é indicado pelo fornecedor das imagens, quando do processamento dos dados registrados pelo radar. Este parâmetro pode ser estimado a partir dos pixels, como realiza o algoritmo descrito em [16] e implementado neste trabalho para tal fim. A idéia básica da obtenção (ou estimação) do número de visadas consiste em medir este parâmetro como uma função da razão entre o desvio padrão e a média de amostras de pixels colhidas em áreas que não exibam textura marcante. Para isso, as aludidas amostras são obtidas de regiões homogêneas, cuja textura origina-se das flutuações do ruído atuando sobre o retroespalhamento provocado por uma superfície de seção cruzada (RCS) considerada constante. As amostras podem ser indicadas manual ou automaticamente, mas a primeira forma é, muitas vezes, passível de erro.

Adotada a distribuição Raiz de Gama para modelar o ruído *speckle* em todos os experimentos deste trabalho, e os casos particulares em amplitude da distribuição Raiz da Gaussiana Inversa Generalizada [19] para X , os retornos de radar (Z) podem assumir certas distribuições, a saber: K-Amplitude, G-Amplitude Zero ou Raiz de Gama. Nas equações a seguir, o símbolo itálico Γ representa a função Gama de Euler [21] e o símbolo \sim significa *distribuído como*.

i. Distribuição K-Amplitude (KA), denotada por $Z \sim \mathcal{K}_A(\alpha, \lambda, n)$, resulta de $X \sim \Gamma^{1/2}(\alpha, \lambda)$ e $Y \sim \Gamma^{1/2}(n, n)$. A função densidade de probabilidade representativa dos retornos Z , para $n, \alpha, \lambda, x > 0$, é expressa como [18]:

$$f_Z(z; \alpha, \lambda, n) = \frac{4\lambda n z}{\Gamma(\alpha)\Gamma(n)} (\lambda n z^2)^{((\alpha+n)/2)-1} K_{\alpha-n} \left(2z\sqrt{\lambda n} \right), \quad (2.2)$$

em que K_v é a função de Bessel de ordem v e o momento de ordem r é dado por:

$$E[Z^r] = (n\lambda)^{-r/2} \frac{\Gamma(\alpha + r/2)\Gamma(n + r/2)}{\Gamma(\alpha)\Gamma(n)}, \quad (2.3)$$

sendo a esperança do retorno igual a:

$$E[Z] = (n\lambda)^{-1/2} \frac{\Gamma(\alpha + \theta, 5)\Gamma(n + \theta, 5)}{\Gamma(\alpha)\Gamma(n)}. \quad (2.4)$$

ii. **Distribuição G-Amplitude Zero (GA0)**, simbolicamente $Z \sim \mathcal{G}_A^0(\alpha, \gamma, n)$, sendo $\alpha < 0, \gamma > 0$ (parâmetro de escala¹) e $n \geq 1$, cuja função densidade é formulada como:

$$f_Z(z; \alpha, \gamma, n) = \frac{2n^n \Gamma(n - \alpha) \gamma^{-\alpha} z^{2n-1}}{\Gamma(n) \Gamma(-\alpha) (\gamma + nz^2)^{n-\alpha}}. \quad (2.5)$$

Esta distribuição resulta da combinação de retornos $X \sim \Gamma^{-1/2}(\alpha, \gamma)$ e ruído de coerência sendo modelado como $Y \sim \Gamma^{1/2}(n, n)$ [23]. O momento de ordem r é dado por:

$$E[Z^r] = \begin{cases} \frac{\Gamma(-\alpha-r/2)\Gamma(n+r/2)}{\Gamma(-\alpha)\Gamma(n)} \left(\frac{\gamma}{n}\right)^{r/2}, & \text{se } \alpha < -r/2, n \geq 1 \\ \infty, & \text{se } -r/2 \leq \alpha < 0 \end{cases} \quad (2.6)$$

e o valor esperado e a variância dessa distribuição são calculados como:

$$E[Z] = \frac{\Gamma(-\alpha - \theta, 5)\Gamma(n + \theta, 5)}{\Gamma(-\alpha)\Gamma(n)} \left(\frac{\gamma}{n}\right)^{1/2} \quad (2.7)$$

e

$$Var(Z) = \frac{\Gamma(-\alpha - 1)\Gamma(n + 1)}{\Gamma(-\alpha)\Gamma(n)} \left(\frac{\gamma}{n}\right) - E[Z]^2. \quad (2.8)$$

iii. **Distribuição Raiz de Gama**, denotada por $Z \sim \Gamma^{1/2}(n, n/\beta)$, advinda do produto entre $X \sim \mathcal{C}(\sqrt{\beta})$ e $Y \sim \Gamma^{1/2}(n, n)$, sendo $\mathcal{C}(\cdot)$ a função distribuição constante (uniforme).

Estas três distribuições adotadas para os retornos permitem modelar pixels de regiões homogêneas, heterogêneas e extremamente heterogêneas. Neste trabalho, elas são aplicadas na geração de imagens contaminadas artificialmente com *speckle* e número de visadas (n) conhecido, desde que seja especificado também o valor médio de cinza (μ) de cada segmento da imagem sintética. A partir destas variáveis (n e μ), é possível calcular os demais parâmetros (γ , λ e β). Vale ressaltar que, em aplicações com imagens SAR reais, todos estes parâmetros podem ser inferidos, a partir de dados coletados nas imagens e mediante técnicas de estimação de parâmetros, como as aplicadas em [22].

As distribuições Raiz de Gama, KA e GA0 adotadas para modelagem de dados SAR em amplitude, encontram-se resumidas na Tabela 2.1. Na geração de dados SAR em intensidade, podem ser consultadas as referências [19, 23]. Nesta tabela, o tipo definido como +Heterogênea significa extremamente heterogênea e $\mathcal{N}^{-1/2}(a, b, c)$ é a distribuição Raiz da Gaussiana Inversa Generalizada com parâmetros a , b e c .

2.3 Geração de Variáveis Aleatórias e Imagens Simuladas em Amplitude

Uma função densidade de probabilidade (fdp) é basicamente uma fórmula matemática que possui alguns parâmetros de entrada e é função de uma ou mais variáveis independentes. O número dessas variáveis independentes fornece a dimensão da fdp ,

¹Caso $Z' \sim \mathcal{G}_A^0(\alpha, 1, n)$, então $Z = \sqrt{\gamma}Z' \sim \mathcal{G}_A^0(\alpha, \gamma, n)$, segundo [22].

que pode ser denotada como, por exemplo, $f_{X,Y,Z}(x, y, z; a, b, c)$. Nesse caso, esta função refere-se a três VAs (X, Y, Z) e possui três parâmetros (a, b, c), sendo seu gráfico uma superfície.

Tabela 2.1: Tipos de regiões e modelos para os retornos SAR em amplitude, n visadas [23].

Tipo de Região	Cena Sem Ruído	Speckle	Retorno
Homogênea	$X \sim \mathcal{C}(\sqrt{\beta})$	$Y \sim \Gamma^{1/2}(n, n)$	$Z \sim \Gamma^{1/2}(n, n/\beta)$
Heterogênea	$X \sim \Gamma^{1/2}(\alpha, \lambda)$	$Y \sim \Gamma^{1/2}(n, n)$	$Z \sim \mathcal{K}_{\mathcal{A}}(\alpha, \lambda, n)$
+Heterogênea	$X \sim \Gamma^{-1/2}(\alpha, \gamma)$	$Y \sim \Gamma^{1/2}(n, n)$	$Z \sim \mathcal{G}_{\mathcal{A}}^0(\alpha, \gamma, n)$
Caso Geral	$X \sim \mathcal{N}^{-1/2}(\alpha, \gamma, \lambda)$	$Y \sim \Gamma^{1/2}(n, n)$	$Z \sim \mathcal{G}_{\mathcal{A}}^0(\alpha, \gamma, \lambda, n)$

Um caso importante surge quando é necessária a realização de um experimento no qual se deseja explorar sua natureza estocástica, em que o objetivo é incorporar uma VA em um processo, cuja distribuição seja conhecida. A primeira ação a ser tomada é gerar algumas observações dessa VA, cujos valores estejam de acordo com a distribuição atribuída ao processo. Conhecida a função de distribuição teórica de um processo, o problema em questão é como gerar amostras de variáveis aleatórias, cuja distribuição se aproxima da teórica. Este é um caso de simulação estocástica ou geração de números aleatórios. A simulação é a técnica que permite imitar um processo físico, segundo um modelo matemático que descreve seu comportamento [24]. Tendo preparado uma simulação de certo fenômeno, é mais ou menos simples alterar vários de seus parâmetros (modificando-os no modelo) e observando os resultados de tais alterações. De modo especial, o experimento realizado por simulação em computador é normalmente mais rápido e de mais baixo custo do que a experimentação com o próprio processo físico. Ao projetar-se uma simulação, a primeira tarefa a fazer é construir um modelo matemático, por meio do qual se descreva o processo.

A geração de números aleatórios em uma máquina digital é obtida por técnicas determinísticas e muitos autores referem-se a isto como geração de números pseudo-aleatórios, dadas algumas limitações dos computadores digitais em produzir números com precisão infinita. O processo de simulação de números aleatórios requer noções de teoria dos números, de estatística e de análise numérica [25].

A distribuição Gama, como descrito na seção anterior, permite simular as demais distribuições aplicáveis a dados SAR e gerar ocorrências para cada tipo particular de região (homogênea, heterogênea e extremamente heterogênea). Para gerar amostras de variáveis aleatórias com distribuição Gama, existem alguns algoritmos propostos na literatura e discutidos em [26]. Outras referências que também tratam desse assunto são [27, 28]. Nestas obras são discutidos vários algoritmos para gerar não somente VAs do tipo Gama, mas dados com outras distribuições. Programas de simulação, tais como o Matlab[®], contêm pacotes estatísticos e rotinas de geração de números aleatórios para algumas distribuições mais comuns.

Para gerar as ocorrências aleatórias Gama deste trabalho, é utilizada a rotina `gamrnd` existente no pacote estatístico do Matlab[®]. Esta rotina incorpora os algoritmos de Best [29] e de Jöhnk [30], definidos em [26] (pág. 410 e págs. 416 e 418, respectivamente). Estes algoritmos foram formulados para casos especiais, em que o parâmetro de forma a de $\Gamma(a, b)$ é menor que a unidade ($a < 1$, algoritmo de Jöhnk), igual à unidade ($a = 1$, em que a distribuição Gama é a própria distribuição Exponencial) e maior que a unidade ($a > 1$, algoritmo de Best ou algoritmo XG). Outra referência que trata da geração de VAs com distribuição Gama e parâmetro de forma não-inteiro a é Tadikamalla [31].

De posse de um gerador de amostras aleatórias com distribuição Gama, implementado segundo os algoritmos desenvolvidos nas citadas referências ou existentes em pacotes de simulação estatísticos, é necessário definir os valores para os parâmetros n , α , β , γ e λ . O parâmetro n é o número equivalente de visadas da imagem, cujos valores indicados devem ser positivos, geralmente inteiros, e os demais parâmetros são calculados. A imagem contendo regiões com valor médio de cinza μ é sintetizada no computador, sendo denominada imagem verdade (ou verdade terrestre, neste caso). Os valores de cinza correspondentes a cada região são definidos, bem como é conhecida a versão segmentada desta imagem.

Após a contaminação da imagem sintética por ruído, a imagem resultante pode ser usada para analisar o desempenho de filtros redutores de *speckle* e segmentadores, por exemplo. As imagens simuladas podem apresentar simultaneamente vários tipos de regiões (homogêneas e heterogêneas), para as quais existe controle dos parâmetros relacionados ao modelo estatístico que se utiliza para gerar os pixels.

2.3.1 Modelagem de áreas homogêneas

A geração de dados característicos de áreas homogêneas, cujos pixels possuem valor médio de cinza igual a μ , consiste em atribuir um vetor \mathbf{v} com amostras aleatórias seguindo uma distribuição $\Gamma(n, n\beta^{-1})$ e retornar $\sqrt{\mathbf{v}}$. O parâmetro β é calculado como:

$$\beta = n \left[\frac{\mu \Gamma(n)}{\Gamma(n + 0, 5)} \right]^2, \quad (2.9)$$

de acordo com [25]. Na função `gamrnd`, não se deve colocar diretamente os parâmetros $(n, n/\beta)$, porque são produzidos valores muito aquém dos níveis de cinza corrompidos que se deseja obter. Pode-se resumir o processo de geração de retornos oriundos de áreas homogêneas segundo o Algoritmo 1.

Algoritmo 1. Geração de amostras com distribuição Raiz de Gama.

- i.* Determinar o valor de β através da Equação 2.9, para n visadas e média μ ;
- ii.* Gerar k amostras $\Gamma(n, 1)$ e multiplicá-las pelo fator $1/n$, de modo a tornar o ruído *speckle* $Y \sim \Gamma(n, n)$;
- iii.* Multiplicar o fator β/n por Y , de modo a gerar a distribuição $Z' \sim \Gamma(n, n/\beta)$;
- iv.* Retornar $Z \sim \Gamma^{1/2}(n, n/\beta)$ aplicando $\sqrt{Z'}$.

2.3.2 Modelagem de áreas heterogêneas

Quando se deseja simular dados característicos de uma região heterogênea com média μ , modelada pela distribuição $\mathcal{K}_{\mathcal{A}}(\alpha, \lambda, n)$, o parâmetro α é o grau de heterogeneidade (ou rugosidade) da região, que assume valores positivos, e n é o número de visadas desejado. São gerados dois vetores aleatórios Gama, um representando o retroespalhamento (\mathbf{v}_1) e o outro (\mathbf{v}_2) representando o *speckle*. Os pixels da imagem ruidosa são gerados ao retornar $\sqrt{\mathbf{v}_1 \mathbf{v}_2}$, em que o produto é realizado elemento a elemento. O valor do parâmetro λ é obtido como [25]:

$$\lambda = \frac{1}{n} \left[\frac{\Gamma(\alpha + 0, 5) \Gamma(n + 0, 5)}{\mu \Gamma(\alpha) \Gamma(n)} \right]^2. \quad (2.10)$$

A simulação de retornos com distribuição K-Amplitude é estabelecida através do Algoritmo 2.

Algoritmo 2. Geração de amostras com distribuição K-Amplitude.

- i. Determinar λ de acordo com a Equação 2.10, para parâmetros de entrada n visadas, média μ e α positivo;
- ii. Gerar k amostras $\Gamma(n, 1)$ e multiplicá-las pelo fator $1/n$, de modo a tornar o ruído *speckle* $Y \sim \Gamma(n, n)$;
- iii. Multiplicar λ^{-1} por $\Gamma(\alpha, 1)$ para obter $X \sim \Gamma(\alpha, \lambda)$;
- iv. Multiplicar ponto a ponto os vetores aleatórios X e Y para obter $Z' \sim \Gamma(\alpha, \lambda, n)$;
- v. Retornar $Z = \sqrt{Z'} \sim \mathcal{K}_A(\alpha, \lambda, n)$.

2.3.3 Modelagem de áreas homogêneas, heterogêneas ou extremamente heterogêneas

De maneira semelhante, a geração de ocorrências oriundas de áreas extremamente heterogêneas com média μ e rugosidade α (grau de heterogeneidade) é modelada segundo a distribuição $\mathcal{G}_A^0(\alpha, \gamma, n)$. Para isto, geram-se dois vetores \mathbf{v}_1 e \mathbf{v}_2 , com distribuição $\Gamma(n, n)$ e $\Gamma(-\alpha, \gamma)$, respectivamente, e se retorna $\sqrt{\mathbf{v}_1/\mathbf{v}_2}$ (razão elemento a elemento). Os valores de α devem ser obrigatoriamente negativos e, dependendo de seu valor, podem ser modelados retornos oriundos de áreas homogêneas, heterogêneas ou extremamente heterogêneas. O valor do parâmetro de escala γ é expresso por [25]:

$$\gamma = n \left[\frac{\mu \Gamma(-\alpha) \Gamma(n)}{\Gamma(-\alpha - \theta, 5) \Gamma(n + \theta, 5)} \right]^2, \quad \alpha < -1/2, \quad n > 0. \quad (2.11)$$

Sendo formulados como valores quadráticos, os parâmetros β , γ e λ podem atingir valores altos, proporcionais ao quadrado de μ .

Conforme explicam os autores em [22], o grau de rugosidade α da distribuição GA0, quando assume valores da ordem de $\alpha < -15$, está geralmente associado a alvos homogêneos, tais como pastagens; valores no intervalo $[-15, -5]$ exprimem observações de áreas tipicamente heterogêneas, tais como florestas; valores no intervalo $-5 < \alpha < 0^2$ estão associados a retornos provenientes de zonas extremamente heterogêneas, como alvos localizados em cidades.

A distribuição GA0 é, portanto, uma distribuição bastante versátil, pois ela pode modelar dados referentes aos três tipos de regiões descritas na Tabela 2.2, que resume ainda os intervalos de valores do parâmetro α para a distribuição GA0.

A geração de ocorrências obedecendo a distribuição $\mathcal{G}_A^0(\alpha, \gamma, n)$ pode ser realizada observando os passos definidos no Algoritmo 3.

Algoritmo 3. Geração de amostras com distribuição G-Amplitude Zero.

- i. Determinar γ através da Equação 2.11, para n visadas, média μ e α negativo;
- ii. Gerar k amostras $\Gamma(n, 1)$ e multiplicá-las pelo fator $1/n$, de modo a tornar o ruído *speckle* $Y \sim \Gamma(n, n)$;
- iii. Multiplicar γ^{-1} por $\Gamma(-\alpha, 1)$ para obter $X \sim \Gamma(-\alpha, \gamma)$;
- iv. Fazer $Z' = (Y/X) \sim \Gamma^{-1}(-\alpha, \gamma, n)$;
- v. Retornar $Z = \sqrt{Z'} \sim \mathcal{G}_A^0(\alpha, \gamma, n)$.

²Matematicamente, este intervalo seria $-5 < \alpha < -0,5$.

Nestes algoritmos, ao gerar as k amostras para os tipos de retornos desejados, é importante incluir uma rotina que realize mudanças aleatórias da posição desses k elementos dentro do vetor de amostras. Esta ação tende a impedir que se formem aglomerados de pixels ou manchas isoladas nos segmentos contaminados, a fim de deixar seus pixels com distribuição espacial mais uniformizada. Outro ponto que deve ser enfatizado é que os padrões de *speckle* gerados pelos algoritmos acima não são correlacionados. A referência [32] trata da simulação de *speckle* correlacionado em imagens SAR intensidade, obedecendo a distribuição \mathcal{K} (K-Intensidade).

Tabela 2.2: Valores do parâmetro α da distribuição G-Amplitude Zero [22].

Tipo de Região	Intervalo de Valores	Tipos de Cenas Associadas
Homogênea	$-\infty < \alpha < -15$	Pastagens, Culturas, Solo Exposto
Heterogênea	$-15 \leq \alpha \leq -5$	Florestas
+Heterogênea	$-5 < \alpha < 0$	Cidades

A próxima seção exemplifica as imagens simuladas usadas neste trabalho e seus parâmetros descritivos.

2.3.4 Imagens de teste contaminadas artificialmente por ruído *speckle*

As imagens exibidas nas Figuras 2.1(a) e 2.1(b) são imagens sintéticas usadas para avaliar o desempenho do algoritmo de segmentação desenvolvido neste trabalho. Acompanham seus respectivos mapas de bordas, dados nas Figuras 2.1(c) e 2.1(d), que definem os limites ideais de cada região. A imagem *kk* possui 200×200 pixels e 4 regiões, enquanto a imagem *imgcartoon* possui 275×367 pixels e 23 regiões. Elas definem a verdade terrestre ou segmentação de referência neste estudo.

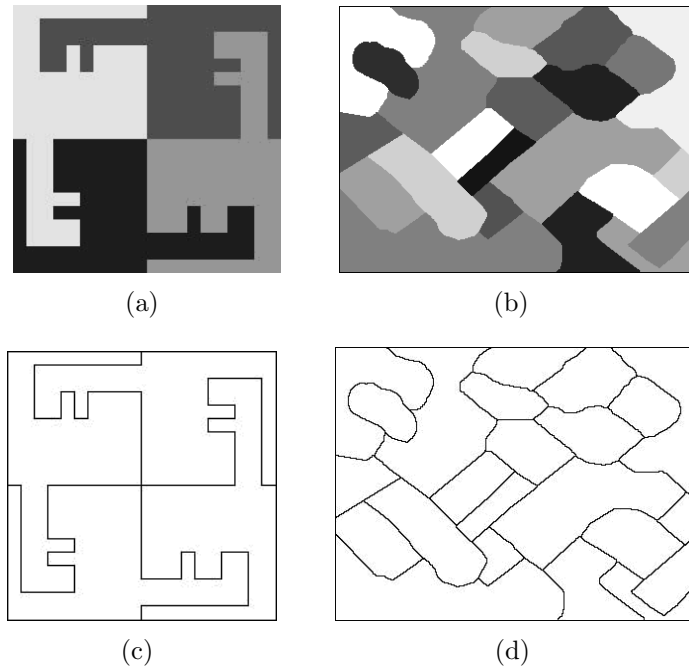


Figura 2.1: (a) Imagem *kk*, 200×200 pixels e 4 segmentos (b) imagem *imgcartoon*, 275×367 pixels e 23 segmentos (c) mapa de bordas da imagem *kk* e de (d) *imgcartoon*.

As imagens constantes da Figuras 2.2(a) e 2.2(b) são as versões contaminadas artificialmente com *speckle* com número de visadas $n = 1$, seguidas das imagens contaminadas com ruído multiplicativo com $n = 3$, Figuras 2.2(c) e 2.2(d). Por último, as imagens ruidosas das Figuras 2.2(e) e 2.2(f) possuem $n = 5$ visadas. À medida que aumenta o valor do parâmetro n , diminui a influência do *speckle* e há melhor definição visual das fronteiras entre os segmentos.

Os pixels dos segmentos contaminados com ruído multiplicativo advêm dos modelos de distribuição para cada tipo específico de cena, descritos na Seção 2.3. Para realizar a contaminação, é desenvolvido um simulador baseado nos algoritmos de geração de variáveis aleatórias para as distribuições Raiz de Gama, K-Amplitude e G-Amplitude Zero.




Figura 2.2: Versões contaminadas com ruído multiplicativo das imagens *kk* e *imgcartoon* com (a–b) 1 visada, (c–d) 3 visadas, (e–f) 5 visadas.

Com este simulador é possível contaminar as imagens sintéticas de forma a simular retornos de radar oriundos de regiões homogêneas, heterogêneas e extremamente heterogêneas, sob múltiplas visadas. Para este fim, os dados de entrada deste simulador são as imagens sintéticas contendo segmentos com tonalidade constante μ e as matrizes de rótulos associadas, que mapeiam a extensão de cada segmento. Esta matrizes são usadas na obtenção das segmentações de referência, bem como dos mapas de bordas de cada imagem.

A variância do ruído *speckle* diminui à medida que o número de visadas n aumenta. Em regiões homogêneas, cuja distribuição dos pixels é aproximada pela distri-

buição Raiz de Gama para imagens em amplitude com n visadas, a variância do ruído é inversamente proporcional à raiz quadrada do número de visadas.

Os pixels constituintes destas imagens contaminadas apresentam valores reais e vários podem ter brilho acima de 255. As imagens exibidas na Figura 2.2 são meramente ilustrativas, seus níveis de cinza foram truncados e aqueles acima de 255 foram ajustados para este nível. Na execução de algoritmos de filtragem ou segmentação, devem ser considerados os valores originais dos pixels das imagens contaminadas para a obtenção de resultados.

O ruído *speckle* apresenta maior variância (ruído totalmente desenvolvido) quando a imagem possui $n = 1$ visada, cujas regiões homogêneas apresentam ruído com distribuição Rayleigh e ao retroespalhamento é atribuída a distribuição constante.

A imagem simulada *kk* apresenta apenas regiões heterogêneas e extremamente heterogêneas, de modo a verificar o desempenho de segmentadores perante cenas com diferentes graus de heterogeneidade. As propriedades distribucionais de cada região e os parâmetros calculados a partir do nível médio de cinza e do grau de textura α (ou rugosidade) estão referidos nas Tabelas A.1, A.2 e A.3, na pág. 112, sob diferentes visadas. Com a imagem *imgcartoon* pretende-se simular retornos de regiões contendo vilas, solo exposto, florestas em regeneração, florestas primárias, áreas lacustres e culturas, definidas segundo a Tabela 4.2, pág. 55. As propriedades distribucionais de cada região dessa imagem e seus parâmetros para n visadas estão indicados nas Tabelas A.4, A.5 e A.6.

A imagem ilustrada na Figura 2.3(a) possui 150×331 pixels e 52 segmentos, evidenciados pelo mapa de bordas. As trinta barras de largura variável, os dígitos e o fundo possuem nível de cinza igual a 50, 100 e 200, respectivamente. Suas versões contaminadas com ruído multiplicativo com 1 e 3 visadas estão exibidas na Figuras 2.3(c) e 2.3(d), respectivamente.




Figura 2.3: (a) Imagem *codbarras* (b) mapa de bordas ideal, com 52 segmentos (c) versão ruidosa com 1 visada e (d) com 3 visadas.

O mapa de bordas destas imagens é obtido a partir da matriz de rótulos, quando são determinados os pontos que constituem a interface entre as regiões. Para isso, realiza-se a varredura da matriz de rótulos com uma janela 3×3 e um pixel (i, j) no centro desta máscara é considerado como ponto de borda, caso qualquer um de seus vizinhos nas direções norte $(i - 1, j)$, sul $(i + 1, j)$, leste $(i, j - 1)$ e oeste $(i, j + 1)$ possua um rótulo distinto daquele referente ao pixel central.

No algoritmo implementado, é acrescentada também a coordenada sudeste $(i + 1, j + 1)$ para o estabelecimento dos cinco pixels vizinhos do ponto central, com o

objetivo de resolver um problema de fechamento de bordas, quando a varredura no plano da imagem é realizada da direita para a esquerda e de cima para baixo. Caso esta coordenada não seja inserida para executar a análise de vizinhança de um pixel qualquer, as bordas dos objetos não são completamente fechadas. O mapa de bordas é uma matriz lógica, em que as posições (i, j) marcadas como 1 são identificados como pixels de borda e aquelas marcadas com 0 consistem dos pixels pertinentes ao interior dos objetos.

A Figura 2.4 ilustra a visão 3D de um detalhe localizado nas proximidades do canto inferior esquerdo da Figura 2.3(c) (o detalhe é referente à janela branca destacada como \boxtimes). É possível observar variações bruscas dos valores de cinza neste detalhe, em que a intensidade dos pixels contaminados é maior nos pontos mais claros, enquanto áreas que possuem originalmente baixo brilho são menos afetadas. Isso decorre do modelo multiplicativo adotado para o ruído de coerência, fato que se observa também em imagens SAR reais.

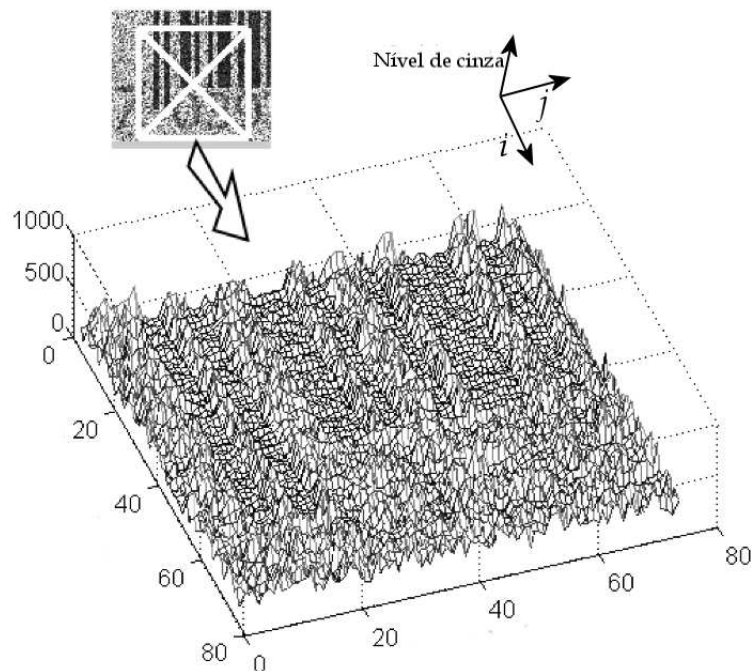


Figura 2.4: Visão 3D de um detalhe de 75×75 pixels da imagem *codbarras*, 1 visada.

Para executar a segmentação de imagens SAR, vários algoritmos são propostos na literatura e muito esforço tem sido dedicado nesta tarefa. No capítulo seguinte é proposto um segmentador de imagens SAR, que está baseado na combinação de crescimento e fusão estatística de regiões.

Capítulo 3

Segmentação de Imagens SAR por Crescimento e Fusão Estatística de Regiões

3.1 Introdução

Os métodos clássicos de segmentação, tais como a limiarização multiescala de histograma [33], a transformada *watershed* oriunda da Morfologia Matemática [34], a divisão e fusão ou outros procedimentos como o crescimento de regiões, quando aplicados a segmentação de imagens de radar, podem não produzir resultados satisfatórios. Estas ferramentas são bastante dependentes suavização prévia de ruído. Para imagens com alto conteúdo ruidoso, tal como as imagens SAR geradas com número de visadas próximo a 1, a qualidade da segmentação está relacionada com a qualidade da filtragem realizada previamente.

As distorções provocadas pelos filtros podem ocorrer em alguma magnitude. Logo, os objetos reais presentes na cena podem não corresponder exatamente aos detectados por um segmentador clássico, face a não preservação de bordas e detalhes, causados por algoritmos de filtragem inapropriados. Por isso, o desenvolvimento de filtros de suavização de *speckle* que preservem bordas e detalhes é tema de continuada pesquisa. Por um lado, há linhas de pesquisas realizam a comparação de desempenho de diferentes filtros, como os trabalhos de [35, 36], ou se ocupam com o desenvolvimento de novas técnicas baseadas na combinação de filtros de ruído *speckle* já existentes, como [37]. Desse modo, técnicas mais simplificadas de segmentação podem ser aplicadas sobre imagens de radar que passam por uma suavização preliminar de ruído [38].

Por outro lado, existem vertentes que buscam a segmentação de imagens de radar sem a necessidade de filtragem prévia, sendo que as técnicas desta categoria atuam diretamente sobre as imagens ruidosas. Entre os trabalhos que utilizam tal princípio, pode-se citar [39, 40, 41].

Seguindo esta idéia, propõe-se neste capítulo uma metodologia para obter a segmentação de imagens SAR sem usar quaisquer tipos de pré-processamentos, tais como a suavização de *speckle*, por exemplo. O objetivo deste algoritmo é localizar as estruturas presentes nas imagens a partir de seus pixels originais.

No contexto apresentado, o modelo de segmentação proposto pode ser obtido através de técnicas que utilizam o conceito de região, ou seja, um conjunto de pixels unidos através de algum critério de similaridade. Este critério servirá para incorporar pixels inicialmente escolhidos e formar pequenas regiões (ou sementes) a partir de informações extraídas da imagem SAR. Muitos algoritmos de segmentação empregando este tipo de

análise geram uma segmentação inicial contendo mais regiões do que o necessário para uma aplicação prática. Os segmentos gerados têm características de cor, textura, forma e tamanhos variados. Estes casos requerem a aplicação de procedimentos de redução do número de regiões, de modo a formar um conjunto desejável de segmentos dentro da partição.

O ruído inerente às imagens de radar gera problemas singulares para programas de processamento de imagens de todos os tipos. Devido a isso, não é comum a existência de segmentadores SAR em aplicativos para processamento de imagens de sensoriamento remoto. Outra possível causa reside no fato destas imagens serem ainda pouco acessíveis, porque o processo de aquisição ainda é caro e a tecnologia empregada requer grandes investimentos.

O simples fato de o ruído *speckle* introduzir uma grande variação nos pixels dentro de uma janela leva à necessidade de incorporar esquemas de análise mais apropriados para formar regiões iniciais. No processamento destes tipos de imagens, um conjunto de pixels fornece mais informações do que elementos isolados. Sozinhos, os pixels podem não representar necessariamente fontes de informação confiáveis, pois seus valores radiométricos resultam de valores originais e desconhecidos de brilho multiplicados por valores aleatórios de ruído. Uma descrição simplificada sobre as interferências eletromagnéticas que ocorrem durante a geração de imagens SAR pode ser encontrada em [14].

Um dos problemas da segmentação de imagens de radar consiste em formar regiões iniciais e um meio mais simples para formá-las pode ser a tesselação da imagem, de modo a gerar uma segmentação fina. Caso ela seja muito fina (no caso da tesselação consistir de regiões de tamanhos diminutos, por exemplo, 2×2 pixels), então as propriedades estatísticas destes segmentos podem ser severamente influenciadas pelo ruído e os indicadores de homogeneidade são não confiáveis. A segmentação elementar é o caso mais severo e consiste na atribuição de um único pixel por região. Por outro lado, quando as regiões são formadas empregando janelas muito grandes, existe uma tendência à supressão de detalhes importantes. Além disso, a segmentação leva à formação de regiões com contornos quadrados, quando estes blocos começam a ser unidos. Por estes motivos, a segmentação inicial representa um ponto muito importante neste processo.

Segundo elucida Tilton em [42], a análise de imagens baseada em regiões é potencialmente mais efetiva do que aquela baseada em pixel isolados. Este autor explica ainda que a análise por região explora melhor a informação espacial e, em geral, a análise por pixels depende ainda da definição de uma grade fixa disposta na imagem para formar os aglomerados iniciais. Isso significa uma imposição arbitrária de segmentação, enquanto a análise por região é derivada de características presentes nos dados; os segmentos formados podem ser unidos de acordo com o tipo de informação contida de cada um. Em última instância, a segmentação tende a ser arbitrária e dependente dos dados, nunca imposta. Além do mais, o número de aglomerados tende a ficar muito grande quando é aplicada uma grade pequena e um decréscimo dessa contagem pode ser obtida se as regiões iniciais são formadas convenientemente. No entanto, o procedimento de criação destas regiões pode tomar bastante tempo, mas compensações futuras podem ser obtidas, como redução do tempo de fusão das mesmas. Quando a resolução não é tão importante, a tesselação pode ser aplicada.

Alguns algoritmos de segmentação de imagens de radar são baseados em aglomerados iniciais de pixels para desencadear o processo de segmentação. São exemplos destes algoritmos: MUM (*Merge Using Moments*) [40], a técnica *simulated annealing* [41] aplicada a imagens SAR e o algoritmo RWSEG, cujo nome é definido pelos autores em [43, 44].

Uma questão relativa a estes métodos é como formar os segmentos iniciais para que funcionem apropriadamente. Nas seções seguintes, desenvolve-se um método baseado no algoritmo clássico de crescimento de regiões para formar os segmentos de partida, de acordo com um critério de homogeneidade estatístico. Os segmentos gerados são posteriormente unidos, a fim de reduzir o grande número de regiões, e constitui outra fase do processo de segmentação desenvolvido nesta pesquisa. Tal procedimento está implementado segundo o diagrama disposto na Figura 3.1.

A primeira etapa de segmentação consiste na formação dos primeiros segmentos da partição, através da análise de homogeneidade dos pixels das imagens SAR, assunto explorado nas Seções 3.2 a 3.4. Em seguida, os fragmentos passam a ser unidos para produzir a segmentação final da imagem, cuja metodologia é tratada nas Seções 3.5 e 3.6. O crescimento de regiões e a fusão são duas etapas distintas no processo de segmentação.




Figura 3.1: Diagrama de blocos do algoritmo de segmentação proposto.

3.2 Crescimento de Regiões Guiado pela Análise do Coeficiente de Variação

O crescimento de regiões proposto conduz à formação da partição inicial e é regido pelos princípios básicos do crescimento de regiões clássico, a saber: 1) escolha de pixels iniciais, denominados sementes; 2) análise da vizinhança das sementes segundo algum critério de similaridade e 3) os pixels vizinhos do pixel semente são incluídos na região, promovendo seu crescimento. Os pixels que não satisfazem as condições de aceitação definem o limite de região em crescimento. Os passos 2 e 3 são repetidos até que nenhum pixel conectado ao pixel semente satisfaça a condição de aceitação, quando são buscadas novas sementes na imagem para reiniciar o crescimento.

A indicação de quais pixels são vizinhos de um pixel semente está condicionada ao conceito de conectividade (se 4 ou 8-conectada). A Figura 3.2 ilustra uma janela 3×3 centrada em um pixel (i, j) de uma imagem digital e as possíveis conectividades. Os pixels 2, 4, 6, 8 são os vizinhos-de-4 do pixel central. A união com os pixels marcados como 1, 3, 5, 7 formam a vizinhança-de-8 ou 8-conectados. Adota-se como ponto $(1,1)$ de uma imagem digital o pixel corresponde ao canto superior esquerdo, em que a primeira coordenada refere-se à linha e a segunda à coluna de um pixel na imagem.

A decisão de incluir um pixel (ou uma sub-região) em uma região sob análise é, freqüentemente, baseada na comparação entre a diferença de propriedades locais dos pixels e das sub-regiões envolvidas, além de um valor pré-definido de limiar. Uma possível

regra para o crescimento da região poderia ser a diferença absoluta entre o valor médio de cinza da região em análise e o valor de cinza pixel a ser incorporado na mesma. Caso esta diferença seja menor do que um limiar arbitrário ε igual a, por exemplo, 15% do máximo de valor de cinza encontrado na imagem, então o pixel é acrescentado definitivamente à região. Esta forma de similaridade para acrescentar pixels a uma região é bastante comum na segmentação de imagens por crescimento de regiões, apesar dos limiares utilizados serem os mais diversos. A escolha destes limiares pode ser feita por meios heurísticos ou podem ser estimados a partir dos dados, como a comparação do valor médio de cinza da região com o nível dos pixels candidatos. Isso, é claro, depende do tipo de imagem com que se trabalha.




Figura 3.2: Vizinhança de um pixel semente de coordenadas (i, j) .

A detecção de regiões homogêneas em imagens SAR pode ser obtida explorando o conceito de coeficiente de variação. Este parâmetro é definido como a razão entre o desvio padrão e o valor médio de um conjunto de pixels de uma região, podendo ser aplicado como regra de similaridade para formar e crescer regiões. A idéia é inicialmente reduzir a imagem a vários pequenos segmentos e depois reunir aqueles com características semelhantes para formar segmentos maiores. Parte-se então de vários segmentos até chegar a uma quantidade determinada pelos parâmetros definidos pelo usuário para uma dada imagem SAR. Método semelhante de aglomeração de pixels é usado no algoritmo MUM, porém iniciar este algoritmo é um problema, pois o cálculo dos momentos (média e variância) implica na existência de populações de pixels já formadas para efetuar a união dos segmentos.

Conforme citam Cook *et al* em [40], um esquema que pode ser aplicado para gerar uma segmentação inicial é a divisão da imagem de radar em grades regulares quadradas. No entanto, isto limita a resolução da segmentação final, como antes explicado. Uma metodologia mais eficiente é usar uma grade adaptativa que permita a mudança de resolução, de modo a produzir a detecção de contornos condizentes com a verdade terrestre. Idealmente, a formação de pequenos elementos deve ocorrer em áreas bastante ocupadas (como cidades). Outrossim, uma grade de maiores dimensões deve ser estabelecida em zonas homogêneas, tais como as superfícies refletoras em imagens de radar contendo regiões de campos, áreas lacustres e colheitas.

Este dimensionamento adaptativo de janelas é possível caso se utilize um detector de bordas com altas taxas de falso alarme, conforme sugerem Cook *et al* (*op. cit.*). No entanto, detectores de bordas tendem a deixar fragmentos, cuja quantidade depende dos limiares usados para decidir se os pixels estão em regiões de transição. Esses limiares podem ser calculados automaticamente, porém limiares globais para detectar bordas em alguns pontos podem não localizar bordas que realmente existam em outros pontos em uma imagem SAR.

Outra alternativa para o problema descrito anteriormente, que é uma contribuição deste trabalho, é a utilização do coeficiente de variação como teste de homogeneidade para a formação de pequenas regiões em imagens SAR, combinada ao algoritmo de crescimento de regiões.

Baseado no trabalho desenvolvido por Park e outros [45], duas classes de refletividade podem caracterizar as cenas presentes em imagens de radar: a classe homogênea, que corresponde às áreas em que refletividade (ou seção cruzada - RCS) é constante; a classe heterogênea, correspondente àquelas áreas com textura granular marcante e zonas de transição, além de alvos pontuais em que o RCS varia. Estes tipos de zonas e suas distribuições estatísticas estão apresentados na Seção 2.2, pág. 10, que trata do modelo multiplicativo para o ruído *speckle* em imagens SAR.

Segundo o aludido modelo, os pixels $z(i, j)$ de uma imagem de radar advêm do produto entre seus valores originais e desconhecidos $x(i, j)$ e valores $y(i, j)$ de ruído *speckle*. A formulação apresentada a seguir refere-se a pixels coletados em áreas homogêneas de imagens SAR, visando explicar a obtenção do coeficiente de variação para áreas homogêneas e não homogêneas. As variáveis aleatórias Z , X e Y podem assumir os valores de $z(i, j)$, $x(i, j)$ e $y(i, j)$, respectivamente. Conforme a Seção 2.2, a modelagem de regiões homogêneas parte da hipótese básica que o retroespalhamento X possui um valor constante, embora desconhecido [23]. Isto conduz ao registro de observações ruidosas pelo sensor, que segue a distribuição Rayleigh para imagens obtidas em amplitude e com $n = 1$ visada. Para n visadas, o retorno Z segue a distribuição Raiz de Gama.

Na ausência de um modelo preciso para o retroespalhamento, representado pela VA X , utilizam-se os próprios pixels da imagem ruidosa para estimar a média e a variância *a priori* de um conjunto de amostras extraídas de regiões homogêneas. Com a aplicação do operador esperança matemática em $Z = XY$, tem-se:

$$E[Z] = E[XY] = E[X]E[Y] = \bar{X}\bar{Y}, \quad (3.1)$$

tomando esta equação válida, porque X e Y são considerados processos independentes [46]. Admitindo que o ruído possua média unitária, $E(Y) = \bar{Y} = 1$, então $E[Z] = \bar{Z} = \bar{X}$, e a variância de Z é obtida conforme a Equação (3.2)[35], sendo:

$$\sigma_Z^2 = E[(Z - \bar{Z})^2] = E[Z^2 - 2Z\bar{Z} + \bar{Z}^2]. \quad (3.2)$$

Haja vista que a refletividade do terreno é constante em áreas homogêneas, então $E[X^2] = E^2[X] = \bar{X}^2$, e o desenvolvimento da Equação (3.2) produz:

$$\begin{aligned} \sigma_Z^2 &= E(X^2)E(Y^2) - 2E(X)E(Y)\bar{X}\bar{Y} + \bar{X}^2\bar{Y}^2 \\ &= \bar{X}^2E(Y^2) - 2\bar{X}^2\bar{Y}^2 + \bar{X}^2\bar{Y}^2 = \bar{X}^2(E(Y^2) - \bar{Y}^2), \end{aligned} \quad (3.3)$$

e observando ainda que $E(Y^2) - \bar{Y}^2 = \sigma_Y^2$, a razão entre o desvio padrão de Z e seu valor médio é dado pela igualdade:

$$(\sigma_Z/\bar{Z}) = \sigma_Y, \quad (3.4)$$

e se a refletividade varia, então deve ser satisfeita a condição:

$$(\sigma_Z/\bar{Z}) > \sigma_Y. \quad (3.5)$$

O coeficiente de variação relativo a um conjunto de pixels retirados da imagem é expresso por:

$$CV = \sigma_Z/\bar{Z}, \quad (3.6)$$

em que a $\overline{(\cdot)}$ representa valor médio e σ_Z é o desvio padrão dos pixels da amostra. A grandeza σ_Y representa o desvio padrão do ruído *speckle*. Em áreas homogêneas, seu valor teórico é igual a $0,5227/\sqrt{n}$ para imagens em amplitude com n visadas, e $1/\sqrt{n}$ para imagens em intensidade [45].

No trabalho de Sephton *et al* [47] está descrito um algoritmo de segmentação desenvolvido para imagens SAR obtidas de zonas de geleiras, que consistem de regiões distintas e estatisticamente homogêneas, das quais alguns atributos podem ser determinados, tais como área, forma, orientação e textura. O processo de segmentação proposto por estes autores consiste de uma cadeia de algoritmos que realizam suavização de ruído usando filtro da mediana, detecção de bordas, ligação entre os pixels semelhantes, rotulação e união de regiões com extração de atributos.

Na detecção de bordas realizada, o conceito de coeficiente de variação é aplicado porque, segundo Sephton *et al* (*op. cit*), testes estatísticos de hipóteses como o teste t de Student são ótimos quando duas amostras de pixels, a serem comparadas, coincidem espacialmente com uma borda. Estes autores afirmam ainda que simulações realizadas determinaram que o coeficiente de variação é uma técnica menos poderosa que o teste t , mas é sensível à presença de bordas, independente da direção das mesmas. Como este critério não fornece informações diretas sobre a direção de bordas, ele é também usado para criar ligações entre pixels vizinhos pertencentes a uma mesma região, segundo o mesmo método de união de pixels, desenvolvido por Oddy & Rye [48]. O coeficiente de variação pode ser usado para discriminar zonas de imagens SAR com texturas diferenciadas, que representam, em geral, distintos tipos de cenas. Este coeficiente é usado também para agrupamento de regiões, como em [49].

Com base nestes estudos, o coeficiente de variação pode ser aplicado como critério para incluir pixels a um segmento, de modo a gerar várias regiões durante esta fase inicial do processo de segmentação. No contexto definido para este trabalho, um segmento é originado a partir de uma janela 3×3 , centrada em um pixel qualquer na imagem SAR, para o qual é calculado o coeficiente de variação, conforme a Equação (3.6). Depois, esta grandeza é comparada com o desvio padrão do ruído *speckle* somado a um pequeno valor δ (*offset*), ou seja, $\sigma_Y + \delta$. O valor $\sigma_Y + \delta$ representa um limite máximo de homogeneidade permitido. Em regiões homogêneas, o coeficiente de variação estimado na janela deve estar próximo do valor do desvio padrão do ruído *speckle*. Assim, é possível identificar se a janela define (ou está) ou não uma zona homogênea, a partir de uma configuração inicial de nove pixels. O cálculo do coeficiente é feito mediante todos os pixels abrangidos pela janela, incluindo o central. Caso não se verifique que $CV < \sigma_Y + \delta$, outro pixel (i, j) é escolhido aleatoriamente na imagem e o mesmo processo de verificação de homogeneidade é aplicado.

3.3 Desenvolvimento do Algoritmo de Crescimento de Regiões Estatístico

A criação das partições iniciais é controlada através de duas matrizes, que possuem as mesmas dimensões da imagem SAR a ser segmentada. Uma delas é denominada matriz de rótulos e a outra é a máscara. Antes de realizar a formação da partição inicial por meio do crescimento de regiões, cada elemento (i, j) da matriz de rótulos recebe um número, correspondente a um rótulo de cada pixel da imagem da radar. Caso a imagem sob análise possua dimensões $k \times m$ pixels, então a matriz de rótulos apresenta $k \cdot m$ rótulos distintos. A organização destes rótulos pode ser seqüencial ou aleatória. Esta matriz é importante, porque ela contém o mapeamento dos rótulos, isto é, a segmentação da ima-

gem de radar. Por sua vez, a máscara define o controle de pixels visitados e incluídos nas regiões, à medida que vão se formando. Todas as entradas da máscara são iniciadas com um sinalizador (*flag*), que pode ser -1 .

O crescimento de regiões é efetuado da seguinte maneira: uma vez que a janela 3×3 de busca de regiões homogêneas, descrita anteriormente, está centrada em algum pixel (i, j) da imagem e que a condição de homogeneidade se verifica, então cada pixel 8-conectado ao pixel central terá seu rótulo mudado para o rótulo deste. Isto implica na geração de um segmento de nove pixels na matriz de rótulos, centrado em (i, j) e identificado por um único número. Na máscara, todas as entradas correspondentes ao pixel central e aos pixels 8-conectados são marcadas como visitadas, passando o *flag* = -1 de cada pixel envolvido para o valor de cinza correspondente.

Para crescer ainda mais esta região semente, são determinados todos os rótulos de seus pixels adjacentes, tornando-se estes candidatos a fazerem parte da região em questão, desde que possam ser incluídos mediante o teste de homogeneidade. Estes pixels candidatos são incluídos um a um, provisoriamente, na região e o novo coeficiente é comparado com o valor $\sigma_Y + \delta$. Se $CV < \sigma_Y + \delta$ para um dado pixel em teste, então ele é incluído definitivamente no segmento, caso contrário ele é descartado e outro é testado. Aqueles pixels incluídos têm seus rótulos mudados para o rótulo do segmento em crescimento, bem como suas entradas na máscara são marcadas como visitadas.

O cálculo do coeficiente de variação a partir da média e desvio padrão amostrais produz uma estimativa grosseira deste parâmetro. O valor determinado do coeficiente de variação possui um desvio em torno do teórico σ_Y , daí a adição de um pequeno valor δ para compensar a variação, também calculado a partir dos pixels.

No cálculo de δ , é desenvolvido um método semelhante ao explicado em [45], o qual originalmente aplica janelas adaptativas para filtragem de ruído *speckle*. Para encontrar a densidade de probabilidade do coeficiente de variação, os autores consideram que seu valor estimado através do janelamento local é uma variável aleatória normalmente distribuída. A Figura 3.3 indica como se comporta tal janela e quais pixels são usados no cálculo do coeficiente de variação (os mais escuros, delimitados pelas linhas cheias) da referência [45]. As explicações que seguem são feitas com base na análise desta figura.




Figura 3.3: Janela adaptativa de dimensões (a) $Q = 7$, que reduz para (b) $Q = 5$.

Nesta ilustração, a janela maior confina em suas bordas um conjunto de amostras (pixels em cinza escuro), usado para a estimação do coeficiente; se o valor calculado mediante a Equação (3.6) define que a janela de lado $Q = 7$ não está em uma região homogênea, então ela é reduzida de tamanho ($Q = 5$), sendo efetuado novamente o cálculo. Ao usar os pixels cinza escuros que definem os dois quadrados, a estimação do coeficiente de variação será igual a $\sigma_Y + \delta$, cujo valor de δ é determinado por [45]:

$$\delta = \sigma_Y \sqrt{\frac{1 + 2\sigma_Y^2}{2N}}, \quad (3.7)$$

sendo $N = 4(Q - 1)$ pixels de amostra da imagem.

Adota-se, nesta dissertação, um procedimento semelhante no algoritmo de crescimento de regiões para cálculo automático de δ . Para tanto, são tomados os N pixels de uma região para estimar o coeficiente, o qual é comparado com um limiar geral $T = \sigma_Y + \eta\delta$, em que η é um pequeno valor de ajuste determinado experimentalmente neste trabalho e igual a 0,075. Este limiar geral é expresso por:

$$T = \sigma_Y \left(1 + \eta \sqrt{\frac{1 + 2\sigma_Y^2}{2N}} \right). \quad (3.8)$$

Uma região é considerada homogênea, caso o valor de coeficiente de variação calculado a partir de seus N pixels seja menor ou igual a T . Quando um pixel candidato for inserido em um segmento sob análise e $CV > T$, então este pixel não deve fazer parte do mesmo. Ao ser inserido provisoriamente no segmento para o cálculo do coeficiente e de T , o tamanho do segmento deve ser considerado como $N + 1$ pixels. Se $CV \leq T$, então o pixel deve ser aceito definitivamente.

Neste algoritmo de crescimento de regiões, as regiões apresentam formas aleatórias à medida que novos pixels vão sendo incluídos. Este procedimento visa minimizar a possibilidade de formação de regiões quadradas, que é um formato típico de algoritmos de divisão e fusão que empregam a técnica conhecida como *quadtree* [50]. Na técnica de *quadtree*, as regiões são divididas em blocos quadrados, que depois são subdivididos em novos blocos quadrados, e assim por diante, segundo algum critério específico para a divisão.

3.4 Restrições para o Crescimento de Regiões

Uma vez que o cálculo do coeficiente de variação valida ou não a incorporação de pixels candidatos para a formação e crescimento de inúmeros fragmentos diminutos, tidos como estatisticamente homogêneos, algumas restrições devem ser impostas, com base nos seguintes princípios:

- Definição dos tamanhos mínimo e máximo das regiões;
- Controle da atribuição de rótulos para os segmentos;
- Controle dos pixels visitados e a
- Marcação das regiões que já atingiram o crescimento.

O tamanho mínimo da região resulta da configuração de janela ilustrada na Figura 3.2, que define um segmento rotulado com nove pixels, inicialmente. Esta configuração em particular deve-se a um compromisso entre a estimativa inicial do coeficiente e a resolução desejada para os contornos dos objetos segmentados. Janelas maiores implicam na perda de resolução e na tendência em produzir regiões com contornos quadrados.

Por outro lado, limitar o tamanho do crescimento das regiões objetiva reduzir a inclusão de pixels que podem pertencer a outras regiões vizinhas. À medida que uma região cresce, a partir dos oito vizinhos conectados ao pixel semente inicial, a estimativa do coeficiente de variação tende a ficar mais confiável.

Foi verificado experimentalmente nesta pesquisa que as regiões devem possuir cerca de 13 a 15 pixels para manter uma qualidade aceitável de preservação de resolução da imagem segmentada. Utiliza-se o valor padrão de 15 pixels e seu aumento depende dos tipos de objetos contidos na imagem e da quantidade de detalhes que a mesma apresenta. Assim, se uma imagem for constituída em grande parte por regiões de campos, por exemplo, os fragmentos a serem criados nesta fase podem ser maiores.

O controle de pixels visitados, como informado anteriormente, é feito mudando o indicador -1 de um pixel para seu valor de cinza correspondente na imagem SAR. Quando uma região atinge o número máximo de pixels, a janela 3×3 é deslocada para outro ponto qualquer da imagem para iniciar o processo de crescimento de um novo segmento, segundo a análise do coeficiente à medida que pixels candidatos vão sendo admitidos. Esta janela, durante a busca de segmentos homogêneos, pode conter um pixel central localizado nos cantos ou nas bordas da imagem e que não possui oito pixels vizinhos válidos. Quando este evento é detectado, a janela é deslocada novamente para outro pixel qualquer, que venha a possuir vizinhança-de-8 válida.

Consoante novos segmentos vão sendo criados, vai diminuindo a quantidade de pixels não visitados. Com isso, surgem mais alguns outros problemas que devem ser contornados, quando a janela muda de posição:

1. O segmento gerado pela janela pode não possuir pixels adjacentes, mas apenas segmentos circunvizinhos já formados;
2. A janela estaciona em um pixel com vizinhança-de-8 válida, porém o segmento está rodeado por outros já criados e alguns pixels não visitados;
3. Alguns pontos no interior da imagem (bem como os que estão nos cantos e nas bordas) constituem pixels não visitados rodeados por segmentos já formados.

Estes três eventos estão ilustrados na matriz de rótulos apresentada na Figura 3.4. O segmento de rótulo 45 é um exemplo do problema número 1, cujos segmentos circunvizinhos têm rótulos 14, 42, 48 e 75. Ele não pode mais crescer neste estágio da segmentação e isto é possível pela análise da máscara; quando um segmento atinge o tamanho máximo permitido ou cresce precocemente, todos os seus pixels estão marcados como visitados. Isso facilita a criação de uma lista de exclusão para identificar que este segmento não deve ser unido com nenhum outro nesta fase. Caso este controle não ocorra, uma região inteira é englobada por um segmento em crescimento, ao invés de um único pixel por vez. Dado que são sempre levantados os vizinhos de uma região de referência (aquela que está em crescimento), a lista é consultada e se algum vizinho estiver presente, automaticamente ele é excluído da lista de vizinhos da região. Assim, o crescimento implica sempre na absorção de pixels vizinhos ainda não visitados, portanto não presentes na lista de exclusão.

Caso o tamanho máximo permitido para uma região seja 15 pixels e esta não atinja esta quantidade, então ocorre crescimento precoce da mesma. Isto significa que, durante seu estágio de crescimento, os pixels candidatos adjacentes não satisfazem o critério de homogeneidade. Esta região cresce, a partir dos nove pixels iniciais, e atinge dez ou doze pixels, por exemplo. Este é o caso do segmento de rótulo 42 na Figura 3.4.

O problema número 3 refere-se à situação em que todos os pixels da imagem ainda não foram visitados e que têm como vizinhos outros pixels e regiões já formadas. Estes pixels devem ser incluídos nas regiões já existentes, desde que satisfaçam algumas condições. Tais pixels geram “buracos” entre os segmentos. A Figura 3.5 mostra o resultado do crescimento de regiões em uma imagem SAR, a partir da visualização da máscara que mapeia as regiões formadas (cor branca) e os vários pixels não visitados (cor preta). Este detalhe possui 1965 segmentos distribuídos ao longo da classe de cor branca e 1156 pixels isolados representados pela classe preta.

Verifica-se ainda que estes buracos devem ser eliminados, porquanto o crescimento de regiões justapostas (de forma análoga à disposição dos segmentos da Figura 3.9, pág. 33) promove a formação de uma partição inicial mais apropriada para a etapa de fusão de regiões.

01	02	14	14	14	14	07	08	09	10
14	14	14	14	14	14	17	18	19	20
42	14	14	14	14	14	48	48	29	30
42	42	42	45	45	45	48	48	48	40
42	42	42	45	45	45	48	48	48	48
42	42	42	45	45	45	48	48	48	48
42	42	75	75	75	75	48	68	69	48
71	72	75	75	75	75	75	75	79	80
81	82	83	75	75	75	75	99	99	99
113	92	93	94	95	96	97	99	99	99
113	113	113	113	113	106	107	99	99	99
113	113	113	113	113	113	117	118	119	120
121	113	113	113	125	126	127	128	129	130

Figura 3.4: Matriz de rótulos com alguns segmentos em formação (14, 42, ..., 99 e 113) e segmentos de único pixel (os demais, nas caixas em branco).

Quando um segmento pára de crescer, um de seus vizinhos é apontado para reiniciar a criação de um novo, ou um pixel não visitado é escolhido aleatoriamente como pixel central para a janela 3×3 .

A etapa final do crescimento de regiões consiste na alocação dos pixels remanescentes (não visitados) que definem os buracos. A estratégia adotada para alocação desses pixels ainda não visitados nos segmentos existentes é executada segundo a observância de algumas restrições baseadas também no cálculo do coeficiente de variação, de acordo com o esquema apresentado na Figura 3.6.

Os procedimentos indicados no fluxograma são possíveis graças à análise realizada na máscara e na matriz de rótulos, as quais permitem localizar os pixels isolados e os não visitados. Cria-se, assim, uma lista desses pixels, para depois encaminhá-los para seus segmentos vizinhos válidos. A alocação destes pixels é feita, mais uma vez, com base nas mudanças do coeficiente de variação, após a inserção temporária dos pixels candidatos em cada segmento vizinho. Isto permite determinar qual o segmento mais apropriado para receber definitivamente um certo pixel candidato, de modo a não alterar em demasia suas características de homogeneidade.




Figura 3.5: Visualização de uma máscara de 100×100 pixels, gerada pelo algoritmo de crescimento de regiões.

Para finalizar esta etapa, os pixels isolados remanescentes (marginalizados) são alocados novamente nos segmentos vizinhos válidos, dando continuidade ao crescimento dos mesmos, desde que também as seguintes condições sejam satisfeitas. Estes pixels resultam de sua não alocação através do procedimento disposto na Figura 3.6.

A lógica deste novo processo é a mesma dada no aludido fluxograma, porém os requisitos de teste são estes:

- i. Os rótulos de todos os pixels marginalizados são registrados em uma tabela. Para cada entrada da tabela são retidos todos os segmentos vizinhos de cada pixel marginalizado que não façam parte da mesma. Isso garante que um pixel marginalizado não seja unido com outro, mas inserido em um segmento já definido, quando possível;
- ii. Um pixel marginalizado é inserido em cada segmento vizinho e os coeficientes são atualizados;
- iii. O pixel marginalizado fica definitivamente no segmento, cujo coeficiente for menor ou igual a σ_Y . Caso contrário, ele fica naquele segmento para o qual sua inserção promoveu a menor alteração de coeficiente.

Estas verificações são executadas até que não haja mais pixels marginalizados. As restrições, como se pode observar, são sempre baseadas na alteração do coeficiente de variação e na consulta da máscara, nunca sendo um pixel encaminhado para a região mais próxima em termos de diferença de valor de cinza, por exemplo. Isso se deve ao fato de o ruído *speckle* modificar o verdadeiro nível de cinza de um pixel ou influenciar no valor médio de uma pequena quantidade de pixels. Pixels isolados são evitados por causa do procedimento seguinte, que é a fusão da grande quantidade de segmentos formados durante o crescimento de regiões.

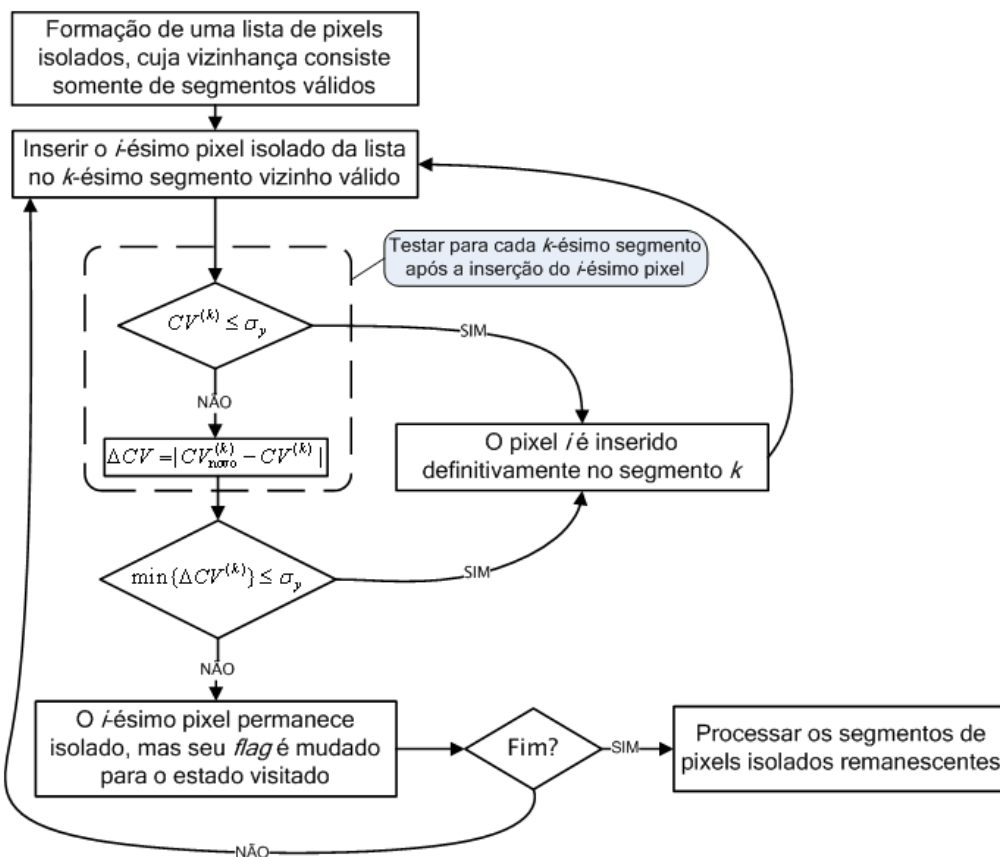


Figura 3.6: Esquema proposto para o processamento estatístico de pixels isolados.

Além das matrizes de rótulos e da máscara, uma matriz de tons médios de cinza ou mapa temático é criada para armazenar o valor médio de cinza de cada segmento. Cada elemento (i, j) do mapa temático que pertença a um determinado segmento recebe o valor

médio de cinza deste, o qual é atualizado sempre que um pixel é incluído na região. Esta matriz serve tanto para visualização quanto para armazenamento de dados para etapa de fusão das regiões.

Terminada a alocação de pixels nos segmentos, o resultado obtido é um mapa de bordas como o exibido na Figura 3.7(b). Estas regiões diminutas devem passar por um processo de fusão ordenado para reduzir a contagem e chegar a uma segmentação final da imagem de radar.




Figura 3.7: (a) Recorte de 200×200 da imagem SAR *Caçapava* (b) mapa de bordas referente a 3982 segmentos gerados pelo crescimento de regiões.

O mapa de bordas apresentado contém os contornos dos fragmentos e os pontos escuros não são buracos, mas sim o interior das regiões. Todos os pixels isolados e marginalizados foram eliminados por inclusão nos segmentos existentes. Caso fosse aplicado um mosaico na imagem da Figura 3.7(a), usando uma grade de 2×2 pixels, haveria $200 \cdot 200/4 = 10.000$ blocos, que no caso é uma quantidade bastante superior a 3982 segmentos. Apesar da divisão em grade ser simples e direta, com obtenção de 10.000 regiões diferentes, haveria grande dispêndio de tempo na fusão das mesmas. Outrossim, as estatísticas obtidas poderiam ser tendenciosas, afetando os resultados da etapa de fusão.

3.5 Segmentação Hierárquica de Imagens

Uma vez finalizada a etapa de supersegmentação por crescimento de regiões e a alocação de pixels isolados da imagem SAR, é necessário reduzir a quantidade de microsegmentos por meio de uniões sucessivas. Deve haver algum tipo de sorteio para fundi-los, porquanto a ordem em que é realizado o processo é muito importante. A fusão de um par de regiões S_i e S_j para formar $S_{i,j}$ ¹ muda completamente a estatística da nova região e uma organização que dê preferência à união de algumas regiões primeiramente, em detrimento de outras, faz-se obrigatória.

Basicamente, o sorteio de regiões mais propícias à fusão é uma questão de otimização, ou seja, consiste da escolha de segmentos bastante similares para serem unidos. Este processo deve ser ordenado e pode ser bastante complexo e demorado. No caso de união de regiões, existem alguns algoritmos que buscam encontrar uma organização otimizada de fusão, como é o caso do *simulated annealing* (SA) [15], desde que uma função custo, temperatura inicial e a função de decréscimo de temperatura sejam especificadas. Em muitos casos, estes parâmetros são determinados empiricamente. A fusão de que se

¹Esta representação indica um novo segmento formado pela união de uma região de rótulo i com uma região de rótulo j , dado que os índices também podem indicar a localização de um pixel na imagem.

fala para o SA refere-se, na verdade, à transposição de pixels entre segmentos vizinhos, até que este processo termine por número de iterações ou por ter sido atingida a temperatura de ‘congelamento’.

Um método mais simples de sorteio proposto em [51, 52] é conhecido como algoritmo de otimização hierárquica passo-a-passo (de HSWO – *Hierarchical Stepwise Optimization Algorithm*). Uma segmentação hierárquica pode ser representada por uma árvore contendo nós e ligações entre estes, em que os segmentos nos níveis mais baixos da árvore são unidos para formar os segmentos de um nível mais alto, de acordo com algum critério que represente a similaridade entre regiões vizinhas. Este critério também é designado como função custo.

A Figura 3.8 representa a analogia entre o processo de união dos segmentos de uma imagem, bem como sua representação em árvore. Uma partição com um grande número de segmentos representa o nível mais baixo da árvore (analogia com suas folhas) e a união progressiva dos segmentos similares vai definindo novos estados da partição, com menor número de segmentos, Figura 3.8(a). O processo de fusão é repetido seqüencialmente até que um número de regiões pré-definido seja atingido. Os procedimentos deste algoritmo são os seguintes:

- i.* definir a partição inicial da imagem;
- ii.* para cada par de segmentos (S_i, S_j) , calcular um custo $C_{i,j}$; encontrar e unir aqueles de mínimo custo;
- iii.* parar quando não houver mais regiões para unir, senão retornar ao passo *ii*.

e para este processo é necessário estabelecer as seguintes variáveis:

1. B_i , que define o conjunto de segmentos adjacentes a S_i , chamados de vizinhança de uma região;
2. D_i , parâmetros descritivos do segmento S_i como, por exemplo, o valor médio de cinza e o tamanho;
3. $C_{i,j} = C(D_i, D_j)$, o custo de unir o segmento S_i com S_j , onde S_j está contido em B_i . O custo é uma função dos parâmetros descritivos de cada região.




Figura 3.8: (a) União de segmentos e (b) diagrama em árvore de uma fusão hierárquica.

A estrutura hierárquica de uma imagem é uma condição bem geral e muito importante para efetivar a união ordenada de regiões. Tal estrutura representa o conceito que uma imagem pode ser dividida em componentes, os quais correspondem aos objetos da cena. Na árvore, os nós são as regiões da partição e as ligações entre eles indicam um conjunto de inclusões.

Os procedimentos de busca de duas regiões mais similares na árvore hierárquica, que descreve a estrutura da imagem em análise, estão descritos no Algoritmo 4.

Algoritmo 4. Algoritmo HSWO (51).

I. Início

- i. $P^0 = \{S_1, S_2, \dots, S_N\}$ (partição ou matriz de rótulos inicial);
- ii. Fazer $k = 0$ e $m = N$;
- iii. Calcular D_i e B_i para todo $S_i \in P^0$;
- iv. Calcular $CS = \{C_{i,j} | S_j \in B_i \text{ e } i \neq j\}$.

II. Unir os segmentos mais similares

- i. $k = k + 1$ e $m = m + 1$;
- ii. Encontrar $C_{u,v} = \min\{C_{i,j}\}$, com $C_{i,j} \in CS$;
- iii. $P^k = (P^{k-1} \cup \{S_m\}) \cap \{S_u, S_v\}^\dagger$;
- iv. Calcular D_m de D_u e D_v ;
- v. $B_m = (B_u \cup B_v) \cap \{S_u, S_v\}^\dagger$;
- vi. $\forall S_j \in B_m, B_j = (B_j \cup \{S_m\}) \cap \{S_u, S_v\}^\dagger$;
- vii. $CS = (CS \cup \{C_{m,j} | S_j \in B_m\}) \cap \{C_{i,j} | i, j = u \text{ ou } v\}^\dagger$.

III. Condição de parada

- i. Parar se não existem mais segmentos para unir;
- ii. Caso contrário, voltar ao passo II.

O Algoritmo 4 inicia a partir de uma configuração inicial ou conjunto de pequenas regiões espacialmente adjacentes. A cada iteração são unidas duas regiões por vez, S_i e S_j , consoante o cálculo de um custo $C_{i,j}$ mínimo para unir tal par de segmentos. Para cada região S_j adjacente à região S_i é calculado um valor de custo $C_{i,j}$. A Figura 3.9 caracteriza um exemplo de uma partição, no qual o segmento S_0 ($i = 0$, com borda mais escura) possui cinco regiões adjacentes ($j = 1, 2, \dots, 5$). S_0 é a região de referência e S_1, S_2, S_3, S_4 e S_5 são as regiões imediatamente adjacentes a S_0 . Caso a região de referência seja S_5 ($i = 5$), então suas fronteiras estarão delimitadas pelas regiões S_0, S_1, S_4, S_6 e S_7 . Essa mesma análise pode realizar-se para cada região e, dessa maneira, é formada uma tabela de adjacências. Esta tabela é conhecida na literatura também por RAG (*Region Adjacency Graph* – grafo de adjacência de regiões) [53] ou tabela de custos.




Figura 3.9: Exemplo de partição de uma imagem.

[†]A intersecção com o complemento implica na remoção destes nós na árvore.

A primeira informação desta tabela refere-se ao rótulo da região i , a segunda ao rótulo da região j e a terceira ao custo de união dado por $C_{i,j}$, calculado segundo algum critério. Estes rótulos são aqueles remanescentes do algoritmo de crescimento de regiões, gerados na partição inicial. A indicação de algum rótulo S_i desta tabela implica na localização precisa de todos os pixels da imagem que compõem o segmento, via matriz de rótulos. A busca de todos os vizinhos também é possível pela especificação de S_i .

Um possível critério de união de regiões pode usar os valores médios de cinza dos dois segmentos S_i e S_j buscados na imagem temática, bem como o tamanho dos mesmos. Sejam $N_i = |S_i|$ e $N_j = |S_j|$ as cardinalidades (número de pixels) das regiões S_i e S_j . Sejam ainda μ_i e μ_j os valores médios de cinza de S_i e de S_j , respectivamente. Uma função de custo para unir duas regiões S_i e S_j , a partir de seus parâmetros descritivos $D = \{N, \mu\}$, é o critério de Ward [53, 54]:

$$C_{i,j} = \frac{N_i N_j}{N_i + N_j} (\mu_i - \mu_j)^2. \quad (3.9)$$

A Equação (3.9) é um critério particular para o caso em que uma imagem é aproximada por segmentos com níveis de cinza similares. Em [51] há um exemplo ilustrativo acerca da execução do algoritmo HSWO a partir de uma imagem 4×4 (Figura 3.10(a)), cuja partição inicial está exibida na Figura 3.10(b). A árvore representativa dessa partição está ilustrada na Figura 3.11 e o critério adotado é o expresso pela Equação 3.9.




Figura 3.10: (a) Valores de cinza dos pixels e a (b) partição inicial de uma pequena imagem. Adaptado de [51].

O processo passo-a-passo de união implica que somente duas uniões devem ocorrer por vez na árvore, com base no menor custo para uni-las. No exemplo da Figura 3.10, o algoritmo inicia com sete segmentos (S_1, S_2, \dots, S_7) no nível mais baixo da hierarquia e são definidas as regiões componentes da partição inicial P^0 . Na árvore está representada a seqüência de uniões que devem ocorrer, começando com os segmentos S_2 e S_5 para formar o segmento S_8 .

A partir da configuração inicial dada pela Figura 3.10(b), a tabela de custos é gerada determinando-se as relações de adjacência entre pares de regiões S_i e S_j , bem como o custo $C_{i,j}$. Isso é realizado para todas as regiões da partição através de uma rotina computacional que estabeleça as relações de vizinhança, usando a matriz de rótulos e a imagem original como dados de entrada. Neste exemplo, a matriz de rótulos é a partição inicial dada pela Figura 3.10(b). O custo é calculado segundo a Equação (3.9), usando os parâmetros descritivos de cada região. Os valores em negrito existentes na Tabela 3.1 representam o conjunto de custos iniciais $C_{i,j}$. Os mínimos custos por iteração estão indicados dentro das caixas.

Cada par de segmentos unidos dá origem a um novo rótulo, distinto de todos aqueles existentes na partição P^k . De acordo com esta tabela, uma vez estabelecidas todas as relações de adjacência para a partição P^0 ($k = 0$), são calculados os respectivos custos (passo i de I do Algoritmo 4) com base nos descritores de cada região.

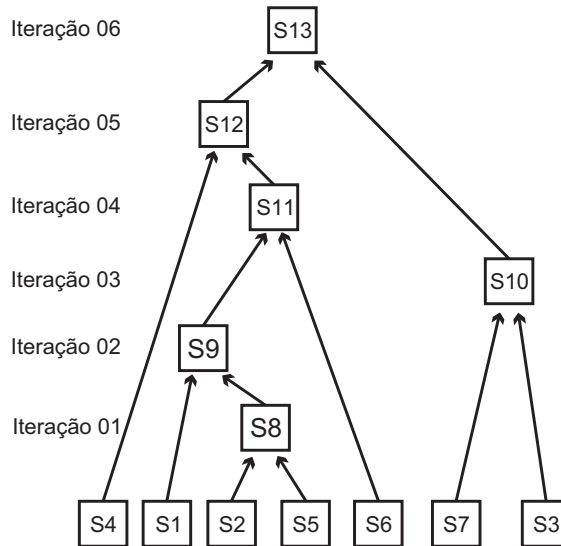


Figura 3.11: Árvore representando a seqüência de uniões dos nós.

Nesta tabela, $S(i, j)$ (primeira coluna) indica os rótulos das regiões a serem testadas para unir, com base nos custos $C(i, j)$. O algoritmo determina o menor custo por iteração, e as regiões unidas passam a ter um rótulo distinto dos demais. O mínimo valor de custo (Algoritmo 4 - passo *ii* de *II*) encontrado na primeira iteração é 1,2 e indica que os segmentos S_2 e S_5 têm prioridade para compor a nova região S_8 , por serem os mais similares. Logo, estas regiões deixam de existir na partição seguinte P^1 ($k = 1$) e S_8 faz fronteira com as regiões remanescentes (1, 3, 4, 6 e 7). Pode-se perceber que estes segmentos não são afetados durante a formação de S_8 . Desse modo, é preciso apenas atualizar os descritores de S_8 e os novos custos para cada região vizinha. Este processo iterativo continua até não existir mais regiões para unir. Aquelas que não possuem relações de vizinhança ou que não podem ser unidas devem apresentar elevado custo de união.

O algoritmo HSWO é um processo não supervisionado, do ponto de vista da avaliação de similaridade e união de segmentos, cuja efetivação depende do tipo de função custo estipulada. No entanto, da forma como este algoritmo está estabelecido, sempre há um custo mínimo e as uniões ocorrem até que reste somente um único segmento. Para contornar este problema, condições de parada podem ser determinadas com o uso de limiares de similaridade ou a definição de um número máximo de regiões.

No caso da segmentação, em especial das imagens de radar, não se sabe precisamente quantas regiões a versão segmentada deve possuir, principalmente quando não existem muitas informações acerca das mesmas. O processamento da imagem pelo algoritmo objetiva determinar as regiões relevantes, com base em seus parâmetros de entrada. Uma das vantagens do algoritmo HSWO é a coordenação da união, desde que uma função custo seja bem definida para o tipo de aplicação.

Tal procedimento pode ser usado para definir a ordem das fusões e sua combinação a outro tipo de teste pode melhor validar a união do par de regiões de mínimo custo na hierarquia. Um método assim foi proposto em [55, 56] para encontrar automaticamente o número de segmentos de uma imagem, com base no teste estatístico *t* de Student aplicado à diferença entre os valores médios das regiões e um fator de correção. Esta versão foi denominada por seus autores como HWSO modificado – MHSO.

Como antes exposto, o valor médio de cinza do conjunto de pixels de uma região, unicamente, não caracteriza bem os segmentos formados para a fusão de regiões em imagens SAR. Critérios de fusão de regiões como a Equação (3.9), que está baseado

apenas na diferença entre valores médios de cinza e na cardinalidade das regiões, não fornecem resultados plausíveis para imagens de grande conteúdo ruidoso. Esta diferença é bastante influenciada pela presença de ruído e não constitui o que se pode chamar de detector de falso alarme constante (*cfar*). No entanto, a razão de médias é comumente aplicada para esta finalidade [57, 58].

Tabela 3.1: Custos por iteração para a segmentação ilustrada na Figura 3.10.

$S(i,j)$	$C_{i,j}$	it1	it2	it3	it4	it5	it6
(1,2)	1,5	1,5					
(1,4)	60,7	60,7	60,7				
(1,5)	4,8	4,8					
(1,6)	30,0	30,0	30,0				
(2,3)	181,5	181,5					
(2,4)	48,0	48,0					
(2,5)	1,2	1,2					
(3,5)	120,0	120,0					
(3,7)	10,8	10,8	10,8	10,8			
(4,5)	32,7	32,7					
(5,6)	9,0	9,0					
(5,7)	49,0	49,0					
(6,7)	16,0	16,0	16,0	16,0			
□	□	□	□	□	□	□	□
(8,1)	3,7		3,7				
(8,3)	210,7		210,7				
(8,4)	48,1		48,1				
(8,6)	18,5		18,5				
(8,7)	82,5		82,5				
(9,3)	270,0			270,0			
(9,4)	58,7			58,7	58,7		
(9,6)	27,2			27,2	27,2		
(9,7)	105,6			105,6			
(10,6)	48,1				48,1		
(10,9)	303,1				303,1		
(11,4)	48,4					48,4	
(11,10)	277,0					277,0	
(12,10)	244,6						244,6

O processo de união após o crescimento de regiões consiste basicamente na verificação da existência de bordas entre os segmentos. A fusão deve ser executada através de outro critério mais robusto, enquanto a escolha dos pares S_i e S_j para teste pode ser feita através do método HSWO, usando uma função de custo apropriada.

Para suplantarmos a falta de um critério de parada ideal para este algoritmo, outra proposta deste trabalho é utilizar um teste de hipóteses conveniente para realizar ou não a fusão de duas regiões de menor custo, eleitas pelo algoritmo hierárquico. Para isso, uma tabela de custos é gerada segundo o cálculo do custo de fusão, de acordo com alguma fórmula matemática, que leve em conta descritores apropriados de cada região, a exemplo da Equação (3.9). A partir da tabela de custos, que nada mais é do que uma matriz alocada na memória, pode-se iniciar o algoritmo de fusão combinado ao teste de hipóteses. Sendo eleitas duas regiões pelo algoritmo HSWO, o teste de hipóteses valida se elas devem ser unidas ou não, com base nas peculiaridades das amostras, do teste empregado e de seus requisitos. Caso o teste não confirme a união, o custo é mudado para um valor muito grande. Depois, duas outras regiões de mínimo custo devem ser buscadas na tabela e este processo ocorre iterativamente até que se atinja a condição de parada.

As seções seguintes abordam alguns testes de hipóteses e funções de custo aplicados neste trabalho e como estes dois modelos podem afetar o processo de fusão.

3.6 Fusão de Regiões por Testes de Hipóteses

A fusão de regiões pode ser realizada consoante testes de hipóteses estatísticos, sendo bem conhecidos os testes t de Student e t de variâncias desiguais. Nesta seção, pretende-se avaliar qualitativamente a aplicação destes testes na segmentação de imagens SAR e propor o uso de outro, em virtude de certas limitações detectadas para os primeiros. O teste t é utilizado em certas versões do algoritmo MUM [25, 40] e o teste t de variâncias desiguais é aplicado na união de regiões no artigo [59].

3.6.1 Testes de hipóteses

Um teste de hipóteses é um procedimento para determinar se certa afirmação sobre alguma característica de uma população é válida ou razoável. Nessa análise, alguns conceitos precisam antes ser explicados, como hipótese nula, hipótese alternativa, nível de significância, valor- p .

A hipótese nula (H_0) refere-se à afirmação original (por exemplo, que duas regiões S_i e S_j podem ser unidas). A hipótese alternativa (H_1) é aquela contrária à primeira. O nível de significância² (α) está relacionado com o grau de certeza de que se necessita para rejeitar a hipótese nula, em favor da hipótese alternativa. Muitas vezes, dependendo do tamanho da população, não se pode ter certeza sobre uma afirmativa. Então, é possível rejeitar a hipótese nula de imediato, se a probabilidade de observar certo resultado for menor que o nível de significância. Valores típicos de nível de significância α podem ser, por exemplo, 5% ($\alpha = 0,05$), 1% ou 0,1% [40]. O objetivo de um teste de hipóteses é sempre rejeitar a afirmação H_0 . Para o nível de significância 5%, a probabilidade de rejeitar erroneamente a hipótese nula, quando ela realmente é verdadeira, é de 5%. Se for necessário que o teste apresente menos erros, então se deve diminuir o valor de α .

Já o valor- p é uma probabilidade calculada de acordo com o modelo de distribuição das amostras da população. Quando esta probabilidade é comparada a um limiar (que é o nível de significância), a hipótese nula é rejeitada se valor- $p < \alpha$.

3.6.2 Teste t de Student

O teste t de Student é aplicado para determinar se as médias de duas amostras colhidas de uma população são significativamente diferentes, desde que suas variâncias sejam próximas. Nesta seção, o teste t de Student é combinado ao algoritmo HSWO para validar a fusão de duas regiões A e B (ou S_i e S_j) escolhidas na estrutura hierárquica como possuindo o mínimo custo de união. No algoritmo de segmentação de imagens SAR proposto por [40], este teste de hipóteses é aplicado na fusão de regiões.

A variável t é obtida por [27]:

$$t = \frac{\bar{x}_A - \bar{x}_B}{s_D}, \quad (3.10)$$

em que \bar{x}_A e \bar{x}_B são os valores médios de cinza de cada região. O desvio padrão conjunto destas regiões, com N_A e N_B pixels, é expresso por:

²O nível de significância de um teste de hipóteses é comumente representado na literatura através do símbolo α . Neste trabalho, α também é usado para representar o grau de rugosidade de uma superfície.

$$s_D = \sqrt{\frac{\sum_{i \in A} (x_i - \bar{x}_A)^2 + \sum_{i \in B} (x_i - \bar{x}_B)^2}{N_A + N_B - 2} \left(\frac{1}{N_A} + \frac{1}{N_B} \right)}. \quad (3.11)$$

Uma vez obtido o valor da variável t através da Equação (3.10), com $v = N_A + N_B - 2$ graus de liberdade, é possível calcular uma função densidade de probabilidade $P(t|v)$. Em geral, esta função é tabelada para alguns valores de t e v . Do ponto de vista computacional, é necessário gerar a função densidade, cuja definição matemática é dada por [27]:

$$P(t|v) = 1 - I_{\frac{v}{v+t^2}}(v/2, 1/2), \quad (3.12)$$

em que $I_k(a, b)$ é a função beta incompleta [21], que possui valores limites $I_0(a, b) = 0$ e $I_1(a, b) = 1$. $P(t|v)$ é a probabilidade de t ser menor que o valor observado da Equação (3.10), dado o grau de liberdade v e caso as médias populacionais sejam, de fato, iguais (hipótese H_0).

De acordo com este teste, duas médias são significativamente diferentes se, por exemplo, $P(t|v) > 0,99$. De outra forma, $1 - P(t|v)$ é o nível de significância no qual a hipótese que as duas médias sejam iguais possa ser descartada. Caso $1 - P(t|v) < p_0$, em que p_0 é um pequeno valor ou limiar escolhido pelo usuário (5%, 1%, 0,01%, por exemplo), as duas regiões são significativamente diferentes, caso contrário, elas são unidas.

3.6.3 Teste t de variâncias desiguais

O teste t de variâncias desiguais é aplicado em [59] para testar a hipótese de unir segmentos e, portanto, reduzir a quantidade de regiões geradas pela aplicação do operador ROEWA (*Ratio Of Exponentially Weighted Averages*) e a transformada *watershed*. Segundo os autores, o teste t de Student aplica-se quando as variâncias das populações não são significativamente diferentes. Eles consideram que esta hipótese, em geral, não é satisfeita em imagens de radar, pois o nível de ruído *speckle* e a variância imposta aos dados dependem da refletividade da região.

A variável t deste teste é formulada como [59]:

$$t = \frac{|\bar{x}_A - \bar{x}_B|}{\sqrt{\hat{\sigma}_A^2/N_A + \hat{\sigma}_B^2/N_B}}, \quad (3.13)$$

em que $\hat{\sigma}_A^2$ e $\hat{\sigma}_B^2$ são as variâncias estimadas das regiões. O grau de liberdade v é calculado de maneira diferente:

$$v = \frac{\left(\frac{\hat{\sigma}_A^2}{N_A} + \frac{\hat{\sigma}_B^2}{N_B} \right)^2}{\frac{(\hat{\sigma}_A^2/N_A)^2}{N_A-1} + \frac{(\hat{\sigma}_B^2/N_B)^2}{N_B-1}}. \quad (3.14)$$

A variável t da Equação (3.13) é modelada aproximadamente como a distribuição t de Student [27] e sua função densidade é dada pela Equação (3.12).

3.6.4 Segmentação empregando diferentes critérios de custo e testes de hipóteses

Nesta seção são apresentadas algumas segmentações de um recorte 256×256 da imagem SAR *Caçapava*, em amplitude e $n = 1$ visada³, de modo a avaliar a aplicação

³O número de visadas estimado para esta imagem é $n = 1,035$, usando o algoritmo da referência [16].

de certas funções de custo para escolha das regiões candidatas e a efetivação da fusão mediante os testes de hipóteses apresentados. A Figura 3.12 mostra o diagrama de fluxo de informação e os processos envolvidos no segmentador proposto.

A partir da tabela, duas regiões de mínimo custo global são eleitas para testar a hipótese de serem unidas. O controle é feito através de um limiar p_0 (parâmetro de controle ou nível de significância) estabelecido pelo usuário, que determina a quantidade de regiões obtidas ao final do processo de união.

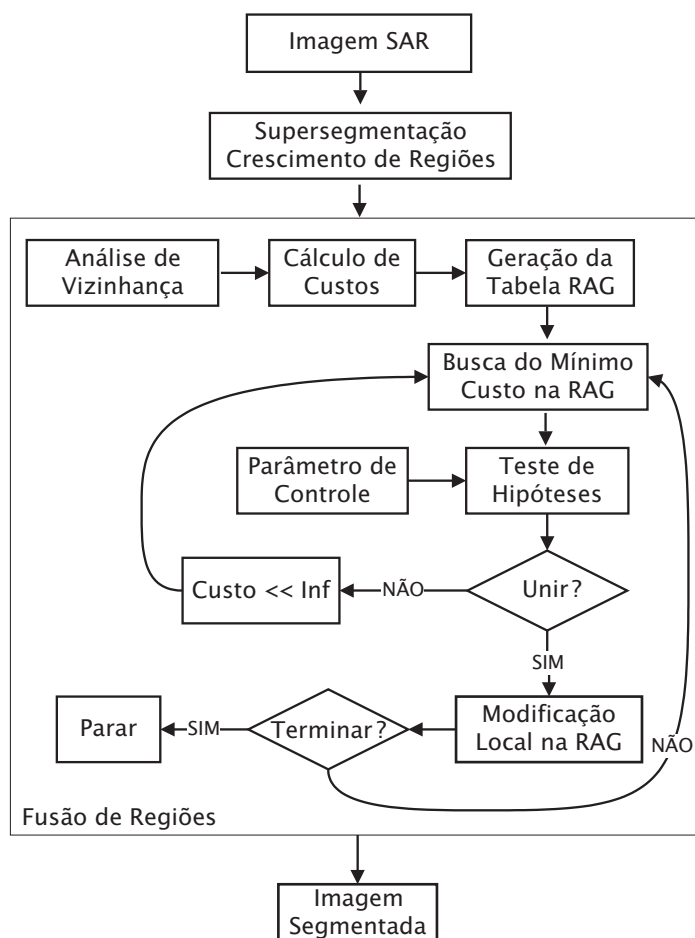


Figura 3.12: Diagrama do processo de segmentação desenvolvido para imagens SAR.

Caso seja aceita a hipótese H_0 para a fusão do par de regiões S_i e S_j , ocorre a atualização dos nós da árvore. Por outro lado, se a hipótese alternativa H_1 for estabelecida (as regiões não podem ser unidas), o custo das regiões eleitas muda para um valor elevado. Consoante estes princípios, um novo par é eleito pelo HSWO e o teste de hipóteses é aplicado mais uma vez, até que não haja mais segmentos para unir. O critério de parada é o obtido pela análise da tabela, ou seja, a fusão pára quando todos os custos das regiões remanescentes apresentam valores muito grandes (tendendo a infinito). A combinação do método HSWO com o teste de hipóteses exclui a opção do usuário determinar taxativamente a quantidade final de segmentos, e o controle de todo o processo de fusão é feito por meio do parâmetro p_0 .

De acordo com o método apresentado, avalia-se qualitativamente a aplicação da função de custo da Equação (3.9), pág. 34, na segmentação do recorte da imagem *Caçapava*. A tabela de custos é gerada usando aquela função de custo, a partir da partição contendo 5083 regiões. As imagens temáticas estão exibidas na Figura 3.13.

A aplicação do teste t na fusão de dois segmentos resulta na criação de 509 regiões, cujos tons médios estão impressos na Figura 3.13(c). O mapa de bordas está indicado na Figura 3.13(d), obtido através da matriz de rótulos. Usando a mesma tabela inicial de custos do exemplo anterior, porém aplicando o teste t de variâncias desiguais, produz-se a segmentação final da imagem SAR com 493 regiões, indicada na Figura 3.14. O nível de significância adotado nestes exemplos é $p_0 = 0,001$.




Figura 3.13: Fusão de regiões usando o teste t (a) recorte de 256×256 de *Caçapava* (b) mapa temático inicial (5083 regiões) (c) mapa temático final (509 regiões) e (d) mapa de bordas.

A grande quantidade de regiões existente nas duas segmentações ainda não é satisfatória e mais fusões devem ocorrer. Percebe-se que a lagoa maior, presente no centro da imagem SAR, ainda se encontra bastante particionada. Alguns trechos do rio estão mais evidentes no mapa de bordas da Figura 3.14(b) do que no mapa da Figura 3.13(d).

A existência de muitas regiões, em primeiro lugar, ocorre por causa das características da função custo da tabela. Se este critério não for muito bem especificado, com base em descritores relevantes para as regiões, a eleição do par de de mínimo custo global na árvore hierárquica pode ficar comprometida. Hipoteticamente, como a ordem é importante, poderia a função custo eleger um par inapropriadamente, em detrimento de outro, e o teste de hipóteses indicar que as regiões desse par devam ser unidas. Em segunda análise, os testes de hipóteses determinam as uniões dos pares com maiores chances de erro, por serem também inapropriados para esta finalidade.

Um ponto importante e que se deseja também colocar em discussão, segundo os resultados produzidos, é o formato das regiões pós-fusão. Nos mapas de bordas das Figuras 3.13(d) e 3.14(b) há muitas regiões com formatos irregulares, sendo conseqüências de fusões inapropriadas de segmentos e da influência do ruído nas medidas.

A Figura 3.14(c) é um exemplo claro de imagem SAR segmentada, com várias regiões irregulares, que pode ser obtida quando o critério de custo é formulado com descritores e modelos estatísticos ineficientes.




Figura 3.14: Fusão de regiões usando o teste t de variâncias desiguais (a) mapa temático final (493 regiões) (b) mapa de bordas correspondente (c) regiões com formas irregulares (*crinkle*).

3.6.5 Proposta de um critério de custo baseado em médias locais

No caso das segmentações ilustradas nas Figuras 3.13 e 3.14, os descritores utilizados são apenas o tamanho e valor médio dos segmentos, e nenhuma outra informação adicional. Como resultado, obtém-se várias regiões para as quais os testes de hipóteses utilizados não promovem mais fusões adequadas, porque muitas das regiões eleitas como similares pelo critério de custo da Equação (3.9) efetivamente não o são. Outro problema consiste na escolha do teste de hipóteses, que pode ser inapropriado para certas aplicações.

Na referência [40] é discutida uma estratégia para formar regiões regulares e leva em consideração o tamanho dos segmentos, a variável t do teste de Student e o tamanho da fronteira comum às duas regiões, Q_{AB} , para calcular uma função custo apropriada. Neste modelo, quanto maior for a fronteira comum entre duas regiões \mathcal{A} e \mathcal{B} , menor será o custo para uní-las, observadas suas propriedades estatísticas. Regiões com formas regulares apresentam poucos vizinhos e favorecem a aceleração do processo de fusão.

Um outro algoritmo utilizado para coordenar a união de regiões é proposto em [60], denominado IPMBM (*Iterative Pairwise Mutually Best Merge Criterion* – melhor critério iterativo de união aos pares). Basicamente, este algoritmo consiste de uma seqüência de restrições impostas à união de dois segmentos \mathcal{A} e \mathcal{B} . Uma destas restrições, chamada de controle de bordas fracas, é feita com base na similaridade apenas dos pixels da fronteira entre duas regiões. Cada pixel pertencente ao segmento \mathcal{A} possui pelo menos um pixel, dentre seus vizinhos-de-4, pertencente ao segmento \mathcal{B} . No IPMBM, para cada pixel de borda é computada a similaridade pixel a pixel e um valor global de ‘força’ é calculado para todos os pixels de borda relevantes. Este valor global é então comparado a um limiar imposto pelo usuário para finalmente determinar se as duas regiões \mathcal{A} e \mathcal{B} podem ser unidas de vez, após a verificação de todas as outras restrições. O trabalho [60] reflete a aplicação do IPMBM para união de segmentos em imagens óticas, não corrompidas por ruído multiplicativo, por causa do processo de aquisição.

Com base nestes princípios do método IPMBM, outra contribuição deste trabalho é combinar uma amostra reduzida de pixels de fronteira à estratégia ditada em [40], usando a razão de médias para definir um novo critério de custo para a formação da tabela RAG. Assim, é proposta uma nova função de custo com base nos seguintes descritores:

- A média dos pixels de fronteira;
- O tamanho da borda comum e
- Os tamanhos das populações de fronteira.

A estratégia adotada neste trabalho para formular tal critério de custo é usar as médias de fronteira (ou locais), ao invés das médias gerais de um par de segmentos (\bar{z}_A e \bar{z}_B). Isto porque o valor médio, obtido a partir de todos os pixels de uma região, vai tornando-se um descritor não confiável à medida que a fusão evolui, porque ocorre sua degradação.

Uma situação clara acerca desta degradação é dada em [61], no qual o autor considera uma imagem com duas regiões: a primeira é uma região grande, cujas intensidades dos pixels crescem suavemente ao longo da sua área; a outra é uma região pequena, cujos valores de cinza dos pixels são aproximadamente constantes. Se apenas o valor médio de cinza for usado como descritor de cada região, esta grandeza descreve mais precisamente a região menor. Um caso crítico ocorre quando duas regiões como estas possuem o mesmo valor médio de cinza. Elas seriam, por tal motivo, consideradas similares e, conseqüentemente, unidas.

Essa união errônea colocaria a região menor nas proximidades de uma porção da região maior, em que os valores de intensidade de cinza seriam significativamente diferentes da primeira. Esse é um erro típico quando se emprega o valor médio de cinza dos segmentos como estatística em critérios de fusão. Verifica-se experimentalmente que, mesmo com baixos valores de p_0 , a utilização do critério de Ward da Equação (3.9) favorece a escolha de certos pares de segmentos, provocando uniões indesejadas.

Por outro lado, a combinação das médias locais dos pixels de fronteira com outros descritores pode levar a um melhor critério de custo para eleger regiões similares na árvore hierárquica. A Figura 3.15 ilustra uma fronteira entre duas regiões \mathcal{A} e \mathcal{B} , em que os símbolos ‘o’ e ‘x’ representam pixels de borda, enquanto ‘+’ e ‘⊙’ são suas respectivas vizinhanças. Os pixels ‘o’ e ‘+’ juntos definem a população de pixels da borda da região \mathcal{A} , enquanto a população de fronteira de \mathcal{B} é formada pela união dos pixels ‘x’ e ‘⊙’.

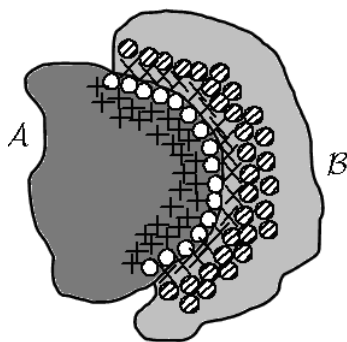


Figura 3.15: Amostras locais de pixels de fronteira e a vizinhança dos mesmos, para dois segmentos \mathcal{A} e \mathcal{B} .

As coordenadas (i, j) dos pixels de borda são obtidas usando vizinhança-de-4 em uma rotina que busca na matriz de rótulos, enquanto as coordenadas de seus pixels vizinhos podem ser encontradas usando conectividade de 4 ou de 8. A escolha do tipo de conectividade depende do tamanho da população de fronteira que se deseja obter.

O fundamento associado ao uso de pixels localizados nas interfaces de segmentos reside em seu poder de influência na fusão, em detrimento daqueles mais distantes. Os valores médios dos pixels (ou das populações) de borda tendem a ser mais parecidos ou mais distintos para cada par de regiões vizinhas, e esta propriedade pode ser usada para inferir sobre a similaridade nas fronteiras.

Isso se configura em uma janela adaptativa ao longo da fronteira entre dois segmentos, que colhe amostras dos pixels ruidosos e permite calcular a razão de médias,

segundo o mesmo princípio dos detectores de borda. Restringindo o cálculo do valor médio aos pixels de fronteira ou à população associada a estes, evita-se a influência de pixels mais distanciados de uma determinada interface $\mathcal{A}-\mathcal{B}$. Uma vez determinados os pixels fronteiros, o custo pode ser estabelecido como:

$$C_{\mathcal{A},\mathcal{B}} = \frac{\min(N_{\mathcal{A}'}, N_{\mathcal{B}'}) \cdot r}{Q_{\mathcal{A},\mathcal{B}}^2}, \quad (3.15)$$

em que $N_{\mathcal{A}'}$ e $N_{\mathcal{B}'}$ indicam as quantidades de pixels localizados em cada lado da fronteira entre as duas regiões. $Q_{\mathcal{A},\mathcal{B}}$ é o comprimento da borda comum, em pixels, e r é expresso por:

$$r = 1 - \min \left\{ \frac{\bar{z}_{\mathcal{A}'}}{\bar{z}_{\mathcal{B}'}} , \frac{\bar{z}_{\mathcal{B}'}}{\bar{z}_{\mathcal{A}'}} \right\}, \quad (3.16)$$

sendo $\bar{z}_{\mathcal{A}'}$ e $\bar{z}_{\mathcal{B}'}$ os valores médios de cada conjunto de pixels localizado na borda. Algumas condições de contorno devem ser impostas quando, porventura, estes valores forem nulos.

A retenção da menor quantidade de pixels de fronteira na Equação (3.15) implica na absorção de regiões pequenas e diminui a quantidade de pequenos segmentos ao final do processo de fusão. Trocando a função de custo definida na Equação (3.9), pág. 34, pela Equação (3.15), é obtida a segmentação ilustrada na Figura 3.16 para o teste t . Na Figura 3.17 está disposta a imagem temática e o mapa de bordas, obtidos com o teste t de variâncias desiguais. O nível adotado para estas segmentações é $p_0 = 0,001$.




Figura 3.16: Fusão de segmentos usando o novo critério de custo e o teste t de Student (a) mapa temático (b) mapa de bordas (314 segmentos).

É possível observar uma redução da quantidade de regiões e a melhoria do aspecto visual dos contornos nestas segmentações. Portanto, o critério da Equação (3.15) é usado doravante na geração da tabela de custos (RAG). Todavia, os testes de hipóteses descritos servem para comparar se as médias de duas populações são significativamente diferentes.

Tal fato, deveras, leva ao questionamento sobre a utilização dos mesmos com dados SAR sem pré-processamento. Estes testes assumem que uma população (de pixels) tenha variâncias iguais (teste t) ou variâncias diferentes (teste t de variâncias desiguais) e desconhecidas, em ambos os casos. Estes testes são mais eficientes quando comparam médias de populações normalmente distribuídas, o que não é o caso para dados de radar, salvo quando estes são processados sob algumas condições (por exemplo, grande número de visadas ou que tenham sofrido prévia suavização de ruído). O uso destes testes paramétricos, em desacordo com dados não distribuídos segundo a Normal, pode aumentar a chance de erros.




Figura 3.17: Fusão de segmentos usando o novo critério de custo e o teste t de variâncias desiguais (a) mapa temático (b) mapa de bordas (373 segmentos).

Estes exemplos de segmentação do recorte da imagem SAR *Caçapava* possuem ainda vários fragmentos e pequenas regiões. A fusão através destes testes, ao utilizar diretamente os pixels originais das imagens, não é muito satisfatória. Um teste de hipóteses que apresenta melhor desempenho em combinação com o HSWO é o teste de Kolmogorov-Smirnov para duas amostras, sendo tal combinação mais outra contribuição deste trabalho.

3.6.6 Teste de Kolmogorov-Smirnov

O teste de Kolmogorov-Smirnov (KS) é um teste não-paramétrico aplicável a funções de distribuição contínuas com variável independente única, ou seja, um conjunto de dados no qual cada valor x pode ser associado a um único valor $F(x)$ ⁴ [27]. Este teste é baseado nos teoremas de Kolmogorov e de Smirnov e advém do conceito de função distribuição acumulada, também chamada de função de distribuição empírica.

Dado um vetor aleatório N -dimensional (X_1, X_2, \dots, X_N) e (x_1, x_2, \dots, x_N) possíveis valores que este pode assumir, então o conjunto $\{x_1, x_2, \dots, x_N\}$ é sorteado em ordem crescente, de modo que seja obtida a seqüência $x_{r_1}, x_{r_2}, \dots, x_{r_N}$ que satisfaça as inequações

$$x_{r_1} < x_{r_2} < \dots < x_{r_N}.$$

A função distribuição de probabilidade empírica (*fde*), denotada por $S_N(x)$, é obtida a partir dos dados sorteados e esta função fornece a fração de pontos localizados à esquerda de algum valor x_i . $S_N(x)$ é constante entre pontos consecutivos e realiza um salto igual a $1/N$ em cada valor x_i , o que torna seu gráfico semelhante a uma escada [27]. A Figura 3.18 ilustra os gráficos de duas funções empíricas e $F(x)$ representa a função distribuição de probabilidade teórica de um conjunto de dados.

Neste gráfico, $S_{N_1}(x)$ e $S_{N_2}(x)$ estão separadas entre si pela maior distância D' e tais *fdes* são obtidas através de:

$$S_N(x) = \begin{cases} 0, & x \leq x_{r_1}, \\ \frac{k}{N}, & x_{r_k} < x \leq x_{r_{k+1}}, \quad k = 1, 2, \dots, N-1. \\ 1, & x \leq x_{r_N} \end{cases} \quad (3.17)$$

Caso seja tomado um conjunto de dados de tamanho N , o número de elementos amostrais observados que sejam menores que x é igual a $NS_N(x)$. $S_N(x)$ assume valores no

⁴A variável x não representa o valor real e desconhecido do pixel, sendo usada apenas para ilustrar a formulação matemática deste teste de hipóteses.

intervalo $[0, 1]$ e é uma função monotonicamente⁵ crescente e contínua a partir da esquerda. De acordo com [27], conjuntos de amostras com distribuições diferentes apresentam *fdes* distintas, segundo a definição expressa na Equação (3.17).

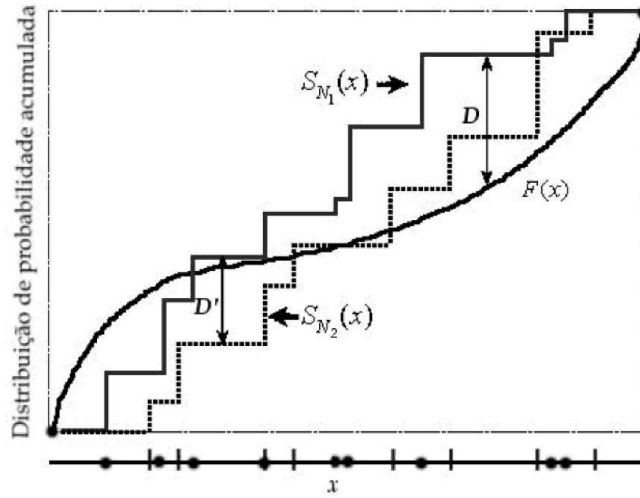


Figura 3.18: Estatísticas de Kolmogorov-Smirnov D e D' . Adaptada de [27].

Sendo $S_N(x)$ uma função da variável independente x , ela possui todas as propriedades de uma função de distribuição, cujo nome é ‘empírica’ para diferenciar da distribuição teórica acumulada $F(x)$. De acordo com [62], é extremamente útil encontrar a relação entre a *fde* $S_N(x)$ e a distribuição teórica $F(x)$, e esta relação existe. Quando o número de amostras assume valores muito grandes ($N \rightarrow \infty$), para cada valor x , vale a probabilidade:

$$P \left[\lim_{N \rightarrow \infty} S_N(x) = F(x) \right] = 1. \quad (3.18)$$

Outros meios de se relacionar $S_N(x)$ e $F(x)$ poderia ser a medida da área absoluta entre as curvas ou a integral da diferença média quadrática. A medida D indicada na Figura 3.18 é uma medida simples, sendo definida como a diferença absoluta entre duas funções de distribuição acumuladas. O teste KS tem como base dois teoremas, propostos por Kolmogorov e por Smirnov, citados e provados em [62], sendo que o teorema de Smirnov requer que a população da qual as amostras são colhidas apresente distribuição teórica acumulada $F(x)$ contínua. Para comparar um conjunto de dados $S_N(x)$ com $F(x)$, a distância de Smirnov é dada por [27]:

$$D = \max_{-\infty < x < \infty} |S_N(x) - F(x)|, \quad (3.19)$$

enquanto para comparar duas *fdes* $S_{N_1}(x)$ e $S_{N_2}(x)$, a distância é:

$$D' = \max_{-\infty < x < \infty} |S_{N_1}(x) - S_{N_2}(x)|. \quad (3.20)$$

A função que permite calcular a significância do teste, de modo a aceitar ou reprová-la hipótese nula (de que dois conjuntos $\{X_{11}, X_{12}, \dots, X_{1N}\}$ e $\{X_{21}, X_{22}, \dots, X_{2M}\}$ são VAs independentes com a mesma função $F(x)$), é a função limite de Kolmogorov [62]. Tal função é representada pelo somatório dado na Equação (3.21).

⁵Função de variável real que no seu domínio é sempre crescente, ou sempre decrescente, ou sempre não-crescente, ou sempre não-decrescente.

$$Q(\lambda) = \begin{cases} \sum_{k=-\infty}^{\infty} (-1)^k e^{-2k^2\lambda^2}, & \lambda > 0. \\ 0, & \lambda \leq 0 \end{cases} \quad (3.21)$$

Há uma alternância de sinal do termo exponencial no somatório, sendo que $Q(\lambda)$ é uma função monotonicamente decrescente, cujos valores limites são $Q(0) = 1$ e $Q(\infty) = 0$. Baseado na Equação (3.21), o nível de significância associado a uma valor observado D (ou D' , ou seja, rejeitar a hipótese nula H_0 de que as distribuições empíricas de duas amostras são iguais) é dada, por aproximação, pela Equação [27]:

$$P(D > \text{valor observado}) = Q \left[\left(\sqrt{N_e} + 0, 12 + (0, 11/N_e) \right) D \right], \quad (3.22)$$

em que N_e é o número efetivo de pontos, $N_e = N$ para o caso de uma só distribuição, cuja métrica é representada pela Equação 3.19, e

$$N_e = \frac{NM}{N + M}, \quad (3.23)$$

sendo N o número de pontos (amostras) da primeira distribuição e M o da segunda.

A natureza da aproximação que originou a igualdade dada na Equação (3.22) consiste no fato de que ela torna-se assintoticamente precisa, quando N_e tende a valores grandes, mas a aproximação é aceitável para $N_e \geq 4$.

A referência [27] provê os códigos-fontes desenvolvidos em linguagem C do teste de Kolmogorov-Smirnov para os casos de uma e de duas distribuições. São explicadas também algumas variantes para este teste. O pacote estatístico do Matlab[®] possui alguns testes de hipóteses, entre eles o teste KS para uma (`kstest`) e duas amostras (`kstest2`).

O resultado da fusão hierárquica das regiões existentes na segmentação inicial indicada na Figura 3.7 está exibido na Figura 3.19. O nível de significância $p_0 = 10^{-5}$ é usado no teste de Kolmogorov-Smirnov para unir duas regiões de mínimo custo da árvore, composta inicialmente pelos 3982 segmentos. Ao final do processo, nota-se uma menor quantidade de regiões, ou seja, 63 segmentos. Devido ao fato de tomar amostras de pixels de duas regiões eleitas pelo algoritmo HSWO, este teste possibilita indicar, com uma chance de erro igual a p_0 , se elas provêm de uma mesma distribuição.

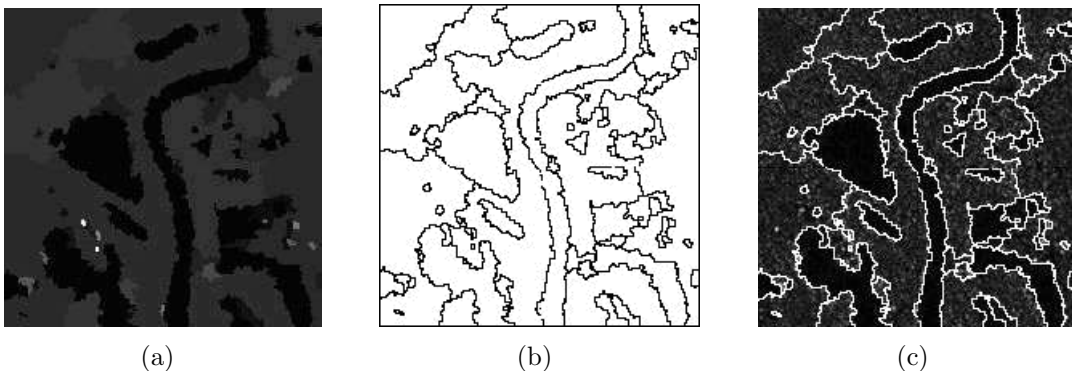


Figura 3.19: Fusão de regiões usando o critério de custo (3.15), combinado com o teste de Kolmogorov-Smirnov (a) mapa temático (b) mapa de bordas (63 segmentos) (c) sobreposição.

Verifica-se que apenas as estatísticas de primeira e segunda ordem são insuficientes para gerar uma segmentação objetiva de imagens SAR. Em virtude do teste de Kolmogorov-Smirnov determinar se duas populações apresentam a mesma função de distribuição, este tem-se mostrado o mais eficiente para realizar a fusão de segmentos, dentre

os métodos testados. Porquanto, ele será usado doravante em combinação com algoritmo HWSO, cujo critério de custo é dado pela Equação (3.15), de modo a suplantar as deficiências mencionadas deste método de sorteio de regiões, quando aplicado isoladamente.

A seguir, o método desenvolvido de segmentação por crescimento e fusão estatística de regiões é aplicado às imagens contaminadas artificialmente com ruído, de modo a testar sua eficiência na segmentação. Para isso, são apresentadas algumas medidas que possibilitam a realização de avaliação de desempenho de métodos de segmentação. Após a avaliação, aplica-se o método proposto na segmentação de imagens SAR reais.

Capítulo 4

Avaliação e Discussão dos Resultados de Segmentação

4.1 Introdução

Neste capítulo é realizada a avaliação de desempenho do segmentador desenvolvido no capítulo anterior. Para isso, inicialmente, são explicadas algumas medidas de discrepância que possibilitam realizar tal procedimento. Em seguida, são apresentados os parâmetros usados para gerar padrões de *speckle* para contaminar as imagens sintéticas ilustradas na Seção 2.3.4, pág. 16. As imagens corrompidas por ruído também são conhecidas por *phantom* e visam idealizar cenas de radar contendo regiões com diferentes graus de homogeneidade.

O próximo passo consiste em segmentar as imagens simuladas e comparar os resultados obtidos com uma segmentação de referência (verdade terrestre). As discrepâncias visuais estão registradas nos mapas de bordas. As medidas de discrepâncias estão classificadas em medidas de micro e de macroajuste, sendo exibidas sob a forma gráfica, e a partir das quais é realizada a análise quantitativa do desempenho do segmentador SAR face a diferentes parâmetros.

4.2 Medidas de Avaliação de Segmentação

A avaliação visual da qualidade de imagens segmentadas pode ser um indicador útil quanto à análise dos algoritmos que as produzem. Existem vários trabalhos desenvolvidos para a segmentação de imagens SAR e que utilizam uma variedade de algoritmos. Diferentes algoritmos produzem diferentes segmentações e determinar o que é uma boa segmentação é uma tarefa complexa, visto que na prática as exigências para segmentação de imagens diferem para cada situação imposta. Por sua vez, podem existir segmentações muito semelhantes de uma mesma imagem e, nesses casos, a simples inspeção visual dos resultados pode levar a dúvidas sobre a indicação do método de segmentação mais eficiente que as tenha produzido.

A Figura 4.1 ilustra o conceito de avaliação supervisionada e será usada para exemplificar melhor o processo de segmentação e as discrepâncias produzidas em relação a uma partição de referência. Algumas regiões têm seus limites modificados pelos segmentadores A, B e C, sendo elas as de rótulos 1, 3, 6 e 7, quando comparadas (visualmente) à segmentação de referência. Em certas situações, as mudanças são quase imperceptíveis e as medidas visam determinar a precisão com que um segmentador modifica a extensão, a forma e o posicionamento dos objetos.

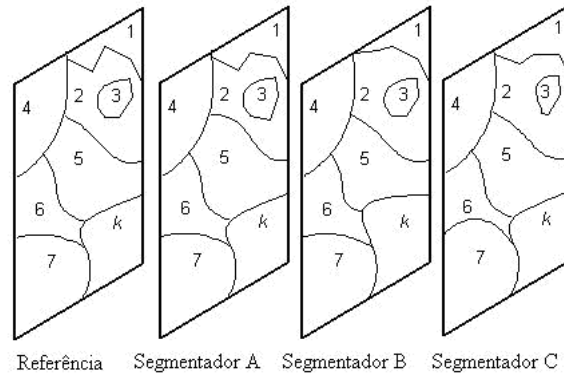


Figura 4.1: Efeitos produzidos por três segmentadores fictícios, em relação a uma segmentação de referência.

Algumas medidas de discrepância baseadas em ajuste de regiões e no ajuste de bordas são consideradas nos trabalhos [25, 63, 64]. Elas são descritas resumidamente a seguir e todas requerem uma imagem de referência para contabilizar as mudanças produzidas pelo segmentador desenvolvido.

4.2.1 Medidas de discrepância baseadas no ajuste de regiões

Uma medida de discrepância usada neste trabalho para comparar segmentadores é denominada medida relativa de precisão (*RUMA*) [64], que considera a precisão com que as características de uma imagem segmentada sejam similares às da partição de referência. A área dos objetos pode ser escolhida como tal característica. A medida *RUMA* é definida por:

$$RUMA_f = \frac{|R_f - S_f|}{R_f} \times 100\%, \quad (4.1)$$

e quanto mais próxima esta medida for do valor zero, mais similar será o atributo de um objeto da imagem segmentada com o seu correspondente na segmentação de referência. No entanto, é feita uma pequena modificação na Equação (4.2) para reverter o limite ideal de similaridade de 0 para 1. A nova expressão é dada por:

$$RUMA = 1 - \frac{|R_f - S_f|}{R_f}, \quad (4.2)$$

em que R_f e S_f são as áreas da região de referência e da região segmentada, respectivamente.

Em [25, 63] são citadas quatro medidas de ajuste para avaliação de algoritmos de segmentação SAR que consideram aspectos de posição, forma e radiometria dos objetos segmentados. Sejam uma imagem segmentada de referência g_1 contendo K regiões, indexadas como $i = 1, 2, \dots, K$, e g_2 uma partição produzida por certo método de segmentação, contendo M regiões, indexadas como $j = 1, 2, \dots, M$. As imagens g_1 e g_2 possuem a mesma dimensão ($xpix$ linhas e $ypix$ colunas). Para avaliar um algoritmo de segmentação, pares de regiões i, j são comparados através dessas medidas. O ajuste é obtido através da sobreposição de regiões. Para cada região i de referência será escolhida dentre todas as regiões j de g_2 uma que melhor a represente, denominada região ajustada. Uma imagem segmentada tende a possuir um número maior de segmentos, em relação a sua segmentação de referência. O ajuste de uma região de g_1 com qualquer outra de

g_2 pode ser medido através de critérios como o posicionamento no plano da imagem, o número de pixels em comum, a intensidade média dos segmentos, bem como a forma.

Para definir os pares de regiões ajustadas, as duas segmentações g_1 e g_2 são sobrepostas, de modo a criar as matrizes G_f e Fit , ambas com dimensão $K \times M$. Os elementos destas matrizes são dados por:

$$G_f(i, j) = \frac{N(i \cap j)}{N(i \cup j)}, \quad (4.3)$$

$$Fit(i, j) = \frac{x_d + y_d + ((p_d + i_d)/2)}{G_f(i, j)}. \quad (4.4)$$

Na Equação (4.3), $N(\cdot)$ indica a cardinalidade de um conjunto (no caso, número de pixels resultantes da intersecção e da união de duas regiões). Na Equação (4.4), as variáveis x_d e y_d indicam o posicionamento dos segmentos no plano da imagem; p_d e i_d são o tamanho e a intensidade média das regiões comparadas, respectivamente. Estes valores da matriz de ajuste são calculados através das equações 4.5 a 4.8.

$$x_d(i, j) = \frac{|\bar{x}_i - \bar{x}_j|}{xpix}, \quad (4.5)$$

$$y_d(i, j) = \frac{|\bar{y}_i - \bar{y}_j|}{ypix}, \quad (4.6)$$

$$p_d(i, j) = \frac{|N(i) - N(j)|}{N(i) + N(j)}, \quad (4.7)$$

$$i_d(i, j) = \frac{|\bar{I}_i - \bar{I}_j|}{\bar{I}_i + \bar{I}_j}. \quad (4.8)$$

Nestas fórmulas, \bar{x}_i e \bar{y}_j representam, respectivamente, o valor médio das abscissas e das ordenadas das regiões i e j , ou seja, as coordenadas do centro geométrico, medidas em pixels. \bar{I}_u denota a intensidade média dos pixels pertencentes a uma região u da imagem ruidosa. i e j indexam segmentos, não estando necessariamente vinculados aos rótulos dos mesmos. O rótulo de um segmento é um mero identificador.

Os elementos de cada linha da matriz Fit representam uma medida do sucesso de ajuste entre os pares de subregiões (i, j) formados, levando em consideração seus tamanhos, formas, posições e intensidades. Para cada subregião i da segmentação de referência, a sua subregião ajustada correspondente j é definida como aquela que possuir o mínimo valor em $Fit(i, j)$. Portanto, $Fit(i, j)$ representa um ajuste médio entre as subregiões i e j , segundo relações de tamanho, localização e intensidade dos pares.

Definida a região ajustada para cada região correspondente na imagem de referência, passa-se à fase de avaliação da qualidade deste ajuste através das medidas de qualidade, definidas pelas Equações (4.9) a (4.12). Estas medidas permitem avaliar a segmentação como um todo, a partir do desempenho do ajuste de cada região i da segmentação de referência.

- **Ajuste de Posição:** $Fitxy$

$$Fitxy = 1 - \frac{x_d + y_d}{2}, \quad (4.9)$$

- **Ajuste de Intensidade:** $Fiti$

$$Fiti = 1 - i_d, \quad (4.10)$$

- **Ajuste de Tamanho:** $Fitn$

$$Fitn = 1 - p_d, \quad (4.11)$$

- **Ajuste de Forma:** $Gforma$

$$Gforma = G_f = \frac{N(i \cap j)}{N(i \cup j)}. \quad (4.12)$$

As medidas expressas pelas Equações (4.9) a (4.12) assumem valores no intervalo $[0, 1]$, sendo iguais à unidade quando há sobreposição integral entre os objetos segmentados e seus correspondentes na segmentação de referência. Na referência [25] são exemplificadas numericamente as medidas apresentadas.

Para cenas complexas pode ser irreal esperar que haja uma correspondência única entre os objetos segmentados da imagem de referência e aqueles encontrados na imagem SAR sob análise. Muitas vezes ocorre sobresegmentação, em que mais regiões são detectadas do que realmente aquelas existentes. Para tal situação, uma grandeza descrita em [63] mede a qualidade de ajuste geral de uma imagem segmentada ($Totgof$), utilizada nesta dissertação.

- **Qualidade de Ajuste Geral:** $Totgof$

Seja $I_i(x, y)$ e $I_j(x, y)$ a intensidade de um pixel de coordenadas (x, y) da região i e da região ajustada correspondente j , respectivamente. Seja ainda

$$S_d = \sum_{x=1}^{xpix} \sum_{y=1}^{ypix} \frac{|I_i(x, y) - I_j(x, y)|}{I_i(x, y) + I_j(x, y)}, \quad (4.13)$$

em que $xpix$ e $ypix$ definem a quantidade de linhas e de colunas da imagem, respectivamente. Caso a intensidade em algum pixel seja $I_i = I_j = 0$, conta-se 0 no somatório. A medida de ajuste geral para uma imagem segmentada é expressa por:

$$Totgof = 1 - \frac{S_d}{xpix \cdot ypix}, \quad (4.14)$$

que também assume valores no intervalo $[0, 1]$, sendo que o valor 1 determina o melhor ajuste do par de regiões (i, j) .

A Figura 4.2 ilustra a sobreposição de regiões para o cálculo destas medidas, destacando os efeitos de deslocamento da posição dos centros geométricos e variação da forma dos objetos. Pode-se observar que o segmentador C produziu uma nova região, rotulada de 8, o que afeta a área da região 7, bem como desloca seu centro de gravidade.

Neste trabalho, todas estas medidas são aplicadas aos resultados de segmentação, de modo a tirar conclusões acerca do desempenho da segmentação. As medidas de ajuste ($Fitxy, Fiti, Fitn, Gforma, Totgof$) são denominadas medidas de macroajuste, em virtude de tomarem como referência regiões inteiras.

4.2.2 Medidas de discrepância baseadas no ajuste de bordas

Medidas de ajuste de bordas ou medidas de microajuste refletem a precisão com que as bordas de um objeto segmentado são reconstruídas. Na Figura 4.3 estão exibidas as bordas sobrepostas, sendo que as linhas cheias definem os limites verdadeiros dos objetos e as tracejadas referem-se aos objetos detectados por um segmentador qualquer. Pode-se observar que a reconstrução das bordas ideais não é perfeita, sendo que ocorrem sobreposições perfeitas em alguns pontos do objeto e em outros, não.

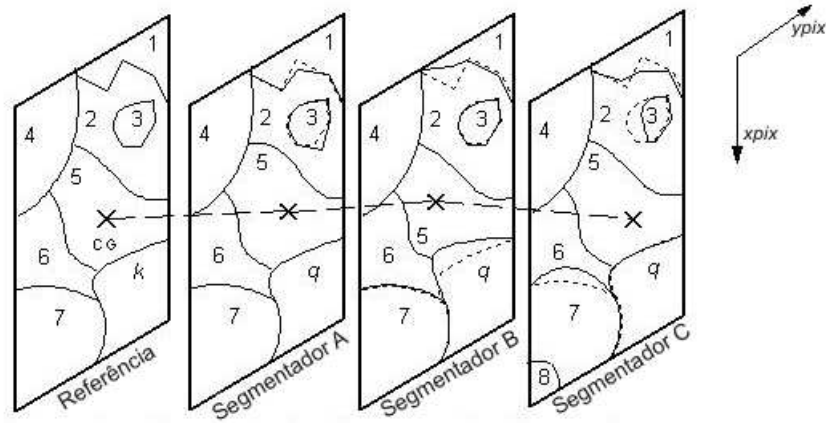


Figura 4.2: Representação do deslocamento do centro de gravidade (CG) e alteração da forma dos objetos segmentados de uma imagem $xpix \times ypix$.

Na região destacada pela lupa, o segmentador recua um pouco da borda ideal. Já na região indicada pela seta, a borda pontilhada excede os limites da borda verdadeira. Há pixels que o segmentador deixa de agregar e que pertencem originariamente ao objeto, como aqueles representados pela textura mostrada na lupa (pixels falsos negativos); há outros que não devem pertencer ao objeto (apontados pela seta e demarcados pelas bordas - pixels falsos positivos). Em outros pontos do desenho ocorrem estes dois casos. Os pixels indicados pela seta são pixels mal segmentados em relação ao objeto verdadeiro, visto que pertencem originariamente ao fundo. Estes pixels são transferidos erroneamente durante a segmentação, aumentando as dimensões do objeto naquela extremidade.




Figura 4.3: Bordas ideais de um objeto (linha cheia) e as bordas geradas por um segmentador (linha pontilhada).

Dois tipos de ajustes podem ser calculados com base na distância entre os contornos. O primeiro usa exclusivamente pixels de borda, estando baseado no distanciamento entre aqueles situados no contorno dos objetos produzidos pelo segmentador e aqueles situados nas bordas ideais do objeto de referência. Seja p um pixel de borda de uma região na segmentação ideal e $D(p)$ a menor distância euclidiana, medida em pixels, entre p e qualquer pixel de borda da região correspondente na segmentação gerada. Em [63] é definida uma medida de ajuste de bordas de uma região i , dada por:

$$D(i) = \frac{\sum c_i D(p)}{\ell_i}, \quad (4.15)$$

em que o somatório é realizado para todos os pixels ao longo do contorno da região ideal, de comprimento ℓ pixels.

Um exemplo ilustrativo desta medida está indicado na Figura 4.4, em que são mostradas as mínimas distâncias (representadas por d e d') entre pixels de bordas de duas segmentações e os localizados no contorno ideal (o objeto está em cinza e a textura indica pixels mal segmentados em relação a este). Quanto maior for o afastamento entre as bordas obtidas e as ideais, maior será o valor de $D(i)$, que fornece uma medida de distância média para os pixels de borda dos objetos segmentados. Quando a superposição das bordas ideais e das segmentadas é perfeita, tal medida é nula.




Figura 4.4: Distâncias euclidianas entre pixels de bordas, representadas pelas linhas pontilhadas, em relação à borda ideal (linha cheia).

$D(i)$ é convertido para valores no intervalo $[0, 1]$ através da Equação (4.16), definindo a medida de ajuste de bordas para uma região de referência i :

$$Ajbrd(i) = \frac{1}{D(i) + 1}. \quad (4.16)$$

Outra medida de ajuste de bordas é baseada na análise de discrepância, segundo a posição e a quantidade de pixels mal segmentados. Isto recai no caso apontado pela seta na Figura 4.3 e todos os pixels representados pela região de textura da Figura 4.4. Sendo o objeto ideal limitado pela linha cheia nessas ilustrações, um segmentador pode extrapolar este limite e incluir mais pixels do que deveria. Estes pixels a mais são denominados mal segmentados e os erros de posição destes em relação aos pixels das fronteiras dos objetos reais podem ser obtidos usando a (menor) distância euclidiana.

A contabilização pixel a pixel define uma nova medida, chamada de ajuste de pixels mal segmentados, originalmente atribuída a Yasnoff *et al.* [65] (ver também [64, 66]). Esta medida é conhecida como distância normalizada. O procedimento realizado neste trabalho consiste em determinar a medida de ajuste de pixels mal segmentados (doravante denotada como $Ajpm_s$) de forma semelhante à descrita para ajuste de bordas. Os erros de posição dos pixels mal segmentados são tomados em relação aos pixels mais próximos que realmente pertencem ao objeto ideal, segundo propõem [65]. Pela análise da Figura 4.4, dado um pixel mal segmentado qualquer (na região com textura), um pixel que realmente pertença ao objeto e que esteja mais próximo desse pixel mal segmentado só pode ser um pixel localizado nas bordas do mesmo. Qualquer pixel localizado em outra parte do objeto ideal, nunca está mais próximo de algum pixel mal segmentado.

Consoante o trabalho de Zhang [64], seja d a mínima distância euclidiana entre um pixel mal segmentado qualquer e um pixel da borda ideal p . A medida de discrepância de N pixels mal segmentados relativos à borda do objeto de referência i é:

$$D_{pms}^{(i)} = \sum_{k=1}^N d^2(k), \quad (4.17)$$

sendo que esta medida é quadrática. O ajuste de pixels mal segmentados ($Ajpm_s$) é uma medida no intervalo $[0, 1]$, sendo melhor (ajuste perfeito) quando não existem pixels mal segmentados para uma dada região ideal e é expressa por:

$$Ajpm_s(i) = \frac{1}{1 + \left(\sqrt{D_{pms}^{(i)}} / \ell \right)}, \quad (4.18)$$

em que, novamente, ℓ representa o número de pixels de borda (perímetro) do objeto i . As medidas de discrepância deste capítulo estão resumidas na Tabela 4.1.

Tabela 4.1: Algumas medidas de discrepância para avaliação supervisionada de segmentadores.

Macroajuste	Medida
RUMA	<i>RUMA</i>
Ajuste de posição	<i>Fitxy</i>
Ajuste de intensidade	<i>Fiti</i>
Ajuste de tamanho	<i>Fitn</i>
Ajuste de forma	<i>Gforma</i>
Ajuste geral	<i>Totgof</i>
Microajuste	
Ajuste de bordas	<i>Ajbrd</i>
Ajuste de pixels mal segmentados	<i>Ajpm_s</i>

4.3 Descrição das Imagens Simuladas e Metodologia de Avaliação

Os rótulos definidos para cada região das imagens kk e $imgcartoon$ estão indicados na Figura 4.5. A descrição dos tipos de cenas associadas a cada região da imagem $imgcartoon$ está indicada na Tabela 4.2.




Figura 4.5: Rótulos dos segmentos das imagens sintéticas (a) kk e (b) $imgcartoon$.

Como antes exposto, o número de visadas é um dos parâmetros de entrada do algoritmo de crescimento de regiões para a formação da partição inicial. Para a imagem contaminada kk , que é constituída somente por regiões heterogêneas e extremamente heterogêneas, são usados os valores nominais dos números de visadas (1, 3 e 5). Para a imagem contaminada $imgcartoon$, os valores estimados para este parâmetro nas simulações estão indicados na Tabela 4.3. Definidos os rótulos representativos de cada região das imagens simuladas e seus números de visadas, passa-se à fase de avaliação da segmentação. A metodologia adotada para este fim está resumida no diagrama da Figura 4.6.

Tabela 4.2: Tipos de alvos associadas a cada região da imagem contaminada *imgcartoon*.

Rótulos	Refletor	Tipo de Superfície
2, 11, 16 e 19	Lagos	Homogênea
6 e 14	Pastagens	Homogênea
3 e 12	Solo exposto	Homogênea
13	Floresta em regeneração	Homogênea
4, 7, 8, 15, 20 e 22	Culturas	Homogênea
5, 9, 10, 18 e 23	Florestas primárias	Heterogênea
1, 17 e 21	Vilas, zonas urbanas e construções	+ Heterogênea

Tabela 4.3: Número estimado de visadas para a imagem contaminada *imgcartoon*.

Valor Nominal	Valor Estimado
1	1,06
3	2,97
5	4,84

O segmentador atua sobre uma imagem artificialmente contaminada por ruído por meio do simulador de *speckle*, o qual foi desenvolvido a partir dos algoritmos de geração de ocorrências com distribuição Raiz de Gama, K-Amplitude e G-Amplitude Zero (Seção 2.2, pág. 10). As medidas de qualidade obtidas permitem aferir o desempenho da técnica de segmentação proposta, sendo que a avaliação está dividida em duas etapas:

- I. **Segmentação de cenas com diferentes tipos de alvos:** Nesta etapa é investigada a influência do parâmetro p_0 do teste de hipóteses, que controla a quantidade de segmentos resultantes ao final do processo. Para cada valor de p_0 , as imagens *phantom* são segmentadas e as medidas de discrepância são extraídas. Pretende-se ainda verificar a capacidade do algoritmo em segmentar imagens contendo regiões não-homogêneas e cenas compostas por regiões homogêneas e heterogêneas. São considerados três casos, $p_0 = 10^{-3}$, $p_0 = 10^{-5}$ e $p_0 = 10^{-6}$, com $n = 1, 3$ e 5 visadas;
- II. **Segmentação de estruturas lineares:** Nesta etapa, outra imagem de teste é contaminada com *speckle*, com $n = 1$ e 3 visadas, sendo depois segmentada, com distintos valores de p_0 . O objetivo é analisar a capacidade do segmentador em detectar e preservar estruturas lineares e curvilíneas.

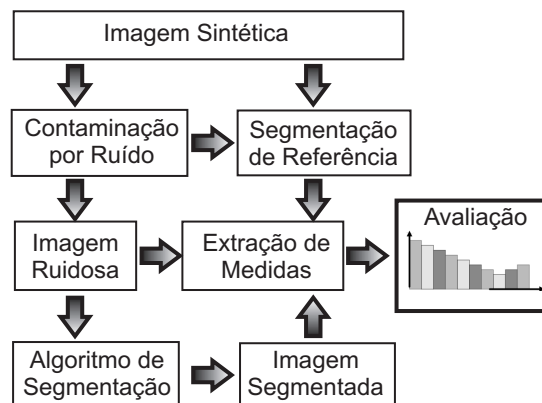


Figura 4.6: Metodologia de avaliação de segmentação.

4.4 Avaliação de Segmentação - Etapa I

4.4.1 Resultados de segmentação com parâmetro $p_0 = 10^{-3}$

Os resultados de segmentação para as imagens de teste com $n = 1$ visada estão indicados na Figura 4.7. Em todos os exemplos mostrados, a sobreposição dos mapas de bordas ideal e obtido visa facilitar a percepção visual das discrepâncias existentes. Os mapas ideais estão em cinza claro, enquanto as bordas detectadas estão em preto. Nos pontos em que a sobreposição é perfeita, sobressai a borda preta.

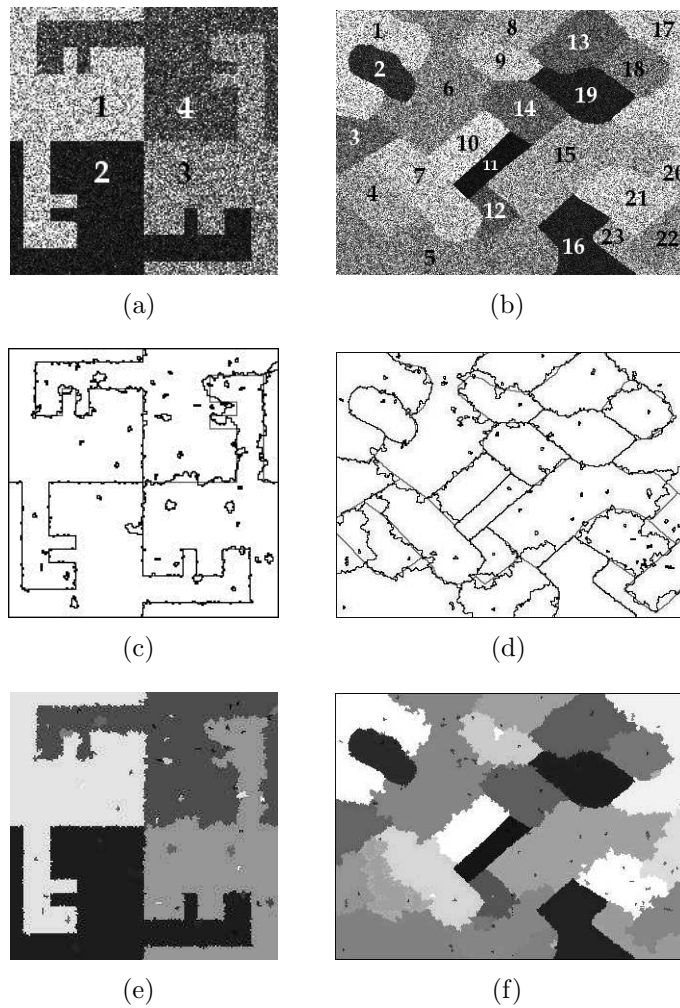


Figura 4.7: Segmentações geradas com $p_0 = 10^{-3}$ (a-b) imagens contaminadas (1 visada) (c-d) mapas de bordas sobrepostos (e-f) imagens temáticas.

Estão ilustradas também as imagens temáticas correspondentes, para fins de visualização dos segmentos segundo seus tons médios de cinza. A segmentação da imagem *kk* inicia com uma partição contendo 4133 regiões criadas pelo crescimento de regiões e para a imagem *imgcartoon*, a partição inicial consta de 9056 segmentos. O parâmetro número máximo de pixels (*maxpixels*) para a etapa de crescimento de regiões, em todas as segmentações seguintes, é sempre 15, salvo menção em contrário.

Na Figura 4.7(e), a segmentação temática de *kk* consiste de 51 regiões, enquanto *imgcartoon* possui 100, exibida na Figura 4.7(f). Em ambas estão incluídos fragmentos remanescentes que deixaram de ser incorporados nas regiões relevantes, rotuladas nas imagens das Figuras 4.7(a) e 4.7(b). As regiões escuras, correspondentes às lagoas em *imgcartoon*, quase não sofrem mudanças, porque se destacam em contraste com as demais regiões e o ruído é afeta menos tais alvos.

Quando o detector de bordas MSPRoA [67] é aplicado às imagens ruidosas constantes das Figuras 4.7(a) e 4.7(b), são obtidas as bordas ilustradas na Figura 4.8. Este detector está baseado na razão de médias e no cálculo de limiares automáticos para localização de bordas. O contraste existente entre as regiões 1, 2 e 3 de *kk* favorece a detecção de várias bordas fragmentadas. Em contrapartida, a heterogeneidade associada às regiões 3 e 4 e aliada ao baixo contraste em zonas de transição dificultam bastante o processo. Os formatos dos objetos nestes locais são também alterados pelo segmentador, como mostra o mapa de bordas constante da Figura 4.7(c) (as bordas foram obtidas a partir da varredura da matriz de rótulos).

O detector também não consegue identificar grande parte das bordas existentes entre as regiões de *imgcartoon*. O nível de ruído para imagens com 1 visada complica bastante a detecção nas zonas de transição, principalmente onde o contraste não é alto, como pode ser observado visualmente na Figura 4.7(b) para algumas regiões. Constituem exemplos as zonas de transição entre os objetos 4 e 7, 6 e 9, 22 e 23.

À luz da teoria desenvolvida por vários autores para detectores de bordas voltados para imagens SAR [67, 68, 69], estes relatam que um pixel está em uma borda quando a razão entre os contrastes (ou razão das médias) dentro de um janela é maior que um certo limiar. Limiares globais podem não ser uma boa solução para a detectar bordas em imagens SAR, porque podem favorecer a detecção em algumas regiões da imagem e em outras o mesmo pode não ocorrer, apesar de elas realmente existirem. Isto explica a não detecção de bordas na maior parte das imagens de teste, exibidas na Figura 4.8, fato que também é dependente do nível de ruído *speckle* existente.




Figura 4.8: Detecção de bordas nas imagens ruidosas com 1 visada, usando o algoritmo MSPRoA com janela 5×5 .

Com relação ao desempenho do segmentador SAR na imagem *imgcartoon*, pelo menos quatro imperfeições são marcantes no delineamento de suas regiões e envolvem os segmentos de rótulos 4 e 7 (culturas), 5 (floresta), 15 (cultura), 20 e 17 (ver Figuras 4.7(a) e 4.7(b)). O segmento 5 está dividido em três partes e as regiões 4 e 17 têm suas áreas reduzidas. Outras regiões segmentadas, apesar de apresentarem pequenos fragmentos em seu interior, mantiveram razoavelmente seus limites próximos dos ideais (rótulos 2, 11, 14, 16 e 19).

Em síntese, a análise dos mapas sobrepostos da Figura 4.7(d) permite evidenciar que não houve muito sucesso no alcance das bordas ideais para boa parte dos segmentos. Isto se deve ao nível de ruído presente e, como exposto, o *speckle* em imagens de 1 visada prejudica bastante o processo de segmentação em zonas de transição com baixo contraste. No entanto, pode-se avaliar que o desempenho do segmentador é melhor do que o desempenho do detector de bordas. No contexto geral, a segmentação dos objetos de *kk* e de *imgcartoon* com 1 visada permite identificar com certa margem de acerto as regiões relevantes.

A Figura 4.9 ilustra as segmentações das imagens de teste geradas com $n = 3$ visadas. Na segmentação de *kk* restam 119 regiões, enquanto *imgcartoon* possui apenas 96. Pela análise dos mapas sobrepostos das Figuras 4.9(c) e 4.9(d), houve o aumento da quantidade de fragmentos para a imagem *kk* e uma diminuição para *imgcartoon*, quando comparados às contagens de regiões das segmentações das imagens com 1 visada. É importante visualizar também as imagens temáticas para acompanhar as mudanças detectadas nos mapas sobrepostos.

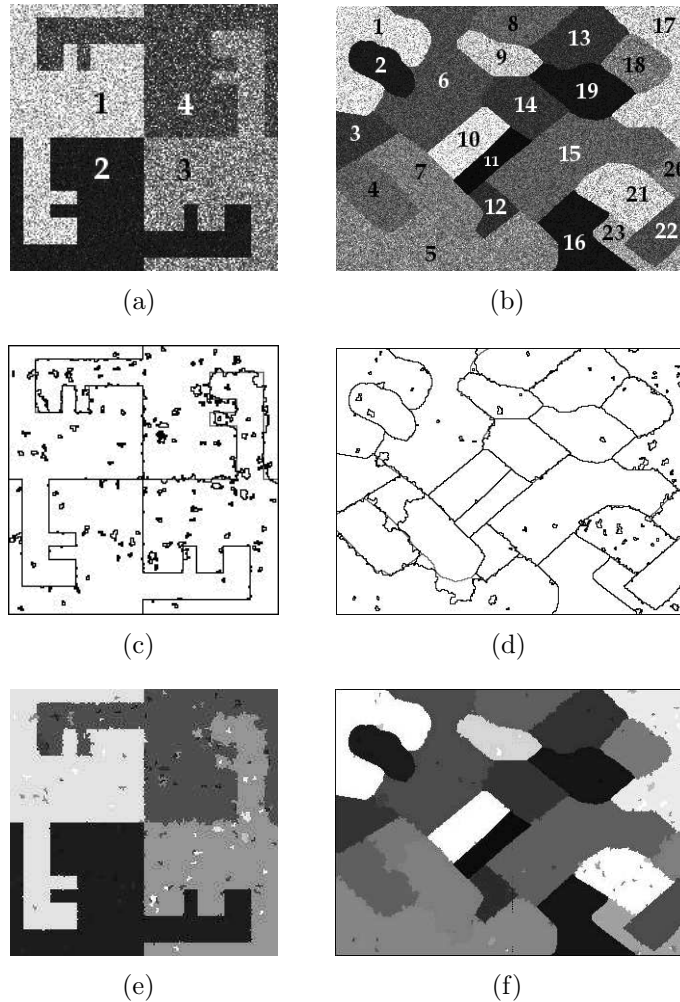


Figura 4.9: Segmentações geradas com $p_0 = 10^{-3}$ (a–b) imagens contaminadas (3 visadas) (c–d) mapas de bordas sobrepostos (e–f) imagens temáticas.

Nas imagens de 3 visadas, o ruído *speckle* apresenta menor variância em relação às de 1 visada, mas ainda estão presentes grande quantidade de pequenos fragmentos distribuídos ao longo de algumas regiões de *kk* e *imgcartoon*. Um erro que ainda persiste e que é mais proeminente em *imgcartoon* está na fronteira das regiões de rótulos 5 (floresta) e 7 (cultura), com o aumento da área desta última, como mostra a Figura 4.9(d). É possível perceber que as regiões 4 e 20 de *imgcartoon* apresentam resultados melhores que aqueles representativos da segmentação com 1 visada. A região 20 está confinada dentro de seus limites ideais, com boa aproximação visual. Já a região 5 não está sobresegmentada, em relação à segmentação anterior (1 visada).

As bordas dos objetos segmentados de *kk* e de *imgcartoon*, com 3 visadas, apresentam-se mais suaves, frente àquelas de aspecto picotado existentes na Figuras 4.7(c) e 4.7(d), respectivamente. Isto é consequência da menor influência do *speckle* no delineamento das bordas.

De modo geral, os contornos dos segmentos de *kk* e *imgcartoon* estão mais bem definidos para 3 visadas. Com relação à maior quantidade de pequenos fragmentos detectados em *kk*, isto pode decorrer da formação ou detecção de aglomerados de pixels ruidosos que ficam impossibilitados de ser unidos às regiões vizinhas, por causa do valor adotado para p_0 .

As bordas detectadas pela técnica MSPRoA para as imagens com 3 visadas estão ilustradas na Figura 4.10. A quantidade de bordas falsas detectadas ao longo das imagens é bem menor em relação àsquelas da Figura 4.8, pois a influência do *speckle* é menor nas medidas realizadas usando os pixels delimitados pela janela do detector. Apesar disto, tendo em vista as interfaces entre as regiões 6, 14 e 15 de *imgcartoon*, observa-se que a detecção não é realizada com sucesso, e o mesmo ocorre para outros objetos dessa imagem. Para a imagem *kk* com 3 visadas, ainda existem muitos fragmentos de bordas detectados nas regiões 3 e 4, que são zonas extremamente heterogêneas.

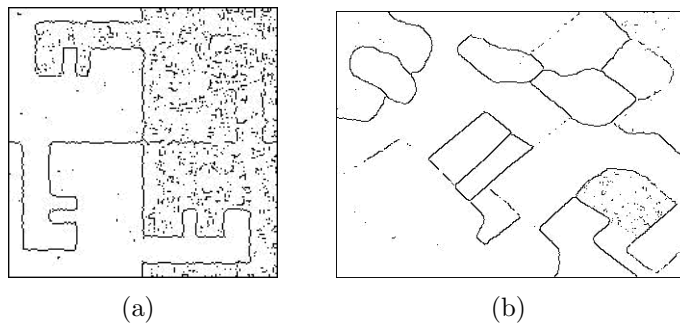


Figura 4.10: Detecção de bordas nas imagens com 3 visadas, usando o algoritmo MSPRoA com janela 5×5 .

Os resultados de segmentação das imagens de teste geradas com $n = 5$ visadas encontram-se na Figura 4.11. A segmentação da imagem *kk* inicia com uma partição contendo 6061 regiões e para a imagem *imgcartoon*, a partição inicial consta de 9531 segmentos. Na segmentação final de *kk* existem 115 regiões, enquanto *imgcartoon* possui 134. As fronteiras entre os segmentos relevantes de *imgcartoon* apresentam maior grau de acerto, em comparação com as Figuras 4.7 e 4.9. A imagem *kk* apresenta distorções entre as regiões 3 e 4 e suas bordas detectadas estão presentes na Figura 4.12. Percebe-se que há melhor delineamento das bordas dos objetos, à medida que o número de visadas aumenta.

Ocorre também o aumento do número de fragmentos, porque a suavização crescente do ruído *speckle* provoca a formação de aglomerados de pixels pelo segmentador, os quais deixam de ser fundidos a outras regiões por causa do nível de p_0 adotado. Alguns destes fragmentos permanecem durante todo o processo de fusão e chegam ao seu final intactos.

As medidas de discrepância apresentadas no início deste capítulo permitem quantificar os resultados e inferir a qualidade da segmentação. A avaliação está ilustrada em gráficos que expressam os valores das medidas no intervalo $[0, 1]$ para cada segmento de referência, cujos rótulos estão indicadas no eixo horizontal. Valores próximos da unidade, para um determinado segmento, indicam que a segmentação obtida do mesmo aproxima-se bastante das características ideais.

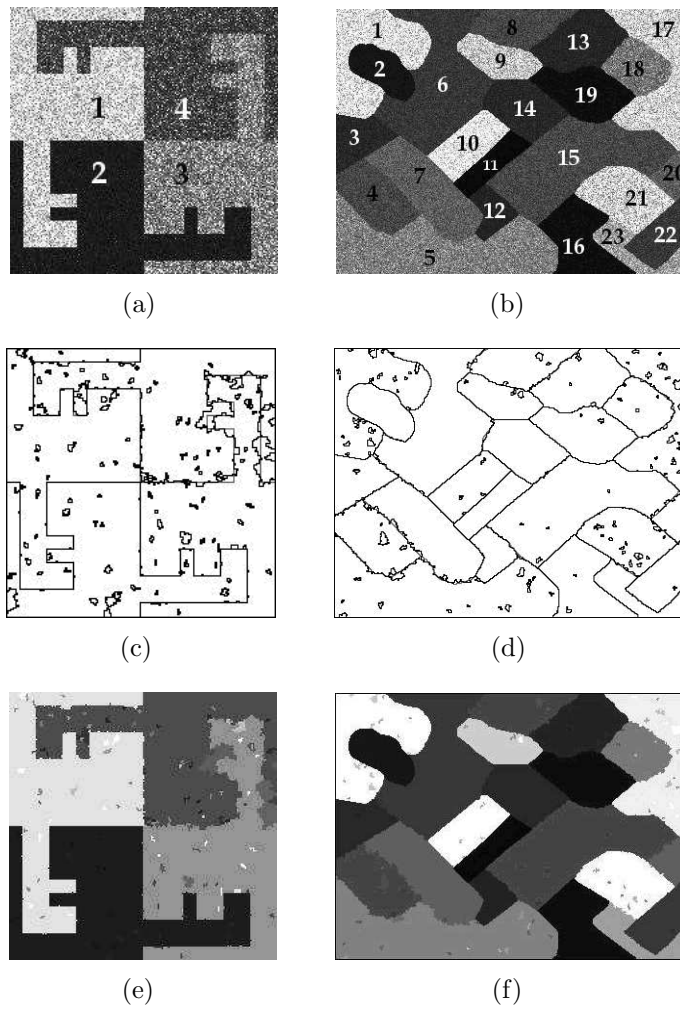


Figura 4.11: Segmentações geradas com $p_0 = 10^{-3}$ (a–b) imagens contaminadas (5 visadas) (c–d) mapas de bordas sobrepostos (e–f) imagens temáticas.





Figura 4.12: Detecção de bordas nas imagens com 5 visadas, usando o algoritmo MSPRoA com janela 5×5 .


4.4.2 Medidas de desempenho com parâmetro $p_0 = 10^{-3}$

A avaliação da segmentação, com o parâmetro de controle $p_0 = 10^{-3}$, inicia com as medidas extraídas da imagem *kk*, seguidas das medidas de *imgcartoon*, para 1, 3 e 5 visadas. As medidas correspondentes a estas imagens de teste estão tabeladas na Seção A.2.1, pág. 115, sendo usadas na concepção dos gráficos que seguem. Os rótulos das regiões de referência estão dispostos no eixo horizontal, enquanto o eixo vertical contém os valores das medidas de micro e de macroajuste.


Na Figura 4.13 estão indicados os gráficos relativos às medidas *RUMA*, ajuste de bordas (*Ajbrd*) e ajuste de pixels mal segmentados (*Ajpm*s, indicada como *PMS*). Estas medidas corroboram as explicações dadas anteriormente, quando é discutido o desempenho do segmentador perante as imagens contaminadas sob diferentes visadas, a partir da análise dos mapas de bordas e das imagens temáticas. Portanto, pode ser necessária uma rápida visualização nas segmentações anteriores para acompanhar o processo de avaliação, Figuras 4.7, 4.9 e 4.11, que também possibilitam a identificação de cada rótulo.



(a)



(b)




(c)


Figura 4.13: Medidas *RUMA* e de microajuste para segmentação de *kk* (a) 1 visada (b) 3 visadas (c) 5 visadas, com $p_0 = 10^{-3}$.

De acordo com as medidas apresentadas nos gráficos da Figura 4.13, o objeto 4 da imagem *kk* apresenta as piores medidas de ajuste de bordas e de área (*RUMA*) para 1 e 5 visadas, em virtude das pequenas expansões do segmento 3 (1 visada - ver Figuras 4.7(c) e 4.7(e)) e a formação de dois grandes fragmentos que alteram as características e limites deste objeto (5 visadas - Figuras 4.11(c) e 4.11(e)). Estas observações são ratificadas pelas medidas de ajuste de forma e de tamanho, relativas aos objetos 3 e 4, sendo que tais medidas apresentam valores mais baixos quando *kk* possui 1 e 5 visadas, conforme mostram os gráficos da Figura 4.14.


Nos mapas de bordas, estas distorções podem ser percebidas no ‘F’ situado no primeiro quadrante (ver Figuras 4.7(c) e 4.11(c)) para as imagens de 1 e 5 visadas. Para 3 visadas (Figura 4.9), as bordas reconstruídas deste mesmo ‘F’ estão mais próximas das ideais.



(a)



(b)




(c)

Figura 4.14: Medidas de macroajuste para segmentação de *kk* (a) 1 visada (b) 3 visadas (c) 5 visadas, com $p_0 = 10^{-3}$.


Os gráficos das Figuras 4.15 e 4.16 resumem as discrepâncias encontradas para *imgcartoon* para diferentes visadas. É possível observar que as medidas *RUMA*, ajuste de bordas e de pixels mal segmentados são, em geral, menores para a segmentação da imagem de 1 visada e se aproximam do valor unitário, quando o número de visadas aumenta. A segmentação da imagem com 1 visada apresenta bordas muito sinuosas, por causa da grande interferência do ruído *speckle*, conforme mostra a Figura 4.7, confirmadas pela medidas da Figura 4.15(a).

As inconsistências perceptíveis para a segmentação de *imgcartoon* com 1 visada estão refletidas nas medidas de ajuste de tamanho e forma, Figura 4.16(a), relativas às regiões 4, 5 e 20. Os problemas encontrados são redução de área, sobresegmentação e aumento de área, respectivamente (ver Figura 4.7(d)). Para 3 visadas, a segmentação de *imgcartoon* apresenta mais inconsistência para o objeto 7 (cultura) e, conseqüentemente, também é afetado o objeto 5 (floresta).


O segmento de rótulo 7 está subdividido em duas partes, sendo que uma delas (a subparte maior) avançou sobre uma porção do segmento correspondente ao objeto 5, como mostra o detalhe ampliado da Figura 4.17, na pág. 64.



(a)



(b)



(c)


Figura 4.15: Medidas *RUMA* e de microajuste para segmentação de *imgcartoon* com (a) 1 visada (b) 3 visadas (c) 5 visadas, e $p_0 = 10^{-3}$.

Conforme expresso anteriormente, todas as medidas de discrepância estão baseadas na correspondência entre pares de regiões ajustadas. A região ajustada corresponde ao objeto, gerado pelo segmentador, que possui maior número de pixels em comum com outro de referência. No detalhe ampliado, o objeto de rótulo igual a 7 (delimitado pela borda ideal apontada pelas setas) está sobreposto às regiões segmentadas, indicadas pelas duas texturas. A borda ideal está sobreposta em grande parte de seu contorno pelas bordas reais (brancas), em que o ajuste é quase perfeito (por exemplo, ao longo dos segmentos ajustados dos objetos 3, 6, 10, 11 e 12).


A região ajustada ao objeto 7 consiste apenas do maior segmento, marcado com textura em quadrados cinza, que invade uma porção da região ajustada correspondente à região de referência 5. Logo, as medidas relativas ao objeto 7 levam em conta apenas sua região ajustada, isto é, a região referente à textura em cinza. A região formada pela textura pontilhada é produzida pelo segmentador e não entra na contabilização de nenhuma medida, Figura 4.17.

Nos gráficos das Figuras 4.15(b) e 4.16(b) (3 visadas) as medidas de ajuste de bordas, de pixels mal segmentados e de forma, relativas ao segmento 7, apresentam valores mais baixos. Isto ocorre porque aumentaram as distâncias entre as bordas obtidas e as ideais. Este segmento possui 981 pixels mal segmentados.


Um ponto que deve ser destacado é que as medidas de microajuste (*Ajbrd* e *Ajpmms*) levam em conta o perímetro das regiões de referência para sua obtenção. Portanto, as regiões que possuem grandes perímetros tendem a possuir valores maiores destas medidas, como é o caso dos segmentos 5 e 7.



(a)



(b)



(c)

Figura 4.16: Medidas de macroajuste para segmentação de *imgcartoon* (a) 1 visada (b) 3 visadas (c) 5 visadas, com $p_0 = 10^{-3}$.

Como o segmento 5 possui maior perímetro, o gráfico de barras da Figura 4.15(b) apresenta valores de ajuste de bordas e de pixels mal segmentados maiores, em relação ao segmento 7. O grande valor de $Ajpm_s$ (0,9792 – Tabela A.9, pág. 116) para o segmento 5 também está relacionado ao fato deste possuir apenas 40 pixels mal segmentados e extenso contorno, contra os 981 pixels mal segmentados do segmento 7, cuja mesma medida é igual a 0,5980. Para 5 visadas, a maior parte dos segmentos obtidos de *imgcartoon* apresenta grande ajuste, apesar da existência de um número considerável de pequenos fragmentos no interior das regiões relevantes.




Figura 4.17: Detalhe ampliado referente à Figura 4.9(d).

A medida *Totgof* representa o ajuste geral para a segmentação, formulada segundo diferenças entre níveis de cinza dos pixels de um segmento de referência e seus correspondentes na imagem segmentada. Os resultados desta medida para a segmentação das imagens de teste com 1, 3 e 5 visadas e nível $p_0 = 10^{-3}$, estão indicados na Figura 4.18. De acordo com estes gráficos, a melhor segmentação é a da imagem *kk* com 3 visadas (0,9559), enquanto para *imgcartoon* a melhor ocorre para 5 visadas (0,9766). Estes valores de *Totgof* representam bom grau de acerto (95,6% para *kk* e 97,7% para *imgcartoon*), porque os níveis de cinza dos pixels das regiões segmentadas estão, em sua maioria, em conformidade com aqueles das regiões de referência.




Figura 4.18: Medidas de ajuste geral para (a) *kk* e (b) *imgcartoon*, $p_0 = 10^{-3}$.

4.4.3 Resultados de segmentação com parâmetro $p_0 = 10^{-5}$

Nesta etapa são avaliados os resultados produzidos pelo segmentador SAR para as imagens de teste com 1, 3 e 5 visadas, sendo o valor do parâmetro de controle é diminuído para $p_0 = 10^{-5}$. Na Figura 4.19 estão reproduzidas as segmentações das imagens de teste com número de visadas $n = 1$. Os rótulos das regiões são os mesmos indicados nas Figuras 4.7(a) e 4.7(b)).

A diminuição do parâmetro p_0 leva a um ‘relaxamento’ no processo de fusão de segmentos e a segmentação final possui menor número de regiões, em decorrência de mais uniões de segmentos significativamente semelhantes. Em certos trechos dos mapas ocorrem sobreposições das bordas ideais, visto que as bordas obtidas aproximam-se bastante das fronteiras ideais, pelo menos visualmente.

Por esta análise dos mapas de bordas de *kk* e de *imgcartoon*, a fusão de regiões ao nível de significância $p_0 = 10^{-5}$ propicia a agregação de grande parte dos pequenos fragmentos no interior das regiões. O resultado é uma segmentação com menos fragmentos distribuídos na imagem, fato que pode ser observado a partir da comparação das Figuras 4.7 (pág. 56) e 4.19.

Para a imagem *imgcartoon*, é possível observar a expansão do segmento ajustado ao objeto ideal 8 em direção ao segmento 9, sendo que este último reduziu-se a um pequeno fragmento. A redução de área também é visível para os segmentos de rótulos 4, 5, 7, 17, 18 e 23, por exemplo. Para cada região da imagem de teste *imgcartoon* reduzida de tamanho, há outras que sofreram expansões, como o segmento referente ao objeto 20, melhor observados na Figura 4.19(d). Além disso, ainda é considerável a presença de bordas sinuosas, percebidas melhor através da imagem temática. Estas mudanças afetam as regiões homogêneas, heterogêneas e extremamente heterogêneas.

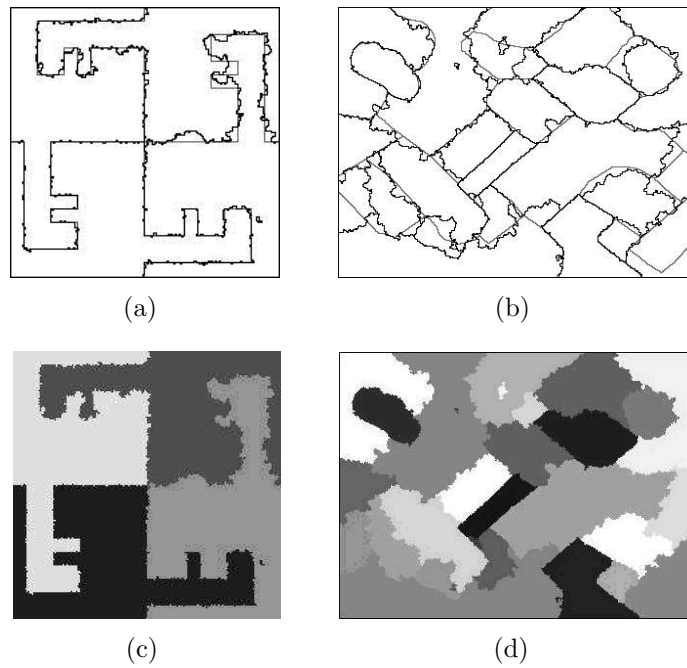


Figura 4.19: Segmentações geradas com $p_0 = 10^{-5}$ e 1 visada (a–b) mapas de bordas sobrepostos (c–d) imagens temáticas.

Os erros apontados para a segmentação das imagens de 1 visada são menos freqüentes em grande parte dos segmentos das imagens *kk* e *imgcartoon* (ambas com 3 visadas), apesar da expansão da região ajustada relativa ao segmento 7 desta última. A influência do parâmetro p_0 pode ser verificada comparando-se as Figuras 4.9 (pág. 58) e 4.20.




Figura 4.20: Segmentações geradas com $p_0 = 10^{-5}$ e $n = 3$ visadas (a–b) mapas sobrepostos e (c–d) imagens temáticas.

As divergências detectáveis visivelmente entre os mapas sobrepostos destas duas segmentações são a eliminação de pequenos fragmentos e a melhor definição dos contornos dos objetos para as duas imagens de teste. Excetuam-se os erros relativos ao segmento 7 de *imgcartoon*, devido a sua expansão em direção ao segmento ajustado ao objeto ideal 5. No entanto, o segmento 7 constitui um objeto não mais sobresegmentado, diferentemente daquele mostrado na Figura 4.9 (cujo detalhe está ampliado na Figura 4.17). A diminuição de p_0 leva a mais fusões, após a diminuição das chances de erro, para a maior parte dos segmentos de *imgcartoon*. É importante lembrar que neste processo de segmentação a ordem das fusões é um fator relevante e dependente do desempenho do teste de hipóteses.

Nas segmentações das imagens de 5 visadas da Figura 4.21, o erro mais aparente é a criação de novos segmentos em ambas as imagens. Eles são visualizados nas Figuras 4.21(c) (nas adjacências do objeto 3 da imagem *kk*, próximo ao centro do quadrante superior direito) e 4.21(d) (entre os objetos segmentados referentes aos rótulos 3, 4 e 7, com a diminuição das áreas destes dois últimos). Ambas as partições contêm raros fragmentos e apresentam melhor definição de bordas, em virtude do número de visadas e do valor adotado para p_0 . As bordas ideais se confundem em vários pontos com as bordas reais geradas pela segmentação, principalmente na imagem *imgcartoon*.





Figura 4.21: Segmentações geradas com $p_0 = 10^{-5}$ e $n = 5$ visadas (a–b) mapas sobrepostos e (c–d) imagens temáticas.

As medidas representativas dos erros antes mencionados para as imagens *phantom* com $n = 1, 3$ e 5 visadas e $p_0 = 10^{-5}$ estão ilustradas a seguir.


4.4.4 Medidas de desempenho com parâmetro $p_0 = 10^{-5}$

As medidas de discrepância de micro e macroajuste estão indicadas nos gráficos das Figuras 4.22 e 4.23 para a imagem *kk* e para *imgcartoon*, observar as Figuras 4.24 e 4.25.


Pela análise das medidas da Figura 4.22 (relativas aos dados da Tabela A.11, pág. 117), os melhores valores de ajuste para a imagem *kk* foram obtidos pelo segmento ajustado referente ao objeto ideal 2, para todas as medidas (*RUMA*, *Ajbrd* e *PMS*).



(a)



(b)



(c)

Figura 4.22: Medidas *RUMA* e de microajuste para segmentação de *kk* (a) 1 visada (b) 3 visadas (c) 5 visadas, para $p_0 = 10^{-5}$.

O segmentador também apresenta bom desempenho ao detectar o objeto ajustado à região de referência 1 de *kk*. Em geral, a segmentação desta imagem é melhor para sua versão com 3 visadas, que apresenta menor quantidade de pixels mal segmentados.


Na imagem *kk* com $n = 5$ visadas ocorrem fusões errôneas que levam à alteração do objeto ‘F’ superior direito e, como conseqüência, decrescem as medidas de bordas dos segmentos envolvidos (os segmentos ajustados dos ideais de rótulos 3 e 4).

Já as falhas apontadas anteriormente para a segmentação de *imgcartoon* estão implícitas no decréscimo dos valores das medidas, principalmente para a segmentação da imagem com 1 visada (Figura 4.24(a)). Nesta figura, destacam-se os erros existentes para os objetos 4, 5, 7, 8, 9, 18, 20 e 23. Para 3 visadas ocorrem erros nas regiões ajustadas aos segmentos ideais 5, 7 e 20, enquanto para 5 visadas destacam-se os erros associados aos objetos 4, 7 e 20.


Conforme já explicado, os segmentos 4 e 7 tiveram suas áreas reduzidas por causa da criação de um novo segmento (ver Figura 4.21). O objeto 20 da imagem *imgcartoon* não apresenta erros expressivos para as versões contaminadas com 3 e 5 visadas, pelo menos visivelmente (Figuras 4.20 e 4.21, respectivamente). Tomando o segmento 20 da partição de 1 visada, existem 1186 pixels mal segmentados (Tabela A.12, pág. 118), 101 para 3 visadas (Tabela A.13) e 74 para o resultado de segmentação da imagem ruidosa de 5 visadas (Tabela A.14). Os valores das medidas *PMS* são 0,26469, 0,87035 e 0,88763, respectivamente (gráficos da Figura 4.24).

As demais medidas de ajuste para *imgcartoon* estão indicadas na Figura 4.25, que também refletem as mudanças nos objetos cujos rótulos são mencionados acima. Na


segmentação da imagem com 3 visadas, destaca-se a diminuição da medida de ajuste de forma para o segmento 7, devido a sua expansão além da borda ideal, o que aumenta a quantidade de pixels mal segmentados (ou pixels falsos positivos).



(a)



(b)




(c)

Figura 4.23: Medidas de macroajuste para segmentação de *kk* (a) 1 visada (b) 3 visadas (c) 5 visadas, para $p_0 = 10^{-5}$.


As medidas de ajuste de intensidade, de posição, e *RUMA* em muitos casos, têm-se mostrado quase invariantes, sendo muito próximas de 1. Isto significa que o segmentador apresenta bom desempenho (principalmente para as imagens com 3 e 5 visadas) de acordo com estas medidas, ou elas podem não ser apropriadas para discriminar problemas que ocorrem em segmentações errôneas. Por outro lado, as mudanças são melhor detectadas pelas medidas de ajuste de bordas e de pixels mal segmentados, bem como de ajuste de forma e de tamanho.

As medidas de ajuste geral para as segmentações com parâmetro $p_0 = 10^{-5}$ estão destacadas na Figura 4.26. O melhor resultado de segmentação da imagem *kk* ocorre para a versão com 3 visadas, enquanto a versão com 5 visadas de *imgcartoon* apresenta melhor grau de acerto (0,9838 contra 0,9766 da mesma versão segmentada com $p_0 = 10^{-3}$).


Consoante a medida *Totgof* graficamente exibida na Figura 4.26, a segmentação da imagem *imgcartoon* com 1 visada ($p_0 = 10^{-5}$) é melhor, quando comparada à segmentação da mesma imagem usando-se $p_0 = 10^{-3}$ (0,8732 contra 0,8631), devido à eliminação de pequenos fragmentos.



(a)




(b)




(c)


Figura 4.24: Medidas *RUMA* e de microajuste para segmentação de *imgcartoon* com (a) 1 visada (b) 3 visadas (c) 5 visadas, com $p_0 = 10^{-5}$.



(a)




(b)




(c)

Figura 4.25: Medidas de macroajuste para segmentação de *imgcartoon* (a) 1 visada (b) 3 visadas (c) 5 visadas, com $p_0 = 10^{-5}$.



(a)



(b)

Figura 4.26: Medidas de ajuste geral para (a) *kk* e (b) *imgcartoon*, $p_0 = 10^{-5}$.

4.4.5 Resultados de segmentação com parâmetro $p_0 = 10^{-6}$

As imagens segmentadas produzidos pelo método proposto com parâmetros $n = 1, 3$ e 5 visadas e $p_0 = 10^{-6}$ estão ilustradas na Figura 4.27. A diminuição de p_0 provoca expressivas alterações nas formas esperadas para os segmentos gerados para a imagem *imgcartoon*, pois ocorrem bastantes fusões. Destacam-se as regiões ajustadas correspondentes aos objetos 3, 4, 5, 7, 12, 17, 20, 21 e 23, além dos segmentos relativos aos objetos 8 e 9 de *imgcartoon* (ver rótulos na Figura 4.11(a,b), pág. 60).




Figura 4.27: Mapas temáticos gerados com $p_0 = 10^{-6}$, a partir das imagens de (a–b) 1 visada (c–d) 3 visadas (e–f) 5 visadas.


Os erros de segmentação oriundos do processamento das imagens com 1 visada são semelhantes àqueles correspondentes às versões com 1 visada e $p_0 = 10^{-5}$, dispostas na Figura 4.19, pág. 66. As segmentações das imagens de teste com 3 e 5 visadas são bastante semelhantes àquelas das Figuras 4.20 e 4.21, respectivamente. As mudanças visuais são sutis, porquanto os valores das medidas relativas a essas imagens tendem a ser bastante próximas dos valores calculados para as imagens de teste anteriores (com 3 e 5 visadas e $p_0 = 10^{-5}$).

4.4.6 Medidas de desempenho com parâmetro $p_0 = 10^{-6}$


As medidas de desempenho para as segmentações da imagem *kk* com 1, 3 e 5 visadas, com o parâmetro $p_0 = 10^{-6}$, estão indicadas nos gráficos das Figuras 4.28 e 4.30.

Os erros mais expressivos para a imagem *kk* referem-se aos segmentos 3 e 4, percebidos pelo decréscimo dos valores das medidas de ajuste de bordas, pixels mal segmentados e de forma, como vem ocorrendo com as segmentações anteriores. A análise desses gráficos permite expressar que a segmentação da imagem *kk* com 3 visadas é melhor quanto ao ajuste de área (medida *RUMA*) e de bordas. Os segmentos 3 e 4 possuem uma maior quantidade de pixels mal segmentados (313 e 286, respectivamente) em relação aos mesmos segmentos constantes da imagem com 5 visadas (216 e 312, respectivamente).


A evolução da quantidade de pixels mal segmentados para os segmentos 3 e 4 de *kk* está indicada na Figura 4.29, de acordo com os dados das Tabelas A.7, A.11 e A.15. O eixo vertical representa a contagem de pixels mal segmentados sob diferentes visadas e o horizontal indica os valores de p_0 .



(a)



(b)



(c)

Figura 4.28: Medidas *RUMA* e de microajuste para segmentação de *kk* (a) 1 visada (b) 3 visadas (c) 5 visadas, para $p_0 = 10^{-6}$.

Esses gráficos de linha indicam que, em geral, há uma tendência ao aumento de pixels mal segmentados relativos às regiões heterogêneas 3 e 4 da imagem *kk*, à medida que o parâmetro p_0 diminui. Isso significa que fusões em demasia estão provocando a diminuição da medida *Ajpm*s para tais segmentos. Uma análise semelhante para a imagem *imgcartoon* torna-se um pouco mais trabalhosa, por causa da quantidade de segmentos presentes.

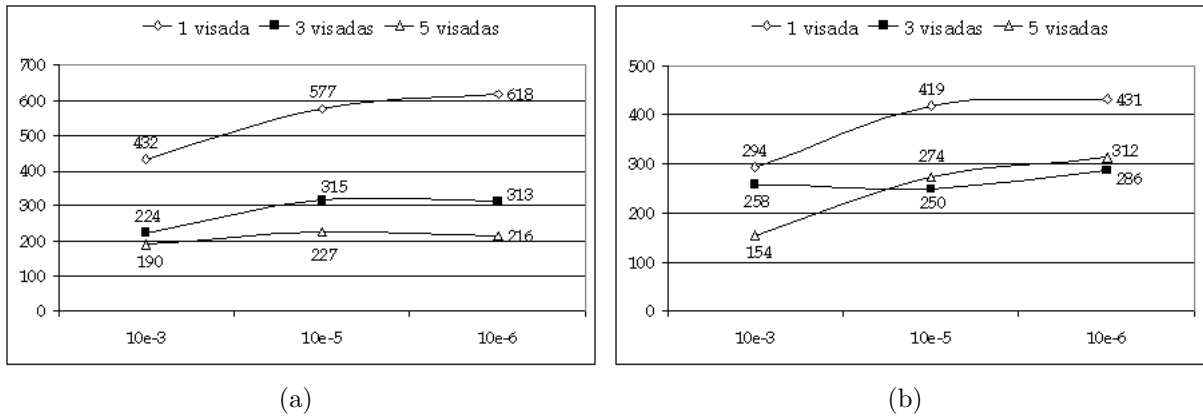





Figura 4.29: Quantidade de pixels mal segmentados para o (a) objeto 3 e (b) objeto 4 de , com $p_0 = 10^{-3}$, 10^{-5} e 10^{-6} e $n = 1, 3$ e 5 visadas.



(a)




(b)




(c)

Figura 4.30: Medidas de macroajuste para segmentação de kk (a) 1 visada (b) 3 visadas (c) 5 visadas, para $p_0 = 10^{-6}$.


A Figura 4.31 apresenta os valores de discrepância relativas às versões segmentadas de *imgcartoon*. Alguns pontos a considerar a respeito da segmentação dessa imagem com 1 visada são as medidas relativas aos segmentos 8, 9, 17, 20, 21, 22 e 23. As medidas de ajuste $Ajpm_s$ são pequenas para estes segmentos, devido a possuírem bastantes pixels mal segmentados – Figura 4.31(a). A região ajustada relativa ao objeto 8, por exemplo, possui área bastante reduzida (1882 pixels mal segmentados na região).




(a)




(b)



(c)



(d)



(e)



(f)

Figura 4.31: (a–b–c) Medidas *RUMA* e de microajuste, (d–e–f) de macroajuste para segmentação de *imgcartoon*, com $n = 1, 3$ e 5 visadas, respectivamente ($p_0 = 10^{-6}$).

A medida *RUMA* relativa aos segmentos 20, 21 e 23 é considerada nula, em virtude dos segmentos obtidos possuírem área maior que os segmentos de referência (em função de uniões errôneas) e devido a segmentos distintos de referência apresentarem um mesmo segmento ajustado. Como posto anteriormente, esta medida não se presta muito bem para casos em que os segmentos obtidos possuem área maior que os de referência.

As medidas de ajuste geral demonstram que houve um aumento de *Totgof* em 1,4% para a segmentação de *imgcartoon* com 1 visada em relação à anterior com $p_0 = 10^{-5}$ (segundo a comparação das Figuras 4.26(b) e 4.32(b)). Para as segmentações com $p_0 = 10^{-6}$, a melhor segmentação é obtida para a imagem com 5 visadas, por apresentar menos erros em relação àquelas com 1 e 3 visadas.

Para a imagem *kk*, houve um decréscimo de 0,1% entre a medida de ajuste geral para a versão de 1 visada a $p_0 = 10^{-6}$ e aquela a $p_0 = 10^{-5}$. Isso significa que a segmentação anterior ($p_0 = 10^{-5}$) da imagem com 1 visada é 0,1% melhor que a realizada com $p_0 = 10^{-6}$, que é uma diferença quase inexpressiva. A melhor segmentação, com $p_0 = 10^{-6}$, é relativa à imagem com 3 visadas, por apresentar menos erros em relação àquelas com 1 e 5 visadas. Na imagem com 1 visada, existe grande influência de ruído, tornando a segmentação bem mais difícil. Por outro lado, a imagem de 5 visadas apresenta nível de ruído menos influente em relação à imagem de 3 visadas, o que leva ao favorecimento de mais fusões com o parâmetro $p_0 = 10^{-6}$. Logo, a combinação do número $n = 3$ visadas e o valor de p_0 neste teste com a imagem *kk* produz melhor resultado em relação às demais.

Em resumo, tanto para *kk* quanto para *imgcartoon*, as segmentações para 3 e 5 visadas ao nível $p_0 = 10^{-5}$ são comparáveis às segmentações de 3 e 5 visadas ao nível $p_0 = 10^{-6}$, levando em conta as medidas de ajuste geral constantes das Figuras 4.26 e 4.32, visto que são bastante próximas.




Figura 4.32: Medidas de ajuste geral para (a) *kk* e (b) *imgcartoon*, $p_0 = 10^{-6}$.

Comparando todas as medidas *Totgof* relativas às segmentações apresentadas para os parâmetros $p_0 = 10^{-3}$, $p_0 = 10^{-5}$ e $p_0 = 10^{-6}$, a melhor segmentação da imagem *kk* ocorre para a versão contaminada com 3 visadas e $p_0 = 10^{-5}$ (*Totgof* = 0,9814), enquanto a melhor segmentação de *imgcartoon* ocorre para a versão com 5 visadas e $p_0 = 10^{-6}$ (*Totgof* = 0,98409).

As diferenças entre as imagens de *kk* com 3 visadas com $p_0 = 10^{-3}$ (Figura 4.9(c), pág. 58) e $p_0 = 10^{-5}$ (Figura 4.20(a), pág. 66) são perceptíveis por causa dos vários fragmentos presentes na primeira, todavia as diferenças são quase indistinguíveis quando a Figura 4.20(c) é comparada com a Figura 4.27(c), pág. 72 ($p_0 = 10^{-6}$). Estas diferenças residem em pequenos fragmentos que existem nos mapas de bordas, que também podem ser visualizados nas imagens temáticas, ao longo das bordas e próximos a estas.

A segunda etapa da avaliação do segmentador utiliza a imagem *codbarras*. Ela contém segmentos lineares de diferentes espessuras e curvilineares e aplica-se ao teste suas versões contaminadas com ruído multiplicativo, geradas com $n = 1$ e 3 visadas.

4.5 Avaliação de Segmentação - Etapa II

A detecção automática de estruturas lineares de pequena espessura é de grande importância no processamento de imagens SAR, bem como para outros tipos de imagens. Tais estruturas podem representar estradas, redes de gasodutos, linhas férreas ou clareiras em florestas, por exemplo. Elas podem ser úteis no estabelecimento de pontos de referência para correção radiométrica ou em aplicações de ajuste de imagens.

Nas imagens SAR, a detecção de estruturas lineares é um problema particularmente difícil, em virtude da presença do ruído *speckle*. Vários algoritmos de segmentação podem falhar nesta empreitada e muitas vezes se recorrem a outras técnicas para tal fim [70]. As estruturas lineares usualmente variam em largura e apresentam minúsculos rompimentos ao longo de seu comprimento, cujos fragmentos podem aparecer como estruturas claras ou mais escurecidas. Uma inspeção mais cuidadosa revela que os possíveis rompimentos que porventura venham a existir ao longo de seu trajeto produzem um conjunto de pequenos fragmentos alinhados.

A detecção de linhas pode ser realizada usando técnicas locais ou técnicas globais como a transformada de Hough [33, 70]. As técnicas locais consistem basicamente de operadores (máscaras), que são mais eficientes na detecção de estruturas lineares em imagens com baixo conteúdo ruidoso. Por sua vez, técnicas globais como a transformada de Hough podem ser aplicadas para detectar estruturas lineares e curvilineares em imagens ruidosas. Esta ferramenta consiste na transformação do espaço $X - Y$ da imagem em um espaço de parâmetros, de modo que linhas retas são mapeadas para um único ponto no espaço de parâmetros. Na referência [70], esta transformada é usada para detectar estruturas lineares em imagens obtidas pelo sensor SAR580. Por sua vez, no trabalho Tupin *et al.* [71], ela é usada na detecção de redes de rodovias. Em geral, o problema de detecção de retas usando a transformada de Hough é reduzido à detecção de pontos neste espaço de parâmetros, apesar desse procedimento não ser uma tarefa muito simples.

Nesta seção é avaliada a capacidade do algoritmo de segmentação SAR proposto em isolar estruturas lineares e curvilineares e a imagem *codbarras* é usada nesta finalidade. Suas versões ruidosas, com 1 e 3 visadas, estão ilustradas na Figura 4.33. Todos os 52 segmentos de *codbarras* foram contaminados para simular retornos de regiões homogêneas. O número de visadas estimado para a imagem de 1 visada é $n = 1,05$, enquanto para a imagem de 3 visadas, $n = 3,19$. O número máximo de pixels (*maxpixels*, parâmetro do algoritmo de crescimento de regiões) deste experimento está configurado em 13.

As segmentações das imagens mostradas na Figura 4.33 estão ilustradas na Figura 4.34, com $p_0 = 10^{-4}$. A partição final da imagem de 1 visada contém 78 segmentos, enquanto a da imagem com 3 visadas apresenta 59.

A segmentação da imagem com 3 visadas é visivelmente melhor, devido a menor influência do *speckle*, o que favorece a reconstrução da maior parte dos segmentos. As demais imagens, exibidas nas Figuras 4.35 e 4.36, representam as segmentações e as imagens de tom médio de cinza, respectivas aos valores $p_0 = 10^{-5}$ e $p_0 = 10^{-6}$.

Um meio para determinar se a reconstrução dos segmentos de uma imagem SAR é bem sucedida é obter sua imagem-razão (*ratio image*) [15]. Ela consiste em realizar a razão ponto-a-ponto dos valores de cinza da imagem ruidosa original e da imagem temática. O resultado é uma imagem que deve corresponder unicamente às flutuações do *speckle*, com média unitária e desvio padrão σ_Y . Quando a segmentação é bem sucedida,

não devem aparecer estruturas visíveis na imagem-razão. Caso resquícios de objetos da imagem SAR estejam presentes na imagem-razão, então a imagem segmentada possui distorções radiométricas.




Figura 4.33: Imagem *codbarras* contaminada com ruído multiplicativo com (a) 1 visada (b) 3 visadas.

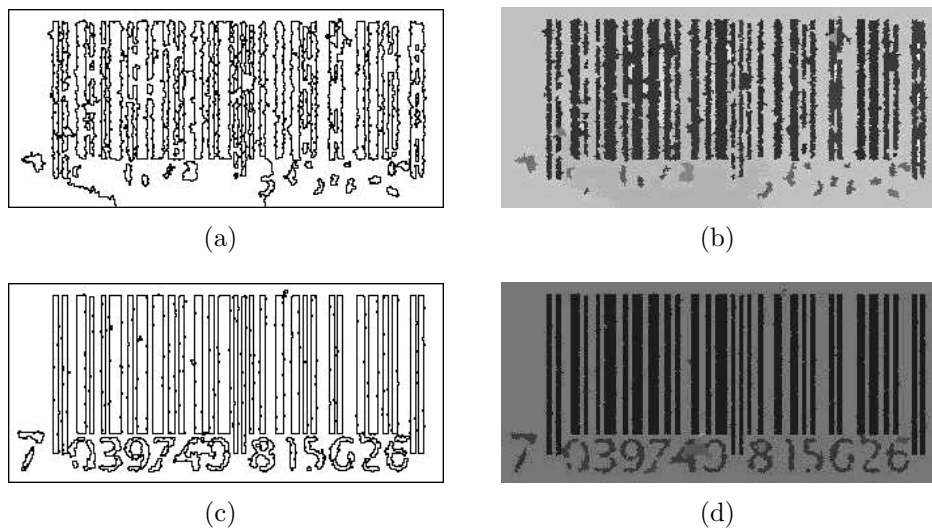


Figura 4.34: Resultados da segmentação para $p_0 = 10^{-4}$ e o (a) mapa de bordas, 1 visada (b) imagem temática (78 segmentos) (c) mapa de bordas, 3 visadas (d) imagem temática (59 segmentos).

A Figura 4.37 ilustra exemplos de imagens-razão das segmentações de *codbarras* simuladas com 1 e 3 visadas, para $p_0 = 10^{-5}$, e seus respectivos histogramas. As tonalidades das imagens-razão estão multiplicadas por 100, para efeitos de visualização, dado que são imagens muito escuras, como mostram os níveis de cinza nos histogramas.

Observa-se que a segmentação das barras para a imagem de 3 visadas é bem sucedida, pois não há estruturas aparentes na região destacada pelo retângulo branco na Figura 4.37(b). Todavia, a segmentação de alguns dígitos dessa imagem não apresenta êxito, dada a existência de pequenas estruturas na região em que se encontram os números.

Para a análise quantitativa do desempenho da segmentação de *codbarras*, não são exibidas todas as medidas de discrepância particulares para cada segmento, mas a medida de ajuste geral na Figura 4.38.

Pode-se avaliar que o segmentador proposto apresentou melhor desempenho na segmentação das versões contaminadas de *codbarras* para o nível $p_0 = 10^{-4}$. Isso pode ser confirmado visualmente através da reconstrução dos dígitos na Figura 4.34, apesar da maior quantidade de segmentos em relação às outras segmentações. O parâmetro p_0 é o controlador global da fusão de segmentos e à medida que seu valor decresce, mais relaxamento é dado à fusão, ou seja, mais segmentos são agrupados.

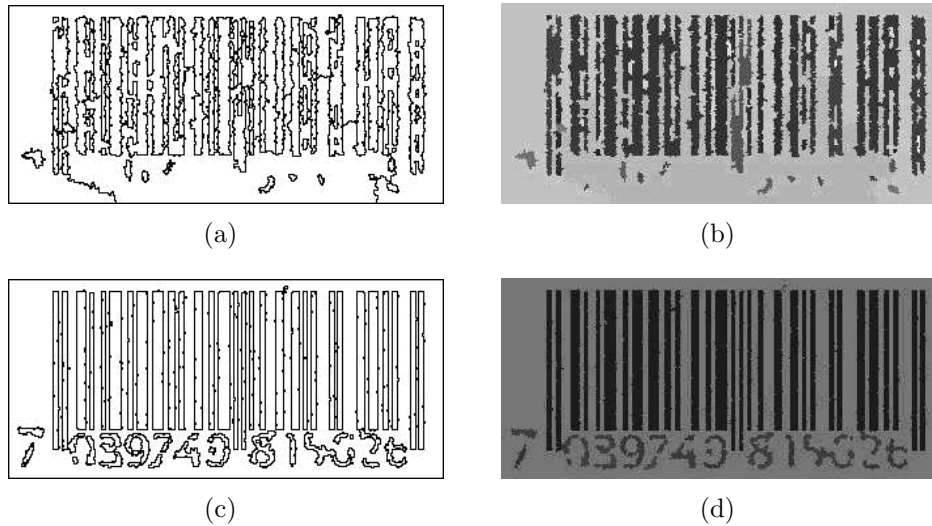


Figura 4.35: (a) Mapa de bordas, 1 visada (b) imagem temática (64 segmentos) (c) mapa de bordas, 3 visadas (d) imagem temática (53 segmentos), com $p_0 = 10^{-5}$.

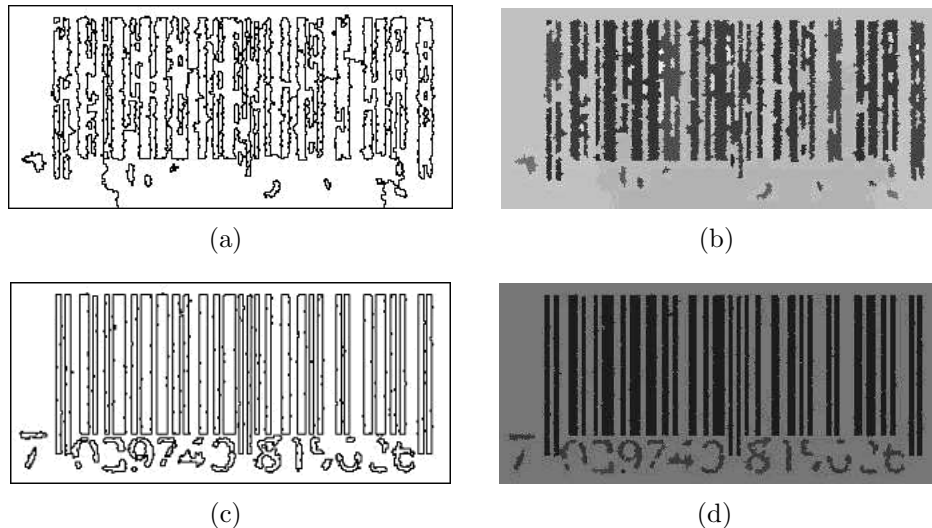


Figura 4.36: (a) Mapa de bordas, 1 visada e (b) imagem temática com 61 segmentos (c) mapa de bordas, 3 visadas e (d) imagem temática associada com 53 segmentos, para $p_0 = 10^{-6}$.

O valor mais apropriado para p_0 , que propicia uma segmentação mais próxima da ideal em termos da identificação de regiões relevantes, é 10^{-4} . Para os demais valores de p_0 (10^{-5} e 10^{-6}), se for tomada a imagem ruidosa de 1 visada, a diminuição de p_0 favorece mais fusões inadequadas. A medida de ajuste geral, portanto, reduz apreciavelmente para este caso e os grandes causadores desses erros foram os dígitos existentes em *codbarras*. Isto ocorreu porque o nível de ruído influencia bastante na geração dos segmentos iniciais e na fusão dos mesmos, à medida que o processo de segmentação evolui.

Para a imagem de 3 visadas, no entanto, os erros de segmentação são muito pequenos para os três níveis associados a p_0 e estão ligados também a identificação dos dígitos. Portanto, a melhor segmentação atribuída à imagem ruidosa *codbarras* com 3 visadas ocorre para $p_0 = 10^{-4}$, considerando o valor de $Totgof = 0,9610$.

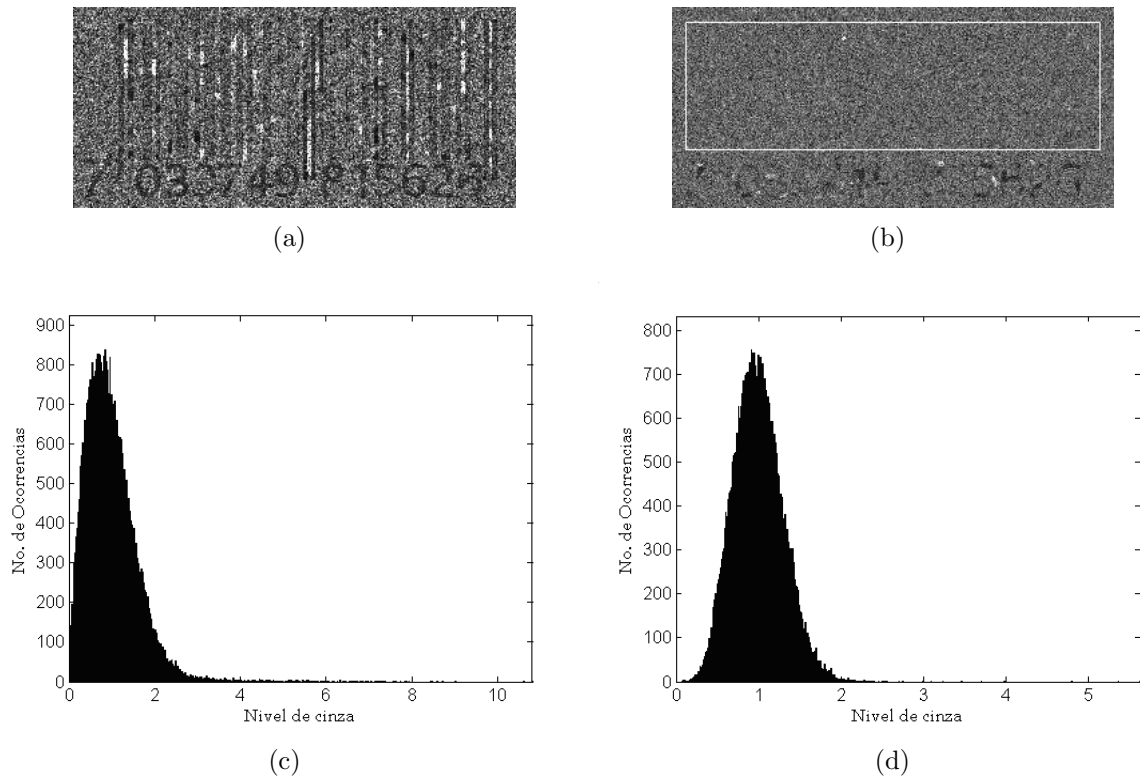


Figura 4.37: Imagens-razão e respectivos histogramas, relativos às segmentações de *codbarras* com (a-c) 1 visada (b-d) 3 visadas.




Figura 4.38: Medida *Totgof* para *codbarras*, sob diferentes valores de p_0 e número de visadas.

4.6 Análise da Segmentação de Imagens Sintéticas

A implementação do segmentador SAR deste trabalho leva em conta a formação de uma grande quantidade de regiões, que são posteriormente unidas através de um procedimento estatístico coordenado. Os microsegmentos são formados segundo a análise do coeficiente de variação e são resumidos a uma quantidade máxima de pixels durante a fase de crescimento, definida antes de iniciar o processo. O limite máximo de pixels por segmento (*maxpixels*) tende a ser extrapolado pela inserção de novos pixels, ao passo que ocorre a eliminação de buracos e de pixels isolados.

A formulação do método de segmentação tratado neste trabalho parte da premissa da homogeneidade parcial para os tipos de alvos encontrados em imagens de radar. A hipótese é que dentro de regiões heterogêneas possam existir conjuntos de pixels que exibam características homogêneas, bem como pode haver aglomerados que não seguem este modelo.

Os *clusters* homogêneos são isolados no primeiro estágio do crescimento, dado que obedecem à condição de homogeneidade, quando a janela 3×3 é deslocada nos diversos pontos da imagem. Uma vez formados os primeiros segmentos, os pixels isolados que restam podem ser incluídos nas regiões existentes, de modo a mantê-las ainda homogêneas. Nesse estágio, há uma grande quantidade de regiões contendo um número razoável de pixels, de modo a garantir um bom desempenho na fase de fusão ordenada. Daí, as fusões ocorrem por conta de decisão estatística distribucional de dois conjuntos de pixels escolhidos por vez.

Na preparação das imagens simuladas, há a preocupação em gerar pixels que reproduzam retornos de radar oriundos de superfícies homogêneas, heterogêneas e extremamente heterogêneas, de modo a testar a capacidade de segmentá-las e avaliar a extensão com que tais superfícies são reconstruídas. O desempenho do segmentador proposto melhora à medida que o número de visadas aumenta e desde que seja escolhido um valor de p_0 adequado, para que não ocorram fusões em demasia. Para a versão de 1 visada da imagem *imgcartoon*, que é bastante ruidosa, houve, em geral, comprometimento da forma e da localização das bordas dos segmentos. Valores altos de p_0 (por exemplo, 10^{-3}) conduziram à formação de vários pequenos fragmentos perdidos.


Ocorre também a formação de vários fragmentos em *kk* com 1 visada, sendo o nível de significância configurado como $p_0 = 10^{-3}$. Em contrapartida, a localização de bordas e a aproximação da forma dos objetos segmentados de *kk* é, em geral, melhor em relação à versão de 1 visada de *imgcartoon*. Isto ocorre também para os demais valores de p_0 testados.

Um fator que deve ser considerado nas segmentações retro é que as regiões da imagem simulada *kk* apresentam boa situação de contraste entre os objetos heterogêneos e extremamente heterogêneos, fato que pode ter influenciado na segmentação. Já as versões de *imgcartoon* apresentam composição de regiões de alto contraste (como é o caso das lagoas - regiões 2, 11, 16 e 19), bem como zonas de contrastes bastantes próximos (pelo menos visualmente). Essa imagem foi elaborada para complicar a localização das transições entre as regiões, principalmente na versão com 1 visada. A definição das bordas vai melhorando quando aumenta o número de visadas e as medidas de ajuste tendem a aproximar-se do valor limite unitário superior.


A influência do número de visadas pode também ser percebida na segmentação das imagens simuladas de *codbarras*. A reconstrução de segmentos lineares e curvilíneos é comprometida para a versão com 1 visada, todavia melhora sensivelmente para a versão com 3 visadas. No entanto, boa parte das estruturas relativas aos dígitos não são bem segmentadas, usando um valor de p_0 muito baixo, da ordem de 10^{-6} . A reconstrução dos objetos é melhorada para a versão com 3 visadas e $p_0 = 10^{-4}$.

4.7 Segmentação de Imagens SAR Reais

Duas segmentações geradas para um detalhe de 512×512 pixels da imagem *Caçapava* estão representadas nas Figuras 4.39(a) e 4.39(b) pelos mapas de bordas com 143 e 103 segmentos, com $p_0 = 10^{-5}$ e $p_0 = 10^{-6}$, respectivamente. Observa-se que o mapa contendo a menor quantidade de segmentos delinea bem as estruturas relevantes, tais como grande parte da extensão do rio Paraíba, as lagoas adjacentes e a zona de cultura de arroz. Outras estruturas presentes na imagem são a mancha clara, acima da região de cultivo de arroz e de forma aproximadamente retangular, e faixas semelhantes a clareiras no solo, que podem ser restos de culturas ou solo exposto (nas proximidades da cultura de arroz). A mancha possui limites visualmente imprecisos, principalmente em sua parte superior.




(a)




(b)

Figura 4.39: Mapas de bordas correspondentes às segmentações de *Caçapava* (a) 143 segmentos, $p_0 = 10^{-5}$ e (b) 103 segmentos, $p_0 = 10^{-6}$.



(a)



(b)

Figura 4.40: Imagem SAR *Caçapava*, 1 visada, amplitude.

A diminuição do valor de p_0 favorece a eliminação de alguns fragmentos diminutos existentes na Figura 4.39(a). Os mapas apresentam bordas regulares e, visualmente, existe um bom delineamento dos contornos dos objetos relevantes e há conformidade na preservação da linearidade em vários trechos do rio, da zona de cultura e das lagoas.

A imagem disposta na Figura 4.41 consiste de um exemplo de coleta de amostras (pequenas máscaras brancas) em regiões consideradas homogêneas para a estimação do número de visadas. Este parâmetro é usado durante a fase de formação dos microsegmentos, no cálculo do desvio-padrão do ruído.




Figura 4.41: Imagem SAR *Stanwick*, com número de visadas estimado em $n = 3,36$, a partir de 419 amostras coletadas em zonas homogêneas (quadrados brancos).

A imagem temática representativa do nível médio de cinza dos segmentos detectados encontra-se na Figura 4.42. Na Figura 4.43 está reproduzido o mapa de bordas relativo aos 1728 segmentos gerados ($p_0 = 10^{-4}$), que pode ser sobreposto à imagem original da Figura 4.44.

Algumas falhas evidentes na segmentação da imagem *Stanwick* podem ser observadas, tais como o seccionamento da rodovia diagonal e a presença de pequenos fragmentos ao longo dos campos, além da não detecção de partes do objeto que se assemelha a um canal sinuoso localizado nas imediações do canto superior esquerdo. A não preservação das estruturas lineares localizadas nos contornos dos campos de cultura e a estrada, por exemplo, deve-se ao valor de p_0 adotado, que pode ser considerado alto. Muitas regiões de campo apresentam-se sobresegmentadas.



Figura 4.42: Imagem temática da segmentação da imagem SAR *Stanwick*, com $p_0 = 0,0001$.




Figura 4.43: Mapa de bordas da imagem SAR *Stanwick* com 1728 segmentos, $p_0 = 0,0001$.



Figura 4.44: Imagem SAR *Stanwick*, de dimensões 768×538 pixels, gerada em amplitude.

A segmentação temática de *Stanwick*, obtida com o nível $p_0 = 10^{-7}$, está disposta na Figura 4.45 e o mapa de bordas encontra-se na Figura 4.46, em que são contados 671 segmentos.




Figura 4.45: Imagem temática da segmentação da imagem SAR *Stanwick*, com $p_0 = 10^{-7}$.

A diminuição do parâmetro p_0 de 10^{-4} para 10^{-7} favorece bastantes fusões na imagem segmentada, principalmente daqueles alvos localizados nas regiões de campos e na vila de *Stanwick*. Não obstante, é também suprimida boa parte dos segmentos que formam a rodovia na segmentação final.




Figura 4.46: Mapa de bordas da imagem SAR *Stanwick*, com 671 segmentos ($p_0 = 10^{-7}$).



Figura 4.47: Imagem SAR *Stanwick*.

As imagens dispostas nas Figuras 4.48 e 4.49 são os resultados de segmentação da imagem SAR *Pedazo*, com número de visadas estimado em 2,21, sob diferentes valores de p_0 . As estruturas de maior brilho destas imagens estão preservadas e a Figura 4.49(c) representa o mapa de bordas sobreposto à imagem original, com menor quantidade de segmentos. Observa-se um bom delineamento das bordas dos objetos relevantes da imagem *Pedazo*, principalmente nas regiões mais escuras, que são superfícies homogêneas na região central da imagem (áreas rodeadas por bosques e manchas urbanas). Outros pequenos fragmentos remanescentes consistem de alvos pontuais preservados, que possuem bom contraste com as regiões vizinhas.




Figura 4.48: Segmentações da imagem SAR *Pedazo*, (a) imagem original (b) imagem temática e mapas sobrepostos com (c) 833 segmentos, $p_0 = 10^{-5}$ e (d) 651 segmentos, $p_0 = 10^{-6}$.




Figura 4.49: Segmentações da imagem SAR *Pedazo* (a) mapa sobreposto (515 segmentos, $p_0 = 10^{-7}$) (b) imagem temática (c) mapa de bordas (409 segmentos, $p_0 = 10^{-8}$) (d) imagem temática.

As imagens exibidas na Figura 4.50 ilustram a segmentação de manchas de óleo no mar. A segmentação ideal consiste no completo isolamento da mancha escura sobre a água e a seqüência de segmentações mostra que a quantidade de segmentos diminui à medida que p_0 decresce. Embora exista ainda um considerável número de fragmentos resultantes do valor de p_0 adotado, é possível observar um bom delineamento ao longo da interface mancha-água na Figura 4.50(d).

A imagem *Zone* destacada na Figura 4.51 é uma imagem difícil de ser interpretada visualmente, por causa da grande quantidade de regiões de cultura existentes e das incertezas sobre localização das zonas de transição para vários segmentos. Esta imagem apresenta baixo contraste entre zonas de diferentes refletividades. Em geral, as imagens obtidas em banda L apresentam maior nível de ruído em relação àquelas geradas por sensores SAR que operam em outras bandas (C e X, por exemplo). Em relação às bandas C e X, a banda L apresenta maior poder de penetração e as imagens captadas são bastante ruidosas.

Possíveis diferenças visuais perceptíveis entre superfícies detectadas nas bandas C e X podem aparecer como uma única região nas imagens geradas em banda L, como se pode observar no detalhe da imagem SAR *Zone* da Figura 4.51.




Figura 4.50: (a) Mancha de óleo de 512×512 pixels, com 5,15 visadas estimadas e mapas sobrepostos contendo (b) 689 ($p_0 = 10^{-5}$), (c) 287 ($p_0 = 10^{-7}$) e (d) 190 segmentos ($p_0 = 10^{-8}$).

De modo análogo, a segmentação da imagem SAR *Flevoland*, disposta na Figura 4.52, apresenta os mesmos problemas. O mapa de bordas contém 668 segmentos e se refere ao detalhe de 512×512 pixels da imagem ilustrada na Figura 4.53. Neste mapa, observa-se uma estrutura escura semelhante a um lago, duas grandes regiões desabitadas (na parte superior e no centro da imagem), várias zonas de cultura e canais de irrigação na diagonal. Observa-se ainda que as regiões desocupadas apresentam-se sobresegmentadas, bem como o lago. Os limites de algumas zonas de cultivos não estão com seus contornos bem definidos. Com relação à preservação de estruturas lineares, há somente alguns trechos dos canais de drenagem. Os canais de pequena espessura em meio ao ruído não são detectados pelo segmentador. A imagem temática exibida na Figura 4.54 permite visualizar os objetos encontrados.

Os mapas de bordas constantes da Figura 4.55 ilustram os segmentos detectados na imagem *Sar580* ilustrada na Figura 4.56, gerada em banda L, obtidos com dois níveis de significância distintos. As bordas apresentam-se sinuosas ao longo da interface restolho-floresta, na qual os limites visuais são imprecisos por causa do ruído.

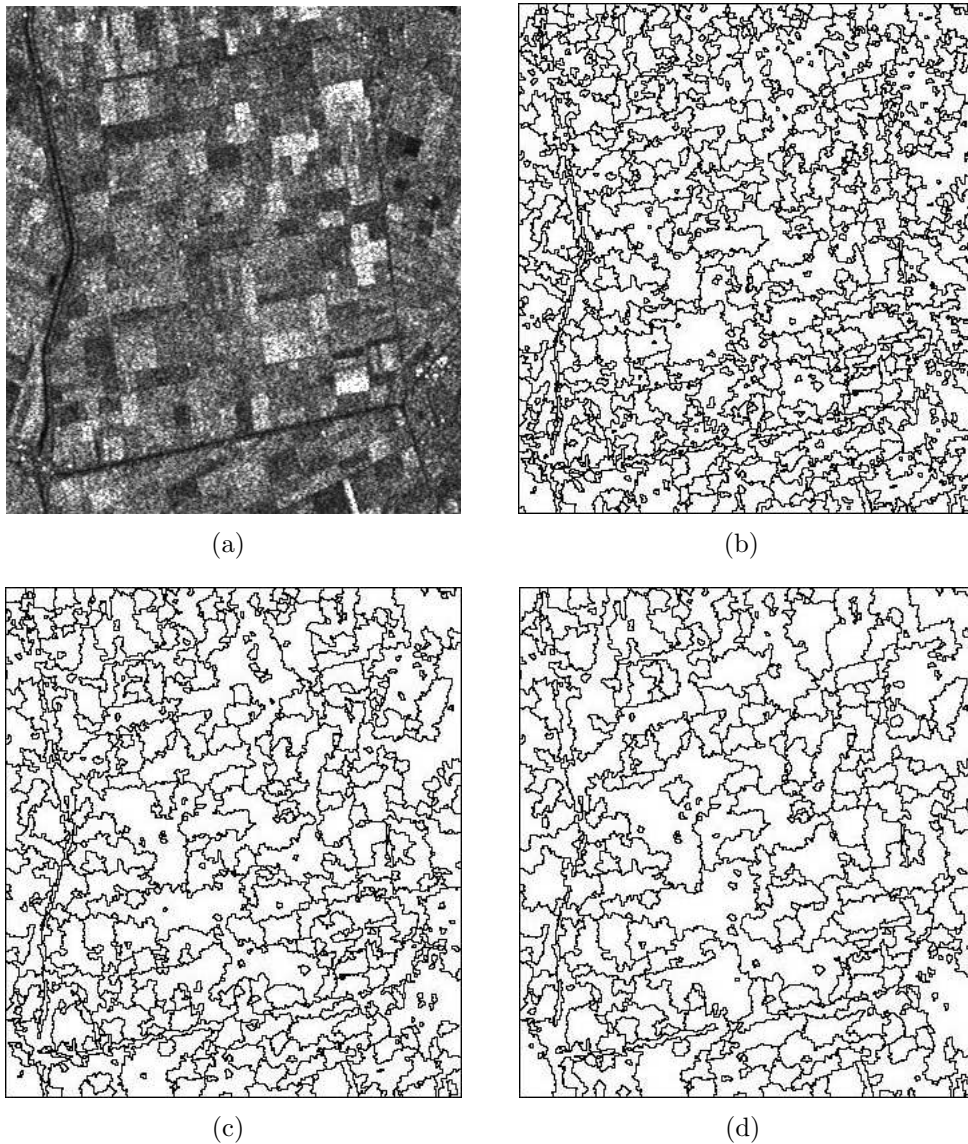


Figura 4.51: Segmentações da imagem *Zone* (a) imagem original, 3,1 visadas estimadas e mapas obtidos com (b) 798 $p_0 = 10^{-3}$, (c) 492 $p_0 = 10^{-4}$ e (d) 344 segmentos, $p_0 = 10^{-5}$.

O mapa disposto na Figura 4.57(b) apresenta a floresta composta por dois segmentos principais, o que permite deduzir que mais fusões são necessárias para segmentar completamente a mesma, bem como outras regiões da área próxima aos tanques de tratamento de esgoto (canto inferior direito).

A versão em banda X da imagem *Sar580* está segmentada na Figura 4.57, sendo que o resultado produzido com $p_0 = 10^{-6}$ ainda não é satisfatório, dada a existência de vários fragmentos distribuídos na imagem. A segmentação realizada com $p_0 = 10^{-8}$ gera uma quantidade menor de segmentos, 162.




Figura 4.52: Mapa de bordas de um detalhe da imagem *Flevoland*, com 668 segmentos, $p_0 = 10^{-5}$.



Figura 4.53: Recorte de 512×512 pixels da imagem *Flevoland*.






Figura 4.54: Imagem temática relativa à segmentação da imagem *Flevoland*, com $p_0 = 10^{-5}$.




(a)




(b)

Figura 4.55: Mapas de bordas da imagem *Sar580*, banda L, 1 visada, com (a) 93, $p_0 = 10^{-7}$ e (b) 60 segmentos, $p_0 = 10^{-8}$.




(a)




(b)

Figura 4.56: Imagem *Sar580*, gerada em banda L, 512×512 pixels.




(a)



(b)

Figura 4.57: Mapas de bordas da imagem *Sar580*, gerada em banda X, 1 visada, com (a) 337, $p_0 = 10^{-6}$ e (b) 162 segmentos, $p_0 = 10^{-8}$.



(a)



(b)

Figura 4.58: Imagem *Sar580*, gerada em banda X, 512×512 pixels.

4.8 Discussão Geral do Método Proposto

Com base nos resultados de simulação obtidos das imagens de teste e das imagens SAR segmentadas, pode-se concluir que:

- O procedimento de crescimento de regiões favorece a geração de uma menor quantidade de segmentos na partição da imagem sob análise, quando comparada ao número de objetos que seriam criados aplicando uma tesselação na mesma. A tesselação, apesar de ser simples e direta, muitas vezes produz uma grande quantidade de regiões quadradas e o reduzido número de pixels por segmento poderia comprometer o desempenho do processo hierárquico-estatístico implementado. O método desenvolvido para formação da partição por crescimento de regiões minimiza a existência de segmentos contendo poucos pixels e não compromete a resolução final desejada para os contornos dos objetos segmentados;
- A fusão estatística de regiões, realizada consoante a eleição de duas regiões por vez na árvore hierárquica, é obtida através do teste de Kolmogorov-Smirnov (KS), que apresenta melhor desempenho em relação aos testes t de Student e de variâncias desiguais. Estes últimos são considerados testes paramétricos, em que é assumido que as amostras provenientes de duas regiões eleitas para fusão são normalmente distribuídas. Esta hipótese ocorre para dados SAR processados sob grande número de visadas (da ordem de cinco ou mais), podendo tais dados ser modelados com outras distribuições, inclusive a Normal. O teste KS, por ser não paramétrico, assume que os dados podem possuir quaisquer distribuições. Nele, é testada a hipótese que dois conjuntos de pixels provêm de uma mesma distribuição particular, que caracteriza o tipo de superfície refletora. Caso isso se confirme, duas regiões eleitas na árvore hierárquica são unidas, pois seus dados (pixels em meio ao ruído) não são significativamente diferentes;
- O parâmetro de controle da fusão do teste KS influencia na quantidade de segmentos obtidos. À medida que este parâmetro diminui, menor é a quantidade final de segmentos. No entanto, valores muito pequenos desse parâmetro podem levar a fusões em demasia e a segmentação obtida pode não ficar muito próxima daquela esperada por um especialista. A diminuição deste parâmetro aumenta também o tempo de processamento;
- A ocorrência de mais fusões não necessariamente implica que todas serão aceitas, visto que a diminuição do valor do parâmetro de controle p_0 implica em maior proteção contra um tipo de erro intrínseco do teste (*erro do Tipo I*). Os segmentos mais similares são unidos, porque o teste de hipóteses determina que seus pixels advêm de uma mesma população, ao nível especificado pelo usuário. Como consequência, ocorre a diminuição da quantidade de pequenos fragmentos que se formaram dentro das zonas relevantes, durante a fase de crescimento;
- O aumento do tempo computacional está relacionado ao processo de fusão usando o teste de Kolmogorov-Smirnov. Conforme explicado, nem todas as fusões podem ser aceitas a um determinado nível de significância especificado e isto depende também da complexidade e do tamanho da imagem. No método desenvolvido, mais tempo é requerido para testar a hipótese de fusão, conforme aumenta a quantidade de pixels por segmento;

- Os algoritmos componentes do segmentador proposto neste trabalho são desenvolvidos sob a forma de scripts do ambiente de simulação Matlab[®]. Como este possui uma linguagem de programação interpretada, a execução dos algoritmos é lenta, em razão de certas rotinas dependerem de outras embutidas neste aplicativo. Deve ser considerado ainda que a execução de algoritmos voltados ao processamento de imagens, em geral, é mais lenta. Isto deve-se ao fato de se trabalhar com dados, no mínimo, em duas dimensões.

Com relação às medidas extraídas na primeira e segunda etapas da avaliação, pode-se concluir que:

- As medidas de macroajuste de posição ($Fitxy$) e de intensidade ($Fiti$) relativas às segmentações de kk e de $imgcartoon$ assumem, em geral, valores próximos da unidade, para os objetos segmentados sob diferentes visadas e valores de parâmetro p_0 . Pode-se avaliar que, segundo as medidas $Fitxy$ (posição) e $Fiti$ (intensidade), as segmentações apresentaram-se com boa correção de intensidade e posição (os centros de gravidade dos objetos segmentados se aproximam daqueles ideais), à medida que aumenta o número de visadas e distintos valores de p_0 . O nível de ruído presente nas imagens SAR é um fator determinante na qualidade da segmentação obtida e a sua influência é maior quando as imagens apresentam pequeno número de visadas (da ordem de 1). Em função disso, a qualidade da segmentação é degradada e pode comprometer a correção de intensidade, posição e forma dos objetos segmentados;
- Todas as demais medidas foram utilizadas para avaliar o desempenho do segmentador sob diferentes aspectos. É de interesse também investigar outras medidas que permitam avaliar o desempenho da segmentação, sob os aspectos de preservação de forma, radiometria e preservação de bordas.

Capítulo 5

Conclusões e Perspectivas

5.1 Conclusões

A pesquisa em segmentação de imagens de radar de abertura sintética (SAR) ainda prossegue como um tema desafiador a ser explorado. Nesse sentido, é elaborada uma nova metodologia de segmentação, mediante a fusão estatística de uma massiva segmentação inicial realizada sobre estas imagens. O grande desafio em processar imagens de radar é decorrente da natureza ruidosa do processo de aquisição pelo sistema imageador.

A formulação e o desenvolvimento de segmentadores aplicados a imagens SAR partem de algumas premissas para os tipos de cenas encontradas. Uma delas é que tais imagens sejam constituídas de zonas homogêneas e o segmentador deverá identificá-las, sendo sua idealização baseada em estatísticas definidas para tais regiões.

Este princípio é aplicado neste trabalho, usando a definição de coeficiente de variação para a geração de pequenos segmentos homogêneos que, com a agregação de novos pixels, crescem para formar segmentos maiores. Em áreas heterogêneas porventura presentes nas imagens de radar processadas, os pixels tendem a formar agrupamentos homogêneos isolados, sendo esta hipótese o ponto de partida para o desenvolvimento desta pesquisa.

A utilização do coeficiente de variação também é útil para segregar os pixels na faixa de transição entre superfícies com diferentes refletividades. O coeficiente de variação, segundo alguns autores, é sensível à presença de bordas, independente da direção das mesmas. Por esta razão, este parâmetro está combinado à técnica de crescimento de regiões para a inserção de pixels nos segmentos iniciais gerados por uma janela 3×3 , que busca aleatoriamente pontos sementes na imagem.

Para testar e avaliar o desempenho do segmentador proposto são utilizadas algumas imagens contaminadas artificialmente com ruído *speckle*. A contaminação é realizada de acordo com distribuições de probabilidade específicas para cada tipo de região, cuja geração dos pixels segue o modelo multiplicativo para dados SAR.

Os resultados de segmentação obtidos a partir do uso das imagens *phantom kk*, *imgcartoon* e *codbarras*, com distintos número de visadas (n) e níveis de significância (p_0), permitiram testar o método apresentado. Seu desempenho pode ser considerado bom, corroborado pela boa correção da localização de bordas e pela medida de ajuste geral (*Totgof*). Os valores dessa e das demais medidas aproximam-se do valor unitário para a maior parte dos segmentos das imagens de teste. O valor unitário é o caso ideal de segmentação perfeita, quando é tomada uma segmentação de referência para comparação.

5.2 Contribuições e Trabalhos Futuros

Devido à complexidade da segmentação das imagens SAR, este é um tema que requer contínuo aprimoramento e vários estudos são realizados neste campo para facilitar a interpretação e o entendimento destas fontes de informação. Dentre as contribuições deste trabalho, pode-se citar:

- O desenvolvimento de um método de crescimento de regiões para a formação de regiões estatisticamente homogêneas e não homogêneas, para favorecer a preservação de resolução dos contornos dos objetos segmentados. Este algoritmo foi implementado com base na análise do coeficiente de variação, combinado à técnica clássica de crescimento de regiões, evitando a aplicação direta de uma tesselação na imagem sob análise. Todo o processo ocorre com os pixels originais da imagem SAR, dispensando filtragem preliminar ou algum tipo de tratamento de dados para criar uma partição inicial por supersegmentação, disponível para o processo de fusão (Seção 3.2);
- A proposição do uso combinado de um algoritmo clássico de análise da estrutura hierárquica em imagens (HSWO) e do teste de Kolmogorov-Smirnov, para coordenar e realizar a fusão estatística das regiões da partição gerada pela etapa de crescimento de regiões. A aplicação combinada destes dois métodos favorece uma segmentação na qual as regiões de mesmas características distribucionais (oriundas de alvos de situados em zonas homogêneas e heterogêneas) são unidas mediante o teste KS. O mesmo é propício para determinar hipóteses com base na distribuição estatística das amostras de cada região (Seções 3.6.4 e 3.6.6) ;
- A formulação de um novo critério de custo com base razão de médias da população de pixels de fronteira e outras características locais dos pares de regiões adjacentes. Tal critério é usado para definir os custos de união na árvore hierárquica. Observa-se que a aplicação desta função de custo diminui as chances de ocorrência de pequenos fragmentos irrelevantes na segmentação final das imagens SAR (Seções 3.6.4 e 3.6.5).

Relativamente às sugestões de melhorias para este trabalho, é possível destacar:

1. A necessidade de estabilizar o algoritmo de crescimento de regiões, tornando praticável a geração da mesma partição adequada ao procedimento de fusão, sempre que tal algoritmo é executado. Como explicado no Capítulo 3, nesta etapa são procurados vários segmentos homogêneos na imagem, de modo aleatório, até que não haja mais regiões, quando então se inicia a alocação de pixels nos segmentos gerados. Essa busca aleatória inviabiliza a reprodução da mesma disposição dos segmentos na partição gerada. Como consequência, esta aleatoriedade se propaga para os demais processos (formação da tabela de custos e fusão estatística, ambos determinísticos), pois a organização, a forma e o conteúdo das microregiões mudam.
2. A geração de microsegmentos com forma e posição aleatórias é intrínseca ao método desenvolvido, sendo possível contornar este problema melhorando o método de fusão ordenado de regiões, ou através de um processo mais refinado de detecção de bordas. No primeiro caso, deve ser investigado um processo de fusão ordenado que seja robusto a esta aleatoriedade da forma, número e tamanho dos microsegmentos, de modo a encontrar as bordas reais próximas daquelas consideradas ideais para os objetos relevantes da imagem. Na segunda hipótese, a detecção de bordas mais aprimorada poderia ser combinada ao processo de fusão para melhor determinar a similaridade de segmentos adjacentes, à medida que a fusão se desenvolve;

3. O método de fusão hierárquica desenvolvido neste trabalho aplica o teste de hipóteses de Kolmogorov-Smirnov (KS). Este apresenta, entretanto, algumas imperfeições oriundas do cálculo da distância D , tal como é realizado através da Equação 3.19, pág. 45;
4. Outra abordagem que deve ser investigada é a combinação do teste KS com outras técnicas, entre elas a detecção de bordas e a localização preliminar de estruturas lineares na imagem de radar. Supõe-se que a combinação de vários critérios para validar a fusão de segmentos pode diminuir as chances de erros, ao invés de um único método preponderar no processo de união hierárquica. Nesse contexto, devem ser também estudados outros critérios de custo para a formação da tabela (RAG), de modo a eleger o mais semelhante possível par de regiões;
5. Convém ainda verificar a possibilidade de executar o teste KS usando apenas um conjunto reduzido de pixels relevantes, representativos de cada par de regiões eleitas na árvore hierárquica, ao invés de usar todas as amostras do par. No levantamento das funções de distribuição empíricas realizada pelo teste de hipóteses, à luz da teoria apresentada, os pixels ruidosos de valores radiométricos próximos constituem fontes de informação redundante. Assim, a determinação das amostras relevantes de cada segmento pode favorecer a celeridade do teste, à medida que novos segmentos advêm da agregação de vários pixels por vez;
6. Sugere-se ainda a investigação do método *bootstrap* e suas aplicações¹ no processo de fusão hierárquica. Esta técnica consiste em usar (re)amostragem de dados, com vistas a obter pseudo-amostras adicionais e extrair informações dessas novas amostras, o que é útil quando se trabalha com pequena quantidade de pixels por segmento. Esta técnica permitiria melhorar a inferência acerca das amostras originais da partição, favorecendo sua aplicação combinada a um teste de hipóteses, para unir segmentos com maior confiabilidade;
7. Considera-se também como perspectiva futura a comparação de desempenho deste segmentador com outros algoritmos de segmentação de imagens SAR já existentes, entre eles o MUM (*Merge Using Moments*). Outra necessidade é avaliar o desempenho da técnica proposta perante outros algoritmos de segmentação, que processem imagens pré-filtradas. Destarte, pode-se determinar se o desempenho do segmentador desenvolvido neste trabalho é melhor que aqueles apresentados por segmentadores que operam sobre imagens SAR filtradas;
8. Outro tema a pesquisar consiste em segmentar imagens SAR de regiões costeiras, com a finalidade de extrair a linha de costa ou fronteira terra-água. A identificação da linha de costa possui algumas aplicações, tais como o mapeamento e o monitoramento de regiões costeiras, sob a ação da indústria petrolífera.

¹A descrição deste método e suas aplicações são apresentadas nas referências [72, 73].

Referências Bibliográficas

- [1] T. M. Lillesand e R. W. Kiefer, *Remote sensing and image interpretation*, 3ª edição. Nova York: John Wiley & Sons, 1994. (document), 1.1, 1.1
- [2] S. Allen, L. Gagnon e F. Lesage, “Hydreous area segmentation in radar imagery by level-set based snakes,” In *Proceedings of the 10e Congrès de l’Association Québécoise de Télédétection (AQT)*, Ste-Foy, Quebec, Canadá, 21–24 Outubro 2001, pp. 479–484. (document)
- [3] R. J. Dekker, “Texture analysis of urban areas in ERS SAR imagery for map updating,” *IEEE/ISPRS Joint Workshop Remote Sensing and Data Fusion over Urban Areas*, pp. 226–230, Novembro 2001. (document)
- [4] F. Ribbes e T. L. Toan, “Use of ERS-1 SAR data for ricefield mapping and rice crop parameters retrieval,” *International Geoscience and Remote Sensing Symposium IGARSS’96*, Vol. 04, pp. 1983–1985, 27–31 Maio 1996, Lincoln, Nebraska. (document)
- [5] D. Borghys, C. Perneel e M. Acheroy, “Detection of built-up areas in polarimetric SAR images,” *Int. Workshop on Pattern Recognition for Remote Sensing - PRRS*, 2000, [Online] Disponível em <http://www.sic.rma.ac.be/~dborghys/Publications/PRRS.pdf>, acessado em 17.dez.04. (document)
- [6] K. Eldhuset, “Principles and performance of an automated ship detection system for SAR images,” *International Geoscience and Remote Sensing Symposium IGARSS’89*, Vol. 01, pp. 358–361, 10–14 Julho 1989. (document)
- [7] —, “An automated ship and ship wake detection system for spaceborne SAR images in coastal regions,” *IEEE Trans. on Geoscience and Remote Sensing*, Vol. 34, No. 04, pp. 1010–1019, Julho 1996. (document)
- [8] A. Niedermeier, E. Romaneessen e S. Lehner, “Detection of coastlines in SAR images using wavelet methods,” *IEEE Trans. on Geoscience and Remote Sensing*, Vol. 38, No. 05, pp. 2270–2281, Setembro 2000. (document)
- [9] A. Niedermeier, S. Lehner e J. V. D. Sanden, “Monitoring big river estuaries using SAR images,” *International Geoscience and Remote Sensing Symposium IGARSS’01*, Vol. 04, pp. 1756–1758, 09–13 Julho 2001, Sidney, Austrália. (document)
- [10] M. I. Skolnik, *Introduction to Radar Systems*. Nova York: McGraw-Hill, 1962. 1.1
- [11] J. C. Curlander e R. N. McDonough, *Synthetic aperture radar: systems and signal processing*. Nova York: John Wiley & Sons, 1991. 1.1, 1.1, 1.2
- [12] J. P. Fitch, *Synthetic Aperture Radar*. Nova York: Springer-Verlag, 1988. 1.1
- [13] P. Moreels e S. E. Smrekar, “Watershed identification of polygonal patterns in noisy SAR images,” *IEEE Transactions on Image Processing*, Vol. 12, No. 07, pp. 740–750, Julho 2003. 1.1

- [14] E. A. Carvalho, “Imageamento através de radar de abertura sintética e suas aplicações,” Universidade Federal do Ceará - Dept. de Eng. de Teleinformática, Fortaleza, CE, Monografia (Pós-graduação em Eng. de Telecomunicações), Setembro 2003. 1.1, 1.2, 3.1
- [15] C. Oliver e S. Quegan, *Understanding Synthetic Aperture Radar Images*. Boston: Artech House, 1998. 1.3, 3.5, 4.5
- [16] L. A. Frulla, J. A. Milovich e D. A. Gagliardini, “Automatic computation of speckle standard deviation in SAR images,” *International Journal of Remote Sensing*, Vol. 21, No. 05, pp. 2883–2899, 2000. 1.3, 2.2, 3
- [17] J. S. Lee, “Speckle supression and analysis for synthetic aperture radar images,” *Optical Engineering*, Vol. 25, No. 5, pp. 636–643, Maio 1986. 2.2
- [18] A. C. Frery, H. J. Müller, C. C. F. Yanasse e S. J. S. Sant’Anna, “A model for extremely heterogeneous clutter,” *IEEE Trans. on Geoscience and Remote Sensing*, Vol. 35, No. 03, pp. 648–659, Maio 1997. 2.2, i
- [19] C. C. F. Yanasse, A. C. Frery e S. J. S. Sant’Anna, “Stochastic distributions and the multiplicative model: relations, properties, estimators and applications to SAR image analysis,” Instituto Nacional de Pesquisas Espaciais - INPE, São José dos Campos, SP, Notas Técnico-Científicas (5630-NTC/318), 1995. 2.2, 2.2
- [20] A. J. Luckman, A. C. Frery, C. C. F. Yanasse e G. B. Groom, “Texture in airborne SAR imagery of tropical forest and its relationship to forest regeneration stage,” *International Journal of Remote Sensing*, Vol. 18, No. 06, pp. 1333–1349, 1997. 2.2
- [21] M. Abramowitz e I. Stegun, *Handbook of Mathematical Functions: With Formulas, Graphs, and Mathematical Tables*. Nova York: Dover Publications, 1964. 2.2, 3.6.2
- [22] F. Cribari-Neto, A. C. Frery e M. F. Silva, “Improved estimation of clutter properties in speckled imagery,” *Computational Statistics and Data Analysis*, Vol. 40, No. 04, pp. 801–824, 2002. 2.2, 1, 2.3.3, 2.2
- [23] P. R. Vieira, “Desenvolvimento de classificadores de máxima verossimilhança para imagens SAR,” Dissertação de Mestrado (INPE-6124-TDI/585), Instituto Nacional de Pesquisas Espaciais - INPE, São José dos Campos, SP, 1996. ii, 2.2, 2.1, 3.2
- [24] T. Pacitti e C. P. Atkinson, *Programação e Métodos Computacionais*. Rio de Janeiro: LTC Editora, 1976, Vol. 02. 2.3
- [25] E. V. D. Lucca, “Avaliação e comparação de algoritmos de segmentação de imagens de radar de abertura sintética,” Dissertação de Mestrado em Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais - INPE, São José dos Campos, SP, 1998, [Online] Disponível em <http://www.dpi.inpe.br/teses/lucca/>, acessado em 02.mar.05. 2.3, 2.3.1, 2.3.2, 2.3.3, 3.6, 4.2, 4.2.1, 4.2.1
- [26] L. Devroye, *Non-uniform random variate generation*. Nova York: Springer-Verlag, 1986, [Online] Disponível em <http://jeff.cs.mcgill.ca/~luc/rnbookindex.html>. 2.3
- [27] W. Press, S. A. Teukolsky, W. T. Vetterling e B. P. Flannery, *Numerical Recipes in C: The Art of Scientific Computing*, 2ª edição. Nova York: Cambridge University Press, 1992. 2.3, 3.6.2, 3.6.2, 3.6.3, 3.6.6, 3.18, 3.6.6, 3.6.6
- [28] W. J. J. Kennedy e J. E. Gentle, *Statistical Computing*. Nova York: Marcel Dekker, 1980. 2.3

- [29] D. H. Best, “A simple algorithm for the computer generation of random samples from Student’s t or symmetric beta distribution,” In *COMPSTAT 1978: Proceedings in Computational Statistics*, L. C. A. Corsten e J. Hermans, Eds. Viena, Áustria: Physica Verlag, 1978, pp. 341–347. 2.3
- [30] M. D. Jöhnk, “Erzeugung von betavestailten und gammavestailten zufellszahlen,” *Metrika*, pp. 5–15, 1964. 2.3
- [31] P. R. Tadikamalla, “Computer generation of gamma random variables,” *Communications of ACM*, Vol. 21, No. 05, pp. 419–422, 1978. 2.3
- [32] O. H. Bustos, A. G. Flesia e A. C. Frery, “Simulation of correlated intensity SAR images,” *XII Simpósio Brasileiro de Computação Gráfica e Processamento de Imagens (SIBGRAPI)*, pp. 317–326, 17–20 Outubro 1999, Campinas, SP. 2.3.3
- [33] R. C. Gonzalez e R. E. Woods, *Processamento de imagens digitais*. São Paulo: Edgard Blücher, 2000. 3.1, 4.5
- [34] L. Vincent e P. Soille, “Watersheds in digital space: An efficient algorithm based on immersion simulations,” *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. 13, No. 06, pp. 583–598, 1991. 3.1
- [35] S. J. S. Sant’Anna, “Avaliação do desempenho de filtros redutores de speckle em imagens da radar de abertura sintética,” Dissertação de Mestrado em Sensoriamento Remoto/Processamento de Imagens, Instituto Nacional de Pesquisas Espaciais - INPE, São José dos Campos, SP, 1995. 3.1, 3.2
- [36] R. C. P. Marques, “Filtragem de ruído speckle em imagens de radar de abertura sintética e avaliação dos efeitos sobre a segmentação,” Dissertação de Mestrado em Sinais e Sistemas, Universidade Federal do Ceará - Dept. de Eng. Elétrica, Fortaleza, CE, 2004. 3.1
- [37] K. M. Costa, “Filtragem interagente de imagens com ruído speckle,” Dissertação de Mestrado, Universidade Federal de Pernambuco - Centro de Informática, Recife, PE, 2004. 3.1
- [38] R. C. P. Marques, E. A. Carvalho, R. C. S. Costa e F. N. S. Medeiros, “Filtering effects on SAR images segmentation,” In *11th International Conference on Telecommunications ICT’04*, ser. Lecture Notes in Computer Science, J. N. de Sousa, Ed., Vol. 3124. Alemanha: Springer-Verlag, Agosto 2004, pp. 1041–1046. 3.1
- [39] I. Tannous e J. P. Arif, “SAR images segmentation using region growing approach,” *International Geoscience and Remote Sensing Symposium IGARSS’89*, Vol. 03, pp. 1209–1213, 10–14 Julho 1989, Vancouver, Canadá. 3.1
- [40] R. Cook, I. McConnel, C. Oliver e E. Welbourne, “MUM (*Merge Using Moments*) segmentation for SAR images,” *Euopto Conf. on SAR Data Processing for Remote Sensing, SPIE*, Vol. 2316, pp. 92–103, 1994, Roma. 3.1, 3.2, 3.6, 3.6.1, 3.6.2, 3.6.5
- [41] D. Stewart, D. Blacknell, A. Blake, R. Cook e C. Oliver, “Optimal approach to SAR image segmentation and classification,” *IEE Proc. on Radar, Sonar and Navigation*, Vol. 147, No. 03, pp. 134–142, Junho 2000. 3.1
- [42] J. C. Tilton, “Image segmentation by iterative parallel region growing and splitting,” *International Geoscience and Remote Sensing Symposium IGARSS’89*, pp. 2420–2423, 10–14 Julho 1989, Vancouver, Canadá. 3.1
- [43] R. Caves, S. Quegan e R. G. White, “Quantitative comparison of the performance of SAR segmentation algorithms,” *IEEE Trans. on Image Processing*, Vol. 07, No. 11, pp. 1534–1546, Novembro 1998. 3.1

- [44] R. G. White, “Change detection in SAR imagery,” *International Journal of Remote Sensing*, Vol. 12, No. 02, pp. 339–360, 1991. 3.1
- [45] J. M. Park, W. J. Song e W. A. Pearlman, “Speckle filtering of SAR images based on adaptive windowing,” *IEE Proc. on Vision, Image and Signal Processing*, Vol. 146, No. 04, pp. 191–197, Agosto 1999. 3.2, 3.2, 3.3, 3.3
- [46] E. Kreyszig, *Advanced Engineering Mathematics*, 8ª edição. EUA: John Wiley & Sons, 1999. 3.2
- [47] A. J. Sephton, L. M. J. Brown, J. T. Macklin, K. C. Partington, N. J. Veck e W. G. Rees, “Segmentation of synthetic-aperture radar imagery of sea ice,” *International Journal of Remote Sensing*, Vol. 15, No. 04, pp. 803–825, 1994. 3.2
- [48] C. J. Oddy e A. J. Rye, “Segmentation of SAR images using a local similarity rule,” *Pattern Recognition Letters*, Vol. 01, pp. 443–449, 1983. 3.2
- [49] B. Ogor, V. Haese-coat e J. Ronsin, “SAR image segmentation by mathematical morphology and texture analysis,” *International Geoscience and Remote Sensing Symposium IGARSS'96*, Vol. 01, pp. 717–719, Maio 1996, Lincoln, Nebraska. 3.2
- [50] A. Mérigot, “Revisiting image splitting,” *12th IEEE International Conference on Image Analysis and Processing ICIAP'03*, pp. 314–319, 17–19 Setembro 2003, Mantova, Itália. 3.3
- [51] J. M. Beaulieu e J. M. Goldberg, “Hierarchy in picture segmentation: a stepwise optimization approach,” *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. 11, No. 02, pp. 150–163, Fevereiro 1989. 3.5, 3.5, 3.5, 3.10
- [52] J. M. Beaulieu, “Utilisation of segment border information in hierarchical segmentation,” Universidade de Laval, Dept. de Informática, Quebec, Canadá, Relatório Técnico, 2004, [Online] Disponível em <http://www.casi.ca/papers/3-11.pdf>, acessado em 10.dez.04. 3.5
- [53] K. Haris, S. N. Efstratiadis, N. Maglaveras e A. K. Katsaggelos, “Hybrid image segmentation using watersheds and fast region merging,” *IEEE Trans. on Image Processing*, Vol. 07, No. 12, pp. 1684–1699, Dezembro 1998. 3.5, 3.5
- [54] J. H. Ward, “Hierarchical grouping to optimize an objective function,” *Journal of the American Statistical Association*, Vol. 58, pp. 236–244, 1963. 3.5
- [55] G. B. Bénié, K. P. B. Thomson e M. Goldberg, “A comparison of four algorithms in the context of agricultural remote sensing,” *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 44, pp. 1–13, 1989, Amsterdam, Holanda. 3.5
- [56] G. B. Bénié e K. P. B. Thomson, “Hierarchical image segmentation using local and adaptive similarity rules,” *International Journal of Remote Sensing*, Vol. 13, No. 08, pp. 1559–1570, 1992. 3.5
- [57] R. Fjortoft, A. Lopès, P. Marthon e E. Cubero-Castan, “Different approaches to multi-edge detection in SAR images,” *International Geoscience and Remote Sensing Symposium IGARSS'97*, pp. 200–206, 04–06 Agosto 1997. 3.5
- [58] R. Fjortoft, P. Marthon e A. Lopès, “Multiresolution edge detection in SAR images,” *Norwegian Signal Processing Symposium NORSIG'97*, pp. 06–10, 24–27 Maio 1997, [Online] Disponível em http://www.enseiht.fr/lima/Vision/Publi/97_norsig_RF++.pdf, acessado em 24.fev.05. 3.5

- [59] R. Fjortoft, P. Marthon, A. Lopès e E. Cubero-Castan, “Edge detection in radar images using recursive filters,” *Asian Conference on Computer Vision ACCV’95*, Vol. III, pp. 87–91, Dezembro 1995, Singapura. 3.6, 3.6.3
- [60] A. Baraldi e F. Parmiggiani, “Segmentation driven by an iterative pairwise mutually best merge criterion,” In *International Geoscience and Remote Sensing Symposium IGARSS’95*, Vol. 01, Firenze, Itália, 10–14 Julho 1995, pp. 89–92. 3.6.5
- [61] B. J. Mealy, “Fast multiphase region count reduction for partitioned images,” Universidade da Califórnia (Santa Cruz) - Dept. de Eng. Computação, Santa Cruz, Califórnia, Relatório Técnico UCSC-CRL-02-40, 12 Dezembro 2002, [Online] Disponível em www.soe.ucsc.edu/research/reports/ucsc-crl-02-40.ps.Z, acessado em 11.mai.05 (20 páginas). 3.6.5
- [62] M. Fisz, *Probability theory and mathematical statistics*, 3ª edição. Nova York: John Wiley & Sons, 1963. 3.6.6, 3.6.6, 3.6.6
- [63] L. M. Delves, R. Wilkinson, C. J. Oliver e R. G. White, “Comparing the performance of SAR image segmentation algorithms,” *International Journal of Remote Sensing*, Vol. 13, No. 11, pp. 2121–2149, 1992. 4.2, 4.2.1, 4.2.1, 4.2.2
- [64] Y. J. Zhang, “A survey on evaluation methods for image segmentation,” *Pattern Recognition*, Vol. 29, No. 08, pp. 1335–1346, Agosto 1996. 4.2, 4.2.1, 4.2.2
- [65] W. A. Yasnoff, J. K. Mui e W. Bacus, “Error measurements for scene segmentation,” *Pattern Recognition*, Vol. 09, pp. 217–231, 1977. 4.2.2
- [66] R. A. I. Peters e R. N. Strickland, “Image complexity metrics for automated target recognizers,” *1990 Automated Target Recognizer System and Technology Conference*, pp. 1–17, 30-31 Outubro 1990, Naval Surface Warfare Center, Silver Spring. 4.2.2
- [67] Z. Bai e P. He, “An improved ratio edge detector for target detection in SAR images,” *Proceedings of the 2003 International Conference on Neural Networks and Signal Processing*, Vol. 2, pp. 982–985, 14–17 Dezembro 2003, Nanjing, China. 4.4.1
- [68] R. Caves, P. J. Harley e S. Quegan, “Edge structure in ERS-1 and airborne SAR data,” *International Geoscience and Remote Sensing Symposium IGARSS’92*, Vol. 02, pp. 1117–1119, 1992, Houston, Texas. 4.4.1
- [69] R. Touzi, A. Lopès e P. Bousquet, “A statistical and geometrical edge detector for SAR images,” *IEEE Trans. on Geoscience and Remote Sensing*, Vol. 26, No. 06, pp. 764–773, Novembro 1988. 4.4.1
- [70] A. Hendry, S. Quegan, A. J. Rye, J. Skingley e P. Churchill, “Application of image processing techniques to SAR 580 data,” Marconi Research Centre, Relatório Técnico MTR 84/59 08, Agosto 1985. 4.5
- [71] F. Tupin, H. Maître, J. F. Mangin, J. M. Nicolas e E. Pechersky, “Detection of linear features in SAR images: application to road network extraction,” *IEEE Trans. on Geoscience and Remote Sensing*, Vol. 36, No. 02, pp. 434–453, Março 1998. 4.5
- [72] B. Efron, “Bootstrap methods: Another look at the jackknife,” *The Annals of Statistics*, Vol. 07, pp. 1–26, 1979. 1
- [73] A. M. Zoubir e B. Boashash, “The bootstrap and its application in signal processing,” *IEEE Signal Processing Magazine*, Vol. 15, No. 01, pp. 56–76, 1998. 1

Apêndice A

Parâmetros das Imagens Simuladas e Medidas de Segmentação

A.1 Parâmetros Descritivos das Imagens Simuladas *kk* e *imgcartoon*

Tabela A.1: Parâmetros de simulação da imagem *kk*, amplitude, $n = 1$ visada.

Região	Tipo	Distribuição	μ	α	γ
1	Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	226	-5,0	$2,7686 \times 10^5$
2	Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	28	-5,0	$4,2497 \times 10^3$
3	+Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	149	-1,5	$2,2201 \times 10^4$
4	+Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	76	-1,5	$5,7760 \times 10^3$

Tabela A.2: Parâmetros de simulação da imagem *kk*, amplitude, $n = 3$ visadas.

Região	Tipo	Distribuição	μ	α	γ
1	Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	226	-5,0	$2,7686 \times 10^5$
2	Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	28	-5,0	$3,6264 \times 10^3$
3	+Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	149	-1,5	$1,8945 \times 10^4$
4	+Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	76	-1,5	$4,9289 \times 10^3$

Tabela A.3: Parâmetros de simulação da imagem *kk*, amplitude, $n = 5$ visadas.

Região	Tipo	Distribuição	μ	α	γ
1	Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	226	-5,0	$2,2858 \times 10^5$
2	Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	28	-5,0	$3,5086 \times 10^3$
3	+Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	149	-1,5	$1,8329 \times 10^4$
4	+Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	76	-1,5	$4,7687 \times 10^3$

Tabela A.4: Parâmetros de simulação da imagem *imgcartoon*, amplitude, $n = 1$ visada.

Região	Tipo	Distribuição	μ	α	β	γ
1	+Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	255	-4,0		$2,6986 \times 10^5$
2	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	45		$2,578 \times 10^3$	
3	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	92		$1,078 \times 10^4$	
4	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	160		$3,259 \times 10^4$	
5	Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	128	-10,0		$1,9303 \times 10^5$
6	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	128		$2,086 \times 10^4$	
7	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	208		$5,509 \times 10^4$	
8	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	160		$3,259 \times 10^4$	
9	Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	208	-7,0		$3,4456 \times 10^5$
10	Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	255			$7,6611 \times 10^5$
11	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	20		$5,093 \times 10^2$	
12	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	82		$8,561 \times 10^3$	
13	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	87		$9,637 \times 10^3$	
14	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	92		$1,078 \times 10^4$	
15	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	160		$3,259 \times 10^4$	
16	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	32		$1,304 \times 10^3$	
17	+Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	240	-3,0		$1,6600 \times 10^5$
18	Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	118	-7,0		$1,1089 \times 10^5$
19	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	32		$1,304 \times 10^3$	
20	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	208		$5,509 \times 10^4$	
21	+Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	255	-2,0		$1,0541 \times 10^5$
22	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	128		$2,086 \times 10^4$	
23	Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	160	-13,0		$3,9937 \times 10^5$

Tabela A.5: Parâmetros de simulação da imagem *imgcartoon*, amplitude, $n = 3$ visadas.

Região	Tipo	Distribuição	μ	α	β	γ
1	+Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	255	-4,0		$2,3028 \times 10^5$
2	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	45		$2,200 \times 10^3$	
3	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	92		$9,196 \times 10^3$	
4	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	160		$2,781 \times 10^4$	
5	Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	128	-10,0		$1,6472 \times 10^5$
6	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	128		$1,780 \times 10^4$	
7	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	208		$4,701 \times 10^4$	
8	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	160		$2,781 \times 10^4$	
9	Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	208	-7,0		$2,9402 \times 10^5$
10	Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	255	-10,0		$6,5375 \times 10^5$
11	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	20		$4,346 \times 10^2$	
12	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	82		$7,306 \times 10^3$	
13	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	87		$8,224 \times 10^3$	
14	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	92		$9,196 \times 10^3$	
15	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	160		$2,781 \times 10^4$	
16	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	32		$1,113 \times 10^3$	
17	+Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	240	-3,0		$1,4166 \times 10^5$
18	Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	118	-7,0		$9,4628 \times 10^4$
19	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	32		$1,113 \times 10^3$	
20	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	208		$4,701 \times 10^4$	
21	+Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	255	-2,0		$8,9954 \times 10^4$
22	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	128		$1,780 \times 10^4$	
23	Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	160	-13,0		$3,4080 \times 10^5$

Tabela A.6: Parâmetros de simulação da imagem *imgcartoon*, amplitude, $n = 5$ visadas.

Região	Tipo	Distribuição	μ	α	β	γ
1	+Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	255	-4,0		$2,280 \times 10^5$
2	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	45		$2,129 \times 10^3$	
3	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	92		$8,897 \times 10^3$	
4	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	160		$2,691 \times 10^4$	
5	Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	128	-10,0		$1,5937 \times 10^5$
6	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	128		$1,722 \times 10^4$	
7	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	208		$4,548 \times 10^4$	
8	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	160		$2,691 \times 10^4$	
9	Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	208	-7,0		$2,8447 \times 10^5$
10	Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	255	-10,0		$6,3250 \times 10^5$
11	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	20		$4,205 \times 10^2$	
12	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	82		$7,068 \times 10^3$	
13	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	87		$7,956 \times 10^3$	
14	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	92		$8,897 \times 10^3$	
15	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	160		$2,691 \times 10^4$	
16	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	32		$1,076 \times 10^3$	
17	+Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	240	-3,0		$1,3705 \times 10^5$
18	Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	118	-7,0		$9,1552 \times 10^4$
19	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	32		$1,076 \times 10^3$	
20	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	208		$4,548 \times 10^4$	
21	+Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	255	-2,0		$8,7030 \times 10^4$
22	Homogênea	$\Gamma^{1/2}(n, n\beta^{-1})$	128		$1,722 \times 10^4$	
23	Heterogênea	$\mathcal{G}_A^0(\alpha, \gamma, n)$	160	-13,0		$3,2972 \times 10^5$

A.2 Medidas de Discrepância para as Segmentações de *kk* e *imgcartoon*

Esta seção contém as medidas de micro e de macroajuste relativas às imagens *kk* e *imgcartoon*. A legenda abaixo deve ser observada para a interpretação das tabelas seguintes.

Legenda	Descrição
A	Rótulo da segmentação ideal (região de referência)
B	Medida <i>Ajbrd</i> (ajuste de bordas)
C	Perímetro da região de referência
D	Medida <i>Ajbrd</i> (ajuste de bordas)
E	Quantidade de pixels mal segmentados em relação à região de referência
F	Medida <i>Ajpm</i> s (ajuste de pixels mal segmentados - representada por <i>PMS</i>)
G	Medida <i>RUMA</i> (<i>relative ultimate measurement accuracy</i>)
H	Medida <i>Fitzy</i> (ajuste de posição – centro de gravidade)
I	Medida <i>Fiti</i> (ajuste de intensidade)
J	Medida <i>Fitn</i> (ajuste de tamanho)
L	Medida <i>Gforma</i> (ajuste de forma)
<i>Totgof</i>	Medida de ajuste geral (consiste do valor imediatamente à direita)
<i>kkn</i>	Imagem de teste <i>kk</i> com <i>n</i> visadas
<i>imgcn</i>	Imagem de teste <i>imgcartoon</i> com <i>n</i> visadas

A.2.1 Medidas de discrepância com $p_0 = 10^{-3}$

Tabela A.7: Medidas de segmentação de *kk* para $n = 1, 3$ e 5 visadas e $p_0 = 10^{-3}$.

	A	B	C	D	E	F	G	H	I	J	L
<i>kk1</i>	1	44068	679	0,97910	186	0,96647	0,99970	0,99375	0,99919	0,99985	0,96377
	2	44058	679	0,98089	90	0,98318	0,98670	0,99625	0,99526	0,99331	0,96898
	3	44066	679	0,94954	432	0,91994	0,98800	0,99500	0,99625	0,99396	0,90567
	4	44071	679	0,78465	294	0,94471	0,87470	0,99250	0,99871	0,93316	0,82116
										<i>Totgof</i>	
<i>kk3</i>	1	45079	679	0,98800	96	0,98073	0,99330	0,99500	0,99924	0,99664	0,97435
	2	45100	679	0,98836	25	0,99187	0,98030	0,99750	0,99809	0,99005	0,97536
	3	45105	679	0,96449	224	0,95904	0,96190	0,99125	0,99362	0,98058	0,91892
	4	45106	679	0,94560	258	0,94095	0,94850	0,99625	0,99991	0,97357	0,89949
										<i>Totgof</i>	
<i>kk5</i>	1	45932	679	0,98809	97	0,97965	0,98370	0,99625	0,99809	0,99178	0,96464
	2	45936	679	0,99213	11	0,99514	0,96370	0,99875	0,99300	0,98151	0,96154
	3	45944	679	0,95365	190	0,95991	0,95660	0,99500	0,99633	0,97782	0,92012
	4	45939	679	0,81834	154	0,96325	0,88730	0,99125	0,99738	0,94029	0,85868
										<i>Totgof</i>	

Tabela A.8: Medidas de segmentação de *imgcartoon*, $n = 1$ visada, $p_0 = 10^{-3}$.

	A	B	C	D	E	F	G	H	I	J	L
<i>imgc1</i>	1	109867	395	0,95268	98	0,94547	0,96986	0,99750	0,99875	0,98470	0,93907
	2	109865	256	0,96645	46	0,96749	0,99478	0,99932	0,99221	0,99738	0,95860
	3	109832	201	0,86145	120	0,84425	0,95775	0,98932	0,98346	0,97842	0,86504
	4	109866	318	0,65879	572	0,66189	0,75156	0,97093	0,98389	0,85816	0,52529
	5	109836	437	0,30536	58	0,97336	0,51831	0,91233	0,99867	0,68275	0,51053
	6	109861	632	0,92781	775	0,85552	0,96647	0,99477	0,98521	0,98351	0,88299
	7	109842	465	0,85821	426	0,85685	0,96259	0,98205	0,99861	0,98094	0,82833
	8	109845	218	0,82417	22	0,97321	0,87008	0,99591	0,99694	0,93053	0,85732
	9	109858	270	0,87492	466	0,74789	0,89323	0,99591	0,97968	0,94932	0,78200
	10	109706	316	0,90147	53	0,95635	0,93153	0,99182	0,99980	0,96455	0,89744
	11	109839	301	0,98019	7	0,98862	0,98385	0,99773	0,99977	0,99186	0,97686
	12	109853	235	0,85366	148	0,84621	0,97819	0,99318	0,99285	0,98898	0,80668
	13	109849	317	0,92206	371	0,77493	0,93180	0,99069	0,98336	0,96702	0,90223
	14	109855	311	0,93274	125	0,93464	0,97377	0,99773	0,99913	0,98671	0,90859
	15	109872	657	0,84733	637	0,86802	0,96562	0,98728	0,98958	0,98251	0,85259
	16	109864	329	0,97305	33	0,97738	0,94402	0,99932	0,99594	0,99700	0,97901
	17	109863	369	0,71806	91	0,93898	0,88326	0,97227	0,99613	0,93801	0,85917
	18	109851	267	0,86020	121	0,91079	0,92222	0,99387	0,99664	0,95954	0,84232
	19	109871	351	0,97411	39	0,97546	0,98737	0,99909	0,99850	0,99364	0,96836
	20	109857	156	0,65081	1109	0,29184	0,18084	0,97205	0,97956	0,70943	0,52403
	21	109869	347	0,86187	41	0,96879	0,79633	0,99432	0,99250	0,88662	0,77915
	22	109868	250	0,84765	232	0,83372	0,97486	0,99682	0,98365	0,98727	0,82096
	23	109840	313	0,87534	382	0,80948	0,86965	0,99727	0,99637	0,93881	0,80870
										Totgof	0,86311

Tabela A.9: Medidas de segmentação de *imgcartoon*, $n = 3$ visadas, $p_0 = 10^{-3}$.

	A	B	C	D	E	F	G	H	I	J	L
<i>imgc3</i>	1	110121	395	0,97732	3	0,99563	0,98509	1,00000	0,99966	0,99249	0,98413
	2	110123	256	0,98842	7	0,98370	0,97751	0,99796	0,99635	0,98863	0,97197
	3	109878	201	0,92640	45	0,95306	0,98467	0,99682	0,99748	0,99228	0,94835
	4	110070	318	0,91716	224	0,90096	0,99741	0,99500	0,99563	0,99870	0,89265
	5	110111	437	0,83759	40	0,97922	0,89687	0,99727	0,99898	0,94563	0,89015
	6	110086	632	0,95070	143	0,94678	0,99020	1,00000	0,99815	0,99508	0,96127
	7	110097	465	0,58228	981	0,59800	0,90088	0,93798	0,99267	0,94786	0,65592
	8	109929	218	0,85864	83	0,90689	0,99344	0,99659	0,99839	0,99671	0,94307
	9	110100	270	0,98078	20	0,97980	0,98749	0,99932	0,99605	0,99370	0,97206
	10	110073	316	0,98353	10	0,98789	0,99695	1,00000	0,99998	0,99847	0,99020
	11	110104	301	0,99532	0	1,00000	0,99899	1,00000	0,99999	0,99949	0,99899
	12	109978	235	0,97285	31	0,96783	0,99743	0,99750	0,99677	0,99872	0,96352
	13	110093	317	0,97776	37	0,97840	0,99929	0,99864	0,99805	0,99965	0,98205
	14	110119	311	0,96360	39	0,96450	0,99071	0,99841	0,99964	0,99533	0,96972
	15	110036	657	0,97605	191	0,96470	0,99205	0,99909	0,99705	0,99604	0,97188
	16	110118	329	0,99325	0	1,00000	0,99885	1,00000	0,99986	0,99943	0,99885
	17	110117	369	0,97164	60	0,97152	0,96626	1,00000	0,99983	0,98284	0,94960
	18	110124	267	0,96720	32	0,96941	0,98602	0,99750	0,99840	0,99296	0,96350
	19	110092	351	0,98945	2	0,99509	0,99307	1,00000	0,99966	0,9652	0,99208
	20	110089	156	0,91246	70	0,89992	0,99387	0,99614	0,99554	0,99693	0,89236
	21	110120	347	0,96112	6	0,99243	0,92960	0,99841	0,99789	0,96651	0,92688
	22	110013	250	0,97094	44	0,96853	0,99053	0,99909	0,99665	0,99529	0,97777
	23	110087	313	0,97011	49	0,96687	0,98417	0,99909	0,99411	0,99202	0,93992
										Totgof	0,95284

Tabela A.10: Medidas de segmentação de *imgcartoon*, $n = 5$ visadas, $p_0 = 10^{-3}$.

	A	B	C	D	E	F	G	H	I	J	L
<i>imgc5</i>	1	110121	395	0,98312	0	1,00000	0,94329	1,00000	0,99859	0,97082	0,94329
	2	110123	256	0,98665	7	0,98907	0,99839	1,00000	0,99207	0,99920	0,99600
	3	109878	201	0,96635	43	0,94791	0,99917	0,99750	0,99693	0,99959	0,96581
	4	110070	318	0,94917	146	0,93388	0,98185	0,99659	0,99685	0,99084	0,90955
	5	110111	437	0,96056	64	0,97145	0,97573	1,00000	0,99982	0,98772	0,96455
	6	110086	632	0,97871	66	0,98269	0,99773	0,99864	0,99939	0,99886	0,98422
	7	110097	465	0,96335	101	0,95911	0,98793	0,99841	0,99989	0,99393	0,95391
	8	109929	218	0,95989	50	0,94887	0,98720	0,99796	0,99868	0,99356	0,95664
	9	110100	270	0,99030	3	0,99363	0,97849	1,00000	0,99988	0,98913	0,97617
	10	110073	316	0,98789	1	0,99685	0,98610	0,99932	0,99771	0,99300	0,98543
	11	110104	301	1,00000	0	1,00000	1,00000	1,00000	1,00000	1,00000	1,00000
	12	109978	235	0,97379	4	0,99156	0,98332	0,99864	0,99868	0,99159	0,97825
	13	110093	317	0,97883	17	0,98575	0,98848	0,99932	0,99869	0,99420	0,98056
	14	110119	311	0,97755	20	0,97983	0,99699	0,99909	0,99961	0,99850	0,98614
	15	110036	657	0,98262	82	0,98194	0,99971	0,99841	0,99905	0,99986	0,98470
	16	110118	329	0,99697	0	1,00000	0,99494	1,00000	0,99949	0,99747	0,99494
	17	110117	369	0,97692	18	0,98336	0,94675	1,00000	0,99973	0,97265	0,94178
	18	110124	267	0,97158	51	0,96407	0,99857	0,99932	0,99838	0,99928	0,96551
	19	110092	351	0,99201	3	0,99509	0,99430	1,00000	0,99783	0,99714	0,99282
	20	110089	156	0,94119	51	0,92587	0,98391	0,99909	0,99915	0,99202	0,94027
	21	110120	347	0,97472	8	0,98933	0,94938	0,99841	0,99998	0,97403	0,94571
	22	110013	250	0,98425	12	0,98633	1,00000	0,99909	0,99829	1,00000	0,99129
	23	110087	313	0,98171	33	0,97415	0,98929	0,99818	0,99984	0,99467	0,98028
									Totgof	0,97657	

A.2.2 Medidas de discrepância com $p_0 = 10^{-5}$

Tabela A.11: Medidas de segmentação de *kk* para $n = 1, 3$ e 5 visadas e $p_0 = 10^{-5}$.

	A	B	C	D	E	F	G	H	I	J	L
<i>kk1</i>	1	44108	679	0,97578	197	0,96513	0,9948	0,99375	0,99711	0,99741	0,96646
	2	44113	679	0,98534	101	0,98182	0,9973	0,99625	0,99123	0,99865	0,98267
	3	44117	679	0,93295	577	0,89926	0,9807	0,99500	0,99113	0,99044	0,90914
	4	44115	679	0,92861	419	0,93075	0,9719	0,99500	0,99022	0,98575	0,89260
									Totgof	0,96742	
<i>kk3</i>	1	45213	679	0,98939	107	0,97940	0,9912	0,99500	0,99808	0,99562	0,98753
	2	45202	679	0,99414	28	0,99112	0,9985	0,99750	0,99865	0,99925	0,99591
	3	45219	679	0,96368	315	0,93914	0,9983	0,99625	0,99490	0,99915	0,94057
	4	45218	679	0,96052	250	0,94082	0,9836	0,99625	0,99707	0,99173	0,93522
									Totgof	0,98140	
<i>kk5</i>	1	46048	679	0,98757	112	0,97711	0,9916	0,99625	0,99726	0,99582	0,98616
	2	45911	679	0,99433	19	0,98881	0,9996	0,99875	0,99311	0,99980	0,99661
	3	46047	679	0,89602	227	0,95006	0,9716	0,99875	0,99457	0,98560	0,92784
	4	46049	679	0,89523	274	0,94912	0,9702	0,99125	0,99563	0,98487	0,91766
									Totgof	0,97185	

Tabela A.12: Medidas de segmentação de *imgcartoon*, $n = 1$ visada, $p_0 = 10^{-5}$.

	A	B	C	D	E	F	G	H	I	J	L
<i>imgc1</i>	1	109935	395	0,93412	97	0,94367	0,96484	0,99750	0,99899	0,98211	0,93444
	2	109940	256	0,96604	66	0,95292	0,98675	0,99932	0,98193	0,99342	0,96127
	3	109895	201	0,79291	159	0,78772	0,92916	0,98932	0,97340	0,96328	0,80995
	4	109915	318	0,63341	347	0,77243	0,64108	0,98115	0,99282	0,78129	0,50559
	5	109880	437	0,65616	933	0,52789	0,90212	0,99296	0,98964	0,94854	0,75642
	6	109875	632	0,88430	1010	0,80622	0,94749	0,98592	0,98311	0,97442	0,85884
	7	109924	465	0,84608	490	0,82479	0,94329	0,98024	0,99976	0,97082	0,79192
	8	109937	218	0,79107	1907	0,19596	0,47377	0,96228	0,95796	0,79169	0,58328
	9	109937	270	0,63569	3244	0,14897	0,08878	0,95389	0,90811	0,68700	0,28323
	10	109889	316	0,89952	47	0,95799	0,92305	0,99318	0,99921	0,95999	0,89289
	11	109921	301	0,96350	19	0,97617	0,98132	0,99682	0,98836	0,99057	0,96250
	12	109933	235	0,81533	288	0,77843	0,97434	0,98978	0,95466	0,98733	0,70980
	13	109909	317	0,84427	879	0,51254	0,80668	0,98069	0,96159	0,91186	0,81758
	14	109910	311	0,92196	243	0,83481	0,99645	0,99500	0,98630	0,99822	0,87215
	15	109938	657	0,83308	908	0,81998	0,99818	0,98728	0,98837	0,99909	0,83831
	16	109939	329	0,97337	53	0,93403	0,99908	0,99932	0,99247	0,99954	0,97502
	17	109931	369	0,69444	82	0,93898	0,86902	0,97023	0,99905	0,92992	0,84745
	18	109923	267	0,71791	161	0,87896	0,80645	0,98297	0,98547	0,89286	0,70790
	19	109943	351	0,97099	62	0,95790	0,99851	0,99682	0,99371	0,99926	0,96829
	20	109934	156	0,61134	1186	0,26469	0,10575	0,96796	0,97683	0,69102	0,51626
	21	109942	347	0,83076	30	0,97629	0,76595	0,99614	0,99686	0,86747	0,75357
	22	109941	250	0,46753	1324	0,43631	0,53042	0,99455	0,95965	0,80985	0,66601
	23	109941	313	0,44805	2871	0,22186	0,12197	0,94549	0,96931	0,68221	0,42420
									Totgof		0,87318

Tabela A.13: Medidas de segmentação de *imgcartoon*, $n = 3$ visadas, $p_0 = 10^{-5}$.

	A	B	C	D	E	F	G	H	I	J	L
<i>imgc3</i>	1	110193	395	0,99062	3	0,99563	0,99870	1,00000	0,99980	0,99935	0,99773
	2	110027	256	0,98977	5	0,98462	0,99960	0,99796	0,99971	0,99980	0,99559
	3	110008	201	0,92640	45	0,95306	0,98467	0,99682	0,99748	0,99228	0,94835
	4	110092	318	0,89799	284	0,84426	0,99922	0,99432	0,99280	0,99961	0,86208
	5	110170	437	0,74210	27	0,98722	0,85926	0,99727	0,99901	0,92431	0,85841
	6	110175	632	0,94506	199	0,93245	0,99773	0,99796	0,99883	0,99887	0,96199
	7	110172	465	0,83412	1755	0,43584	0,72194	0,97228	0,99744	0,87794	0,74894
	8	110042	218	0,85836	91	0,90522	0,99938	0,99659	0,99925	0,99969	0,94412
	9	110171	270	0,97550	14	0,98453	0,99296	0,99932	0,99998	0,99647	0,98211
	10	110165	316	0,98269	10	0,98789	0,99627	1,00000	0,99990	0,99813	0,98953
	11	110187	301	0,99532	0	1,00000	0,99899	1,00000	0,99999	0,99949	0,99899
	12	110086	235	0,97316	27	0,97023	0,99743	0,99932	0,99602	0,99872	0,96847
	13	110179	317	0,97776	37	0,97840	0,99788	0,99864	0,99863	0,99894	0,98484
	14	110195	311	0,96163	51	0,95864	0,99590	0,99841	0,99863	0,99795	0,96847
	15	110173	657	0,96947	220	0,95948	0,98860	0,99636	0,99532	0,99433	0,96989
	16	110194	329	0,99325	0	1,00000	0,99885	1,00000	0,99986	0,99943	0,99885
	17	110188	369	0,97311	60	0,97152	0,99943	1,00000	0,99989	0,99972	0,98250
	18	110197	267	0,96720	32	0,96941	0,99032	0,99750	0,99925	0,99514	0,96775
	19	110178	351	0,98945	2	0,99509	0,99728	1,00000	0,99971	0,99864	0,99629
	20	110026	156	0,88536	101	0,87035	0,98008	0,99546	0,99523	0,99014	0,87482
	21	110196	347	0,95991	18	0,98232	0,96704	0,99841	0,99823	0,98324	0,95873
	22	110119	250	0,96484	67	0,95512	0,98142	0,99909	0,98958	0,99080	0,97048
	23	110176	313	0,97155	55	0,96283	0,98929	0,99909	0,99418	0,99467	0,96051
									Totgof		0,96925

Tabela A.14: Medidas de segmentação de *imgcartoon*, $n = 5$ visadas, $p_0 = 10^{-5}$.

	A	B	C	D	E	F	G	H	I	J	L
<i>imgc3</i>	1	110420	395	0,99335	0	1,00000	0,99060	1,00000	0,99902	0,99528	0,99060
	2	110425	256	0,98665	7	0,98907	0,99839	1,00000	0,99207	0,99920	0,99600
	3	110157	201	0,95896	70	0,90638	0,98053	0,99750	0,99631	0,99036	0,96256
	4	110305	318	0,79745	111	0,94083	0,89704	0,99114	0,99622	0,94573	0,84396
	5	110402	437	0,96306	92	0,96542	0,99804	0,99727	0,99966	0,99902	0,98183
	6	110408	632	0,97218	117	0,95603	0,99711	0,99864	0,99817	0,99856	0,97900
	7	110359	465	0,88440	134	0,90111	0,96828	0,98955	0,99930	0,98389	0,92384
	8	110335	218	0,93823	39	0,96434	0,98938	1,00000	0,99967	0,99466	0,96544
	9	110401	270	0,99101	1	0,99631	0,99101	1,00000	0,99852	0,99548	0,99023
	10	110405	316	0,99060	1	0,99685	0,99797	0,99932	0,99981	0,99898	0,99729
	11	110406	301	1,00000	0	1,00000	1,00000	1,00000	1,00000	1,00000	1,00000
	12	109271	235	0,97285	19	0,95289	0,99294	0,99864	0,99644	0,99646	0,96895
	13	110322	317	0,97861	20	0,98387	0,99788	0,99932	0,99976	0,99894	0,98853
	14	110007	311	0,97755	20	0,97983	0,99699	0,99909	0,99961	0,99850	0,98614
	15	110369	657	0,97945	87	0,98134	0,99990	0,99841	0,99921	0,99995	0,98357
	16	110403	329	0,99697	0	1,00000	0,99977	1,00000	0,99998	0,99989	0,99977
	17	110423	369	0,97094	18	0,98336	0,99089	1,00000	0,99979	0,99542	0,98580
	18	110418	267	0,96270	68	0,95463	0,98280	0,99932	0,99372	0,99147	0,96921
	19	110258	351	0,99201	3	0,99509	0,99926	1,00000	0,99799	0,99963	0,99777
	20	109604	156	0,93363	74	0,88763	0,96552	0,99909	0,99734	0,98305	0,92531
	21	110426	347	0,96725	5	0,99097	0,97951	0,99841	0,99721	0,98965	0,97719
	22	110421	250	0,98425	12	0,98633	0,99745	0,99909	0,99867	0,99873	0,99383
	23	110370	313	0,97791	64	0,94051	0,97346	0,99636	0,99555	0,98691	0,96790
										<i>Totgof</i>	0,98380

A.2.3 Medidas de discrepância com $p_0 = 10^{-6}$ Tabela A.15: Medidas de segmentação de *kk* para $n = 1, 3$ e 5 visadas e $p_0 = 10^{-6}$.

	A	B	C	D	E	F	G	H	I	J	L
<i>kk1</i>	1	44110	679	0,97578	197	0,96513	0,99480	0,99375	0,99711	0,99741	0,96646
	2	44115	679	0,98534	101	0,98182	0,99730	0,99625	0,99123	0,99865	0,98267
	3	44118	679	0,91951	618	0,89504	0,97690	0,99500	0,98919	0,98858	0,90535
	4	44116	679	0,91620	431	0,93005	0,96900	0,99500	0,98840	0,98426	0,88764
										<i>Totgof</i>	0,96630
<i>kk3</i>	1	45213	679	0,98809	121	0,97702	0,98980	0,99500	0,99767	0,99493	0,98617
	2	45204	679	0,99414	43	0,97330	0,99700	0,99750	0,99586	0,99850	0,99442
	3	45220	679	0,96239	313	0,93911	0,99640	0,99625	0,99454	0,99820	0,93581
	4	45219	679	0,95925	286	0,93512	0,98680	0,99625	0,99484	0,99336	0,93156
										<i>Totgof</i>	0,98003
<i>kk3</i>	1	46052	679	0,98757	112	0,97711	0,98990	0,99625	0,99761	0,99498	0,98784
	2	45917	679	0,99433	19	0,98881	0,99960	0,99875	0,99311	0,99980	0,99661
	3	46051	679	0,89526	216	0,95353	0,96670	0,99875	0,99371	0,98307	0,92512
	4	46054	679	0,89480	312	0,94029	0,97510	0,99250	0,99171	0,98739	0,91534
										<i>Totgof</i>	0,97160

Tabela A.16: Medidas de segmentação de *imgcartoon*, 1 visada, $p_0 = 10^{-6}$.

	A	B	C	D	E	F	G	H	I	J	L
<i>imgc1</i>	1	109941	395	0,93341	92	0,94410	0,96063	0,99750	0,99980	0,97992	0,93183
	2	109947	256	0,96465	87	0,94096	0,97631	0,99932	0,96957	0,98829	0,95537
	3	109903	201	0,78591	185	0,78156	0,92254	0,98932	0,96296	0,95971	0,78569
	4	109922	318	0,63269	312	0,79902	0,63071	0,98388	0,99513	0,77354	0,50864
	5	109907	437	0,74234	2544	0,36356	0,85206	0,97114	0,97570	0,93113	0,75174
	6	109889	632	0,87944	1063	0,80389	0,93542	0,98592	0,98190	0,96872	0,86056
	7	109930	465	0,84548	451	0,83008	0,93087	0,98487	0,99839	0,96420	0,79159
	8	109943	218	0,63998	1882	0,19617	0,48095	0,96160	0,95404	0,79395	0,58655
	9	109943	270	0,58765	3197	0,15105	0,09777	0,95457	0,91200	0,68913	0,28971
	10	109898	316	0,89952	47	0,95799	0,92305	0,99318	0,99921	0,95999	0,89289
	11	109928	301	0,96350	19	0,97617	0,98132	0,99682	0,98836	0,99057	0,96250
	12	109836	235	0,75579	712	0,47045	0,69981	0,97796	0,90900	0,86949	0,57904
	13	109933	317	0,83935	895	0,51237	0,80527	0,97865	0,95986	0,91127	0,81310
	14	109917	311	0,92124	267	0,82558	0,99699	0,99500	0,98822	0,99850	0,86682
	15	109944	657	0,83256	1069	0,75249	0,98640	0,98637	0,98503	0,99325	0,82659
	16	109946	329	0,97337	53	0,93403	0,99908	0,99932	0,99247	0,9954	0,97502
	17	109948	369	0,79014	4851	0,08645	0,40746	0,91934	0,99891	0,77144	0,53347
	18	109929	267	0,71747	257	0,78193	0,84695	0,97752	0,96205	0,91714	0,69117
	19	109949	351	0,96672	62	0,95790	0,99257	0,99682	0,99439	0,99627	0,96244
	20	109948	156	0,58335	9905	0,01901	0,00000	0,83618	0,92848	0,20895	0,11427
	21	109948	347	0,74272	8004	0,03633	0,00000	0,83001	0,97047	0,55038	0,25973
	22	109945	250	0,46667	1597	0,41165	0,43097	0,99455	0,93618	0,77850	0,62414
	23	109945	313	0,45300	3143	0,21175	0,00000	0,94685	0,95257	0,71068	0,41127
										<i>Totgof</i>	0,88707

Tabela A.17: Medidas de segmentação de *imgcartoon*, 3 visadas, $p_0 = 10^{-6}$.

	A	B	C	D	E	F	G	H	I	J	L
<i>imgc3</i>	1	110193	395	0,98826	3	0,99563	0,99773	1,00000	0,99974	0,99886	0,99676
	2	110029	256	0,98977	5	0,98462	0,99960	0,99796	0,99971	0,99980	0,99559
	3	110010	201	0,92640	45	0,95306	0,98467	0,99682	0,99848	0,99228	0,94835
	4	110092	318	0,86915	555	0,72407	0,90638	0,99773	0,98204	0,95528	0,83020
	5	110169	437	0,74201	26	0,98742	0,85900	0,99727	0,99899	0,92415	0,85471
	6	110173	632	0,94341	219	0,93093	0,99546	0,99796	0,99850	0,99774	0,96025
	7	110158	465	0,92944	1479	0,53067	0,78211	0,97228	0,99583	0,90176	0,76901
	8	110046	218	0,95836	91	0,90522	0,99938	0,99659	0,99925	0,99969	0,94412
	9	110170	270	0,97550	14	0,98453	0,99296	0,99932	0,99998	0,99647	0,98211
	10	110164	316	0,97315	10	0,98789	0,99220	1,00000	0,99977	0,99609	0,98547
	11	110187	301	0,99532	0	1,00000	0,99899	1,00000	0,99999	0,99949	0,99899
	12	110086	235	0,97316	27	0,97023	0,99743	0,99932	0,99602	0,99872	0,96847
	13	110177	317	0,97776	37	0,97840	0,99788	0,99864	0,99863	0,99894	0,98484
	14	110195	311	0,95321	49	0,95887	0,99153	0,99841	0,99840	0,99575	0,96522
	15	110171	657	0,96865	224	0,95978	0,98822	0,99636	0,99496	0,99414	0,96953
	16	110194	329	0,99325	0	1,00000	0,99885	1,00000	0,99986	0,9943	0,99885
	17	110188	369	0,97311	60	0,97152	0,99943	1,00000	0,99989	0,99972	0,98250
	18	110197	267	0,96720	32	0,96941	0,99032	0,99750	0,99925	0,99514	0,96775
	19	110176	351	0,98945	2	0,99509	0,99728	1,00000	0,99971	0,99864	0,99629
	20	110028	156	0,87311	108	0,86747	0,98467	0,99364	0,99195	0,99240	0,86129
	21	110196	347	0,92145	16	0,98300	0,93925	0,99568	0,99987	0,96867	0,93127
	22	110118	250	0,96210	83	0,92892	0,97559	0,99909	0,98791	0,98794	0,96499
	23	110186	313	0,94899	159	0,83148	0,94088	0,99909	0,97659	0,97129	0,91721
									Totgof		0,96793

Tabela A.18: Medidas de segmentação de *imgcartoon*, 5 visadas, $p_0 = 10^{-6}$.

	A	B	C	D	E	F	G	H	I	J	L
<i>imgc5</i>	1	110424	395	0,99335	0	1,00000	0,99887	1,00000	0,9986	0,99943	0,99887
	2	110429	256	0,98665	7	0,98907	0,99839	1,00000	0,99207	0,99920	0,99600
	3	110165	201	0,95791	64	0,90708	0,99006	0,99750	0,99658	0,99505	0,95803
	4	110311	318	0,78376	99	0,94384	0,88719	0,98568	0,99658	0,94022	0,83995
	5	110408	437	0,96306	92	0,96542	0,99920	0,99727	0,99945	0,99960	0,98298
	6	110414	632	0,97097	145	0,95299	0,99329	0,99864	0,99810	0,99666	0,97713
	7	110366	465	0,88461	157	0,89692	0,97242	0,99092	0,99880	0,98602	0,92044
	8	110343	218	0,93823	39	0,96434	0,98938	1,00000	0,99967	0,99466	0,96544
	9	110407	270	0,99101	1	0,99631	0,99844	1,00000	0,99973	0,99922	0,99765
	10	110411	316	0,99060	1	0,99685	0,99797	0,99932	0,99981	0,99898	0,99729
	11	110412	301	1,00000	0	1,00000	1,00000	1,00000	1,00000	1,00000	1,00000
	12	109280	235	0,97285	19	0,95289	0,99294	0,99864	0,99644	0,99646	0,96895
	13	110329	317	0,97861	20	0,98387	0,99788	0,99932	0,99976	0,99894	0,98853
	14	110016	311	0,97755	20	0,97983	0,99699	0,99909	0,99961	0,99850	0,98614
	15	110376	657	0,97945	87	0,98134	0,99990	0,99841	0,99921	0,99995	0,98357
	16	110409	329	0,99697	0	1,00000	0,99977	1,00000	0,99998	0,99989	0,99977
	17	110427	369	0,96904	18	0,98336	0,99089	0,99818	0,99930	0,99542	0,98580
	18	110422	267	0,96270	68	0,95463	0,98280	0,99932	0,99372	0,99147	0,96921
	19	110262	351	0,99201	3	0,99509	0,99926	1,00000	0,99799	0,99963	0,99777
	20	109630	156	0,92857	82	0,88549	0,95939	0,99909	0,99888	0,98010	0,91997
	21	110430	347	0,95786	5	0,99097	0,97457	0,99659	0,99710	0,98712	0,97225
	22	110425	250	0,98425	12	0,98633	0,99745	0,99909	0,99867	0,99873	0,99383
	23	110377	313	0,97585	85	0,92425	0,96369	0,99636	0,99322	0,98217	0,95880
									Totgof		0,98409

© Documento tipografado em L^AT_EX 2_ε, usando a classe *report*, fonte *AvantGarde*, tamanho 12pt e espaçamento simples. Versão 1.1, impressa em 20 de julho de 2006.

