



MINISTÉRIO DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

INPE-14466-TDI/1147

SEGMENTAÇÃO MULTI-NÍVEIS E MULTI-MODELOS PARA IMAGENS DE RADAR E ÓPTICAS

Manoel de Araujo Sousa Junior

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Luciano Vieira Dutra e Corina da Costa Freitas, aprovada em 31 de março de 2005.

INPE
São José dos Campos
2007

Publicado por:

esta página é responsabilidade do SID

Instituto Nacional de Pesquisas Espaciais (INPE)

Gabinete do Diretor – (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 – CEP 12.245-970

São José dos Campos – SP – Brasil

Tel.: (012) 3945-6911

Fax: (012) 3945-6919

E-mail: pubtc@sid.inpe.br

**Solicita-se intercâmbio
We ask for exchange**

Publicação Externa – É permitida sua reprodução para interessados.



MINISTÉRIO DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

INPE-14466-TDI/1147

SEGMENTAÇÃO MULTI-NÍVEIS E MULTI-MODELOS PARA IMAGENS DE RADAR E ÓPTICAS

Manoel de Araujo Sousa Junior

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Luciano Vieira Dutra e Corina da Costa Freitas, aprovada em 31 de março de 2005.

INPE
São José dos Campos
2007

528.711.7:621.376.5

Sousa Jr., M. A.

Segmentação multi-níveis e multi-modelos para
imagens de radar e ópticas / Manoel de Araújo Sousa
Junior. - São José dos Campos: INPE, 2005.

131p. ; – (INPE-14466-TDI/1147)


1. Segmentação. 2. Radar. 3. Multi-nível 4. Imagens
ópticas. 5. Processamento de imagens. I. Título.

Aprovado (a) pela Banca Examinadora
em cumprimento ao requisito exigido para
obtenção do Título de Doutor em
Computação Aplicada


Dra. Leila Maria Garcia Fonseca


Presidente / INPE / São José dos Campos - SP

Dra. Corina da Costa Freitas


Orientador(a) / INPE / SJC Campos - SP


Dr. Luciano Vieira Dutra


Orientador(a) / INPE / SJC Campos - SP


Dr. Camilo Daleles Rennó


Membro da Banca / INPE / São José dos Campos - SP


Dr. Marco Antonio Chamon


Membro da Banca / INPE / São José dos Campos - SP

Dr. David Fernandes


Convidado(a) / ITA / SJC Campos - SP

Dr. Aylton Pagamisse


Convidado(a) / UNESP/PP / Presidente Prudente - SP

Aluno (a): Manoel de Araújo Sousa Júnior

São José dos Campos, 31 de março de 2005

A busca do novo, sem se importar a princípio se vai ser melhor ou pior do que o que já existe, é o objetivo mais nobre da pesquisa. Buscar no velho algo novo é tentar ver uma realidade que passa despercebida por todos aqueles que deixaram morrer a inquietude, essa virtude essencial à alma.

Manoel de Araújo Sousa Júnior
Agosto de 2002

A meus pais,
Elman e Carmélia.
A minha esposa
Silvia.

AGRADECIMENTOS

Aos orientadores Dra. Corina da Costa Freitas e Dr. Luciano Vieira Dutra pela amizade, paciência, persistência e principalmente confiança no trabalho desenvolvido, assim como pelas produtivas discussões sobre segmentação de imagens de radar. E confirmando o que eu pensei antes de iniciar esta tese, um filho sem mãe está sozinho no mundo, muitíssimo obrigado Corina.

Ao Instituto Nacional de Pesquisas Espaciais (INPE) pela oportunidade de estudo e utilização de suas instalações.

Aos docentes do Curso de Pós-Graduação em Computação Aplicada (CAP) que auxiliaram na formação de fundamentos para o desenvolvimento desta Tese.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa de estudo.

À Divisão de Processamento de Imagens (DPI), que me acolheu como um dos seus, dando todo o apoio necessário para o desenvolvimento deste trabalho.

Ao Dr. Camilo Daleles Rennó, antes de tudo um grande amigo, por ter sido um orientador na programação em IDL e pela cooperação em vários momentos deste trabalho.

Ao Sidnei João Siqueira Sant'Anna, por ter a paciência em esclarecer minhas dúvidas sobre os sistemas de radar, e pelas sugestões para que este trabalho ficasse melhor, e pela grande amizade.

A Nanci Naomi Arai e a Marcelo Banik de Pádua, por terem me apresentado e ajudado com o $\text{\LaTeX}$.

Aos amigos de curso, da DPI, do SERE, da *Senzala* e em especial a Guaracy José Ethal, João Benedito Diehl, Dr. João Roberto dos Santos, Dr. José Marinaldo Gleriani, Leonardo Sant'Anna Bins, Dr. Nelson Jesus Ferreira, Dra. Maycira Pereira da Costa, Maria Etelvina Renó, Dr. Sergio Donizete Farias e Terezinha Gomes, que de formas diferentes foram importantes durante o desenvolvimento deste trabalho.

À Silvia Pardi Lacruz por ser parte da minha vida, em todos os momentos, compreensiva em todas as horas, companheira em tantas outras, e sempre ao meu lado mesmo quando eu estava pensando na outra, a Tese.

RESUMO

Neste trabalho apresenta-se um novo segmentador para imagens de radar e ópticas, *SegSAR*. O segmentador *SegSAR* faz uso de técnicas de crescimento e agrupamento de regiões, detecção de bordas, teste de homogeneidade e teste de área mínima, integradas numa estrutura de compressão piramidal. Assim, o segmentador *SegSAR* apresenta-se como uma inovação no processo de segmentação por integrar técnicas tradicionais de segmentação, sendo um segmentador hierárquico, multi-nível e multi-modelo e trabalha com imagens em uma banda ou multi-bandas. Uma outra inovação deste segmentador é a possibilidade de se obter resultados intermediários nos diferentes níveis de compressão do processo de segmentação. O processamento das imagens de radar é feito em intensidade, no entanto as imagens de entrada podem ser em amplitude, intensidade ou *dB*. O segmentador trabalha com dois modelos para representar os dados das imagens: o primeiro é o modelo de manchas (*cartoon*) que é adequado para imagens com regiões homogêneas onde o *backscatter* é constante, e o segundo é o modelo de textura, o qual é mais indicado para imagens com regiões em que o *backscatter* não é constante. O modelo de manchas para imagens de radar faz uso das propriedades da distribuição Gama para segmentar as imagens, e usa como critério para determinar a homogeneidade de uma região o coeficiente de variação, o qual é obtido por simulação *Monte Carlo* sobre amostras com distribuição Gama para diferentes níveis de significância. O modelo de textura para imagens de radar usa como principal critério de segmentação, o coeficiente de variação das regiões, que é comparado com um coeficiente de variação crítico determinado pelo usuário. Para imagens ópticas, o modelo de manchas supõe que a variância é constante para toda a imagem, enquanto que o modelo de textura faz uso da variância das regiões no processo de segmentação. Em ambos os modelos, o teste de homogeneidade é calculado sobre um valor de coeficiente de variação. O *SegSAR* foi implementado na linguagem *IDL - Interactive Data Language* e faz uso de algumas ferramentas do *ENVI* para tornar a interface mais amigável. A avaliação do *SegSAR* foi realizada usando critérios qualitativos e quantitativos sobre conjuntos de imagens simuladas. Adicionalmente foram realizadas segmentações sobre imagens de radar na banda X e sobre imagens ópticas *Landsat7/ETM+* e *Landsat5/TM*, sendo estes resultados analisados qualitativamente. O modelo de manchas apresentou um bom desempenho tanto para imagens formadas por regiões homogêneas com para imagens com textura. Os modelos de manchas e de textura apresentaram um bom desempenho quando aplicados às imagens ópticas. O modelo de textura para imagens de radar apresentou um bom resultado para imagem real, o mesmo não ocorrendo para imagens simuladas.

DEVELOPMENT OF SYSTEM INCREMENTAL MULTI-LEVEL OF SEGMENTATION TO OPTICAL AND RADAR IMAGES

ABSTRACT

This research presents an innovative automatic segmentation method (*SegSAR*) designed for radar and optical satellite imagery. The design of *SegSAR* is innovative because it encompasses (i) several common segmentation techniques such as region growing and merging, edge detection, and minimum area and homogeneity test, which are integrated in a pyramidal compression structure; (ii) a hierarchical segmentation procedure; (iii) a multi-level segmentation procedure; (iv) a multi-model homogeneity test; (v) a single band or multi-bands of satellite imagery option; and (vi) the generation of intermediate results at each level of the segmentation process. The processing of radar imagery is performed in intensity values; however, options of input image are amplitude, intensity, and dB. *SegSAR* is designed to represent imagery in two different models, (i) the cartoon model that is suitable for homogeneous regions, i.e., constant backscattering, of the image; and (ii) the texture model that is suitable for heterogeneous regions, i.e., variable backscattering. For segmentation of radar imagery, the cartoon model assumes that the data for each region has a Gamma distribution, and uses the coefficient of variation to determine the homogeneity degree of a region. Gamma distributed samples are used to obtain the critical coefficients of variation, at different levels of significance, through Monte Carlo simulation. Differently, the texture model uses only a comparison between a coefficient of variation of a region and a user defined coefficient of variation. For segmentation of optical imagery, the cartoon model assumes that the variability of digital number is constant over the entire image. Conversely, the texture model uses the variability among regions to segment the image. A used defined coefficient of variance is used to define the homogeneity degree for both models. *SegSAR* was implemented in IDL (Interactive Data Language), and uses ENVI tools to make the interface user friendly. The performance of *SegSAR* over radar imagery was conducted using quantitative and qualitative criteria over simulated data and qualitative criteria over airborne band X image. The performance over optical data was conducted using qualitative criteria over Landsat 7/ETM+ and Landsat 5/TM imagery. Both, the cartoon and the texture models, showed good results for both the radar and optical imagery, except for the not satisfactory results obtained when the texture model was applied over simulated radar imagery.

SUMÁRIO

Pág.

LISTA DE FIGURAS

LISTA DE TABELAS

CAPÍTULO 1	INTRODUÇÃO	21
CAPÍTULO 2	ESTATÍSTICA DE IMAGENS	23
2.1	Imagens Ópticas	23
2.2	Radares de Abertura Sintética - <i>SAR</i>	23
2.2.1	Imageamento <i>SAR</i>	25
2.2.2	Propriedades Estatísticas da Imagem <i>SAR</i>	28
CAPÍTULO 3	SEGMENTAÇÃO DE IMAGENS	37
3.1	Modelos de Representação dos Dados	38
3.2	Representação de Imagens	39
3.2.1	Representação por Matriz	39
3.2.2	Representação Hierárquica	40
3.2.3	Representação Simbólica	43
3.3	Técnicas de Segmentação de Imagens	43
3.3.1	Ajuste de Regiões	43
3.3.2	Crescimento de Regiões	43
3.3.3	Detecção de Bordas	44
3.4	Avaliação da Segmentação	45
CAPÍTULO 4	O SEGMENTADOR <i>SegSAR</i>	49
4.1	Primeira Etapa	54
4.1.1	Entrada de Dados	54
4.1.2	Compressão	59
4.1.3	Segmentação por Crescimento de Regiões	65
4.2	Segunda Etapa	68
4.3	Terceira Etapa	69
4.3.1	Teste de Ajuste de Bordas	70
4.3.2	Teste de Homogeneidade para Regiões	71

4.3.3	Teste para Agrupar Regiões	74
4.4	Quarta Etapa	78
CAPÍTULO 5 APLICAÇÕES E DISCUSSÕES		81
5.1	Aplicações do <i>SegSAR</i> sobre Imagens de Radar	81
5.1.1	Imagens Simuladas	81
5.1.2	Modelo de Manchas	85
5.1.3	Modelo de Textura	101
5.1.4	Imagens Reais	108
5.2	Aplicações do <i>SegSAR</i> sobre Imagens Ópticas	109
5.2.1	Segmentação <i>TM/Landsat</i> Versus <i>JERS</i>	110
5.2.2	Segmentação de Imagem <i>ETM+/Landsat</i>	112
CAPÍTULO 6 CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES		115
REFERÊNCIAS BIBLIOGRÁFICAS		117
APÊNDICE A ALGUMAS DISTRIBUIÇÕES ESTATÍSTICAS E SUAS PROPRIEDADES		121
A.1	Distribuição Normal	121
A.2	Distribuição Constante	121
A.3	Distribuição Exponencial Padrão	121
A.4	Distribuição Exponencial	122
A.5	Distribuição Gama Padrão	122
A.6	Distribuição Gama	123
APÊNDICE B VALORES CRÍTICOS DE COEFICIENTE DE VARIAÇÃO DA DISTRIBUIÇÃO GAMA		125

LISTA DE FIGURAS

	Pág.
2.1 Fasores do vetor amplitude	26
2.2 Geometria de imageamento para radares de visada lateral de abertura real	26
3.1 Exemplo de representação hierárquica por pirâmide com 3 níveis.	40
3.2 Perda de informação numa imagem degradada de resolução através da representação piramidal.	42
3.3 Representação espacial do <i>quad tree</i>	42
4.1 Interface principal do segmentador <i>SegSAR</i> ilustrando os campos de entrada de dados, para imagens de radar, usando os modelos de manchas (a) e de textura (b).	50
4.2 Interface do segmentador <i>SegSAR</i> no caso de imagem de ópticas	51
4.3 Interface do ENVI para selecionar imagens de entrada para o programa de segmentação <i>SegSAR</i>	52
4.4 Fluxograma do processo de segmentação de imagens com o <i>SegSAR</i>	54
4.5 Fluxograma da primeira etapa do processo de segmentação.	55
4.6 Distribuições $\Gamma(n, n)$ para diferentes valores de n	56
4.7 Pirâmide de compressão com quatro níveis	60
4.8 Fluxograma da segunda etapa do processamento.	68
4.9 Fluxograma da terceira etapa do processamento.	69
4.10 Ilustração do teste de ajuste de bordas.	72
4.11 Fluxograma da quarta etapa do processamento.	79
5.1 Imagem com as regiões da imagem referência (<i>phantom</i>)	82

5.2	Segmentação ideal utilizada no processo de avaliação do segmentador <i>SegSAR</i>	82
5.3	Processo de segmentação de uma imagem Gama 8 <i>looks</i> com nível máximo de compressão igual a 5	84
5.4	Imagem original Gama com 3 <i>looks</i> e as respectivas segmentações para os diferentes níveis máximos de compressão, usando o modelo de manchas	86
5.5	Valores médios globais obtidos da segmentação sobre as 100 imagens Gama de 3 <i>looks</i> para os diferentes níveis de compressão, usando o modelo de manchas	87
5.6	Valores médios globais das medidas de qualidade sobre as 100 imagens Gama de 3 <i>looks</i> para diferentes níveis máximos de compressão, usando o modelo de manchas	89
5.7	Imagem original Gama com 8 <i>looks</i> e as respectivas segmentações com diferentes níveis máximos de compressão, usando o modelo de manchas	90
5.8	Valores médios globais das medidas de qualidade para segmentação das 100 imagens Gama de 8 <i>looks</i> para os diferentes níveis de compressão, usando o modelo de manchas	91
5.9	Valores médios globais das medidas de qualidade sobre as 100 imagens Gama de 8 <i>looks</i> para diferentes níveis de compressão, usando o modelo de manchas	91
5.10	Média geral e o tempo médio das segmentações das imagens Gama de 3 e 8 <i>looks</i> para os diferentes níveis máximos de compressão, usando o modelo de manchas	93
5.11	Número médio de regiões formado ao segmentar as imagens Gama com 3 e 8 <i>looks</i> no modelo de manchas	93
5.12	Imagem original Textura com 3 <i>looks</i> e as respectivas segmentações para os diferentes níveis de compressão, usando o modelo de manchas	94
5.13	Valores médios globais obtidos da segmentação sobre as 100 imagens Textura de 3 <i>looks</i> para os diferentes níveis de compressão, usando o modelo de manchas	95

5.14	Valores médios globais das medidas de qualidade sobre as 100 imagens Textura de 3 <i>looks</i> para os diferentes níveis máximos de compressão, usando o modelo de manchas	96
5.15	Imagem original Textura com 8 <i>looks</i> e as respectivas segmentações para os diferentes níveis de compressão, usando o modelo de manchas	98
5.16	Valores médios globais obtidos da segmentação sobre as 100 imagens Textura de 8 <i>looks</i> para os diferentes níveis de compressão, usando o modelo de manchas	99
5.17	Valores médios globais das medidas de qualidade sobre as 100 imagens Textura de 8 <i>looks</i> para os diferentes níveis de compressão, usando o modelo de manchas	99
5.18	Média geral e o tempo médio das segmentações das imagens Textura de 3 e 8 <i>looks</i> para os diferentes níveis de compressão, usando o modelo de manchas	100
5.19	Número médio de regiões formado ao segmentar as imagens Textura com 3 e 8 <i>looks</i> no modelo de manchas	101
5.20	Imagem original Textura com 3 <i>looks</i> e as respectivas segmentações para os diferentes níveis de compressão, usando o modelo de textura	102
5.21	Imagem original Textura com 8 <i>looks</i> e as respectivas segmentações para os diferentes níveis de compressão, usando o modelo de textura	103
5.22	Valores médios globais obtidos da segmentação sobre as 100 imagens Textura de 3 <i>looks</i> para os diferentes níveis de compressão, usando o modelo de textura	104
5.23	Valores médios globais das medidas de qualidade sobre as 100 imagens Textura de 3 <i>looks</i> para os diferentes níveis de compressão, usando o modelo de textura	104
5.24	Valores médios globais obtidos da segmentação sobre as 100 imagens Textura de 8 <i>looks</i> para os diferentes níveis de compressão, usando o modelo de textura	106

5.25	Valores médios globais das medidas de qualidade sobre as 100 imagens Textura de 8 <i>looks</i> para os diferentes níveis de compressão, usando o modelo de textura	106
5.26	Média geral das segmentações das imagens Textura de 3 e 8 <i>looks</i> para os diferentes níveis de compressão, usando o modelo de textura	107
5.27	Número médio de regiões formado ao segmentar as imagens Textura com 3 <i>looks</i> nos modelos de mancha e textura	108
5.28	Número médio de regiões formado ao segmentar as imagens Textura com 8 <i>looks</i> nos modelos de mancha e textura	108
5.29	Imagem de radar Banda X com 6 <i>looks</i> e resolução de 1 metro	109
5.30	Imagem banda X segmentada com o modelo de manchas e com o modelo textura	110
5.31	Imagem <i>TM/LANDSAT</i> na composição RGB-543 e a imagem <i>JERS</i> . . .	111
5.32	Imagem <i>TM/LANDSAT</i> segmentada com 4 níveis de compressão e imagem <i>JERS</i> segmentada com 6 níveis	111
5.33	Imagem do sensor <i>ETM+/Landsat</i> da região de Miguelópolis (SP) composição 453.	112
5.34	Imagem segmentada da região de Miguelópolis (SP) usando o <i>SegSAR</i> com 5 níveis de compressão.	113

LISTA DE TABELAS

	Pág.
2.1 Modelagem do sinal de retorno em intensidade para n visadas	33
2.2 Modelagem do sinal de retorno em amplitude para n visadas	33
4.1 Conjunto de parâmetros de segmentação para cada tipo de imagem de entrada representada pelos diferentes modelos.	53
4.2 Compressão e descompressão de imagem com 641 colunas por 480 linhas. .	61
4.3 Valores críticos de cv a 5% obtidos por simulação <i>Monte Carlo</i>	73
5.1 Valores de similaridade e número equivalente de <i>looks</i> para a imagem Gama com 8 <i>looks</i> , segundo o modelo de manchas.	85
5.2 Valores de média e desvio padrão das medidas de qualidade para as 100 imagens Gama simuladas com 3 <i>looks</i> , usando o modelo de manchas. . . .	88
5.3 Valores de média e desvio padrão das medidas de qualidade para as 100 imagens Gama simuladas com 8 <i>looks</i> , usando o modelo de manchas. . . .	92
5.4 Valores de média e desvio padrão das medidas de qualidade para as 100 imagens Textura simuladas com 3 <i>looks</i> , usando o modelo de manchas. . .	96
5.5 Valores de média e desvio padrão das medidas de qualidade para as 100 imagens Textura simuladas com 8 <i>looks</i> , usando o modelo de manchas. . .	97
5.6 Valores de média e desvio padrão das medidas de qualidade para as 100 imagens Textura simuladas com 3 <i>looks</i> , usando o modelo de textura. . . .	105
5.7 Valores de média e desvio padrão das medidas de qualidade para as 100 imagens Textura simuladas com 8 <i>looks</i> , usando o modelo de textura. . . .	107
B.1 Valores críticos de cv a 0,1% obtidos por simulação de <i>Monte Carlo</i>	125
B.2 Valores críticos de cv a 0,5% obtidos por simulação de <i>Monte Carlo</i>	126
B.3 Valores críticos de cv a 1% obtidos por simulação de <i>Monte Carlo</i>	127

B.4	Valores críticos de cv a 5% obtidos por simulação de <i>Monte Carlo</i>	128
B.5	Valores críticos de cv a 10% obtidos por simulação de <i>Monte Carlo</i>	129
B.6	Valores críticos de cv a 15% obtidos por simulação de <i>Monte Carlo</i>	130
B.7	Valores críticos de cv a 20% obtidos por simulação de <i>Monte Carlo</i>	131

CAPÍTULO 1

INTRODUÇÃO

O uso de imagens de radar (*RAdio Detection and Ranging*), em particular de abertura sintética (*Synthetic Aperture Radar - SAR*) vem crescendo nos últimos anos. O interesse por esse tipo de dado e as suas aplicações em atividades de monitoramento e análise tem tido um acréscimo considerável. Estas imagens são aplicadas em várias áreas, tais como: geologia, hidrologia, oceanografia.

Gerando imagens de alta resolução sem depender da iluminação solar e tendo uma pequena influência dos efeitos atmosféricos, os sensores *SAR* tornam-se os mais indicados para regiões que apresentam alta taxa de cobertura de nuvens.

As imagens geradas pelos sistemas *SAR* apresentam um ruído multiplicativo denominado *speckle*, resultante da radiação coerente usada para gerar as imagens. A presença deste ruído provoca dificuldade na análise destas imagens, tanto visual quanto automática, pois o mesmo provoca uma grande variação nos valores de intensidade de cada ponto da imagem.

Com o aumento da utilização de dados *SAR*, faz-se necessário o desenvolvimento de técnicas automáticas de processamento e análise, para tornar operacional o uso dessas imagens. O desenvolvimento de técnicas específicas para a extração de informações das imagens *SAR* é um dos principais desafios hoje em dia para a comunidade científica. Técnicas de filtragem, de segmentação e de classificação são comumente utilizadas para melhorar a discriminação de feições e alvos de interesse.

A segmentação de imagens *SAR* apresenta-se como um ponto crítico no processo de análise de imagens. Os algoritmos de segmentação têm como principal objetivo obter de forma automática uma partição da imagem, e o ponto difícil na implementação de alguns algoritmos está na forma de representação das características da imagem.

A modelagem de dados de sensoriamento remoto através da distribuição Gaussiana é comumente usada em algoritmos de segmentação, sendo um dos fatores desse freqüente uso a facilidade na implementação da mesma. Entretanto, essa distribuição não é a mais adequada para representar os dados de imagens *SAR*.

O presente trabalho tem como principal objetivo o desenvolvimento, implementação e teste de um segmentador para imagens *SAR* levando em consideração suas propriedades estatísticas. O sistema desenvolvido possui diversas propriedades as quais, integradas, o

tornam um sistema de segmentação único: tem flexibilidade para trabalhar com imagens de radar e imagens ópticas; faz segmentação multi-bandas; usa critérios hierárquicos para fazer a segmentação, usa técnicas de crescimento de regiões (*region growing*), testes para ajuste de bordas (*edge detect*); usa testes de homogeneidade para regiões (*split*) e testes de homogeneidade entre regiões (*merging*). Uma outra característica do segmentador proposto é que ele é incremental, utilizando desta forma a informação contida em cada nível para segmentar com maior detalhe a imagem. Podem ser também gerados resultados intermediários, os quais são segmentações sobre as imagens com resolução degradada.

Embora o objetivo principal deste trabalho tenha sido desenvolver um segmentador para imagens de radar, o mesmo possui um módulo para a segmentação de imagens ópticas, o qual difere do segmentador para imagens de radar basicamente na modelagem dos dados e nos testes utilizados, os quais são mais apropriados para imagens ópticas.

Esta tese está dividida em seis capítulos. O Capítulo 1 é a introdução ao tema. A formação das imagens ópticas e de radar *SAR*, suas características estatísticas, e as distribuições mais usadas para modelar essas imagens são abordadas no Capítulo 2. Uma revisão bibliográfica sobre segmentação de imagens e sobre os tipos de segmentadores existentes para imagens *SAR* é apresentado no Capítulo 3. O Capítulo 4 apresenta o segmentador desenvolvido para imagens de radar e ópticas o *SegSAR* e a metodologia utilizada no desenvolvimento do mesmo. No Capítulo 5 são apresentadas aplicações e discussões do segmentador e os resultados obtidos para imagens ópticas e de radar. Por fim, no Capítulo 6 tem-se as conclusões e recomendações da presente tese.

CAPÍTULO 2

ESTATÍSTICA DE IMAGENS

Este capítulo faz uma introdução às imagens ópticas e os dados gerados por radares imageadores de abertura sintética *SAR*, suas características e a modelagem estatística necessária para tratar esse tipo de dado. Será dada mais ênfase a imagem de radar por ser este o objetivo principal do segmentador.

2.1 Imagens Ópticas

Os sensores ópticos operam em diferentes faixas do espectro-eletromagnético sendo que cada sensor tem características próprias que estão diretamente relacionadas com a faixa espectral ou banda de imageamento na qual ele opera. Em geral, as imagens geradas por sensores ópticos são modeladas estatisticamente por uma única distribuição, a distribuição normal (ou gaussiana). Isso permite que o uso de uma técnica de segmentação com base na estatística gaussiana sirva para a maioria das imagens ópticas.

Uma grande diferença entre imagens ópticas e de radar é que a primeira apresenta preponderantemente um ruído aditivo e a outra um ruído multiplicativo. Por definição, ruído é qualquer tipo de informação indesejada que obstrui a aquisição e o processamento da informação desejada.

É comum em imagens ópticas, a suposição de que o ruído possua uma distribuição uniforme ou gaussiana. O ruído gaussiano é muito comum e é frequentemente usado para modelar ruídos desconhecidos (Marque e Viera, 1999). Isso se dá devido ao teorema do limite central, que estabelece basicamente que a soma de um grande número de termos, representando ruídos aleatórios, tende a produzir um ruído resultante do tipo gaussiano (Hoel et al., 1978; DeGroot e Schervish, 2002).

2.2 Radares de Abertura Sintética - *SAR*

O sistema de radar opera normalmente numa faixa restrita do espectro eletromagnético, também conhecida como faixa de microondas. Este intervalo espectral tem como frequência mínima 0,3 GHz e máxima 100,0 GHz correspondendo a comprimentos de onda de 100 cm e 0,3 cm, respectivamente.

Diferentemente dos sensores passivos que dependem de uma fonte externa de energia, os sistemas de radar emitem a energia para o imageamento, sendo assim denominados de sensores ativos. Essa independência traz grandes vantagens, pois permite gerar imagens

em qualquer horário.

Uma característica da energia nas frequências de microondas é ter uma alta transmitância atmosférica em alguns comprimentos de onda. Esta transmitância chega a ser total para comprimentos de ondas maiores que 5 cm. No geral, o pulso emitido pelo sistema de radar sofre uma pequena atenuação atmosférica, o que permite estudos com imagens regulares úteis, já que restrições atmosféricas como chuva, nuvem, neblina, são minimizadas, tornando este tipo de sensor apropriado para ser usado em regiões com constante cobertura de nuvens (Ulaby et al., 1986; Ulaby e Dobson, 1989; Mascarenhas e Frery, 1994). Esse fato não ocorre com as imagens obtidas por sensores passivos, que sofrem grande dependência das condições atmosféricas para a obtenção de imagens.

Os sistemas de radar podem ser divididos em 2 grupos: os imageadores e os não imageadores. Os sistemas de antena rotatória, os radares de abertura real (*RAR - Real Aperture Radar*) e os radares de abertura sintética (*SAR - Synthetic Aperture Radar*) integram o grupo dos radares imageadores. Já os espectrômetros, os escaterômetros e os altímetros são exemplos de radares não imageadores (Ulaby et al., 1986; Ulaby e Dobson, 1989).

Em sensores *SAR* e em outros sistemas que utilizam radiação coerente, as imagens são corrompidas por uma forma de ruído multiplicativo, conhecido como *speckle*. Este tipo de imagem tem como característica apresentar uma baixa relação sinal ruído e por consequência, requer um processamento especial.

Segundo Nathanson (1991), o radar tem radiação coerente quando as componentes do sinal, a amplitude e a fase relativa, têm uma relação conhecida, mesmo que possam estar consideravelmente separados no tempo, ou também quando o oscilador (que gera o pulso de radiação) é suficientemente estável, sendo possível com isso prever a fase recebida um tempo depois da transmissão do pulso.

O sistema de radar é capaz de gerar imagens de alta resolução mesmo em plataformas orbitais (Ulaby et al., 1986), o que é possível pelo uso de uma técnica de processamento de imagens que melhora a resolução azimutal (resolução ao longo da direção de movimento da plataforma), através da síntese de uma antena maior que o seu tamanho real (antena sintética).

A seguir será descrito o processo de imageamento para dados *SAR*, a obtenção da resolução em *range* (alcance) e em azimute, e o processamento *multilook* ou n visadas.

2.2.1 Imageamento *SAR*

O imageamento por radar consiste na emissão e recepção de pulsos de energia eletromagnética na faixa de microondas. A energia emitida se propaga até encontrar um alvo ou obstáculo que a espalhe. Parte da energia retroespalhada é captada pelo sistema sensor do radar, outra parte da energia interage com o alvo (absortância e transmitância) e é absorvida e liberada em forma de calor. A energia captada pelo sensor contém informações que caracterizam o alvo e é usada para formar a imagem.

Existem dois tipos de sistemas de imageamento, os monoestáticos e os biestáticos. O primeiro usa somente uma antena para a emissão do pulso e recepção do sinal retroespalhado pelo alvo, enquanto que o segundo utiliza duas antenas, uma para emissão e outra para recepção. Uma das vantagens dos sistemas biestáticos é que as antenas podem ter características distintas como a dimensão, o ângulo de visada e a polarização. No entanto, o fato de utilizar duas antenas pode causar problemas no transporte e na disposição das antenas, acarretando em interferência entre as mesmas, motivo pelo qual é mais comum o uso de sistemas monoestáticos (Ulaby et al., 1986; Henderson e Lewis, 1999).

Quanto à representação digital, o sinal obtido pelo sensor de radar é geralmente representado por números complexos ($Z_{\Re} + iZ_{\Im}$). Assim, o sinal é representado por uma única onda de frequência senoidal que é descrita como um fasor girando. Além da conveniência matemática, existem algumas vantagens práticas de se usar a representação complexa para o sinal. Para o uso prático, os sinais complexos são derivados separando o sinal nas componentes real em fase ($\Re$) e quadratura ($\Im$) (Nathanson, 1991).

As imagens de radar geralmente estão representadas em amplitude ($A = \sqrt{Z_{\Re}^2 + Z_{\Im}^2}$) também denominada detecção linear, ou em intensidade ($I = Z_{\Re}^2 + Z_{\Im}^2 = A^2$) denominada detecção quadrática. Uma outra forma de representar imagem de radar é em dB (decibéis), que é uma medida de potência ($dB = 10\log(I)$).

As imagens *SAR* são caracterizadas por apresentarem um ruído multiplicativo denominado *speckle* que é resultante das interferências construtivas e destrutivas da energia retroespalhada pelo alvo. A Figura 2.1 mostra o processo de formação do sinal com amplitude A e com a fase Φ , como sendo a resultante da somatória de todos os vetores elementares pontuais, representados pelas amplitudes A_i e pelas fases Φ_i . Observações sucessivas dentro de uma mesma área imageada pelo sensor, podem resultar em diferentes valores de amplitude.




FIGURA 2.1 – Fasores do vetor amplitude.

2.2.1.1 Resolução em *Range* e em Azimute

A resolução pode ser definida como a mínima diferença pela qual dois valores discretos ou alvos podem ser identificados numa imagem.

As resoluções nos sistemas de radar são definidas em três direções: azimutal, transversal no terreno e perpendicular à linha de vôo. A Figura 2.2 apresenta os parâmetros da geometria de imageamento para radares de visada lateral de abertura real. Nesta figura, L representa o comprimento físico da antena; β_h e β_v são os ângulos da abertura horizontal e vertical, respectivamente; h é a altitude do sensor; R representa a distância da antena à uma célula de resolução; e θ é o ângulo de apontamento do eixo da antena ou ângulo de visada.




FIGURA 2.2 – Geometria de imageamento para radares de visada lateral de abertura real.

FONTE: Modificada de Ulaby e Dobson (1989).

Em radares de visada lateral podem ser definidos três tipos de resolução:

- resolução em azimute (r_a) - *azimuth resolution*;
- resolução transversal no terreno (r_t) - *ground range resolution*;
- resolução transversal na linha de visada (r_{lv}) - *slant range resolution*;

Em radares de abertura real, a resolução azimutal pode ser calculada por:

$$r_a = R\beta_h \quad (2.1)$$

onde R é a distância da antena à uma célula de resolução e β_h é o ângulo de abertura horizontal do sensor.

Sabendo-se que

$$R = \frac{h}{\cos\theta} \quad (2.2)$$

então

$$r_a = \frac{\beta_h h}{\cos\theta} \quad (2.3)$$

A resolução azimutal piora para os pontos mais distantes a nadir da antena (sensor), onde se observa os maiores valores de θ .

A largura do feixe (em radianos) é dado por:

$$\beta_h \cong \frac{\lambda}{L} \quad (2.4)$$

onde λ é o comprimento de onda e L é o comprimento físico da antena (Elachi, 1987).

A resolução transversal no terreno (r_t) é inversamente proporcional à banda do sinal modulado, ou seja, está diretamente relacionada à duração do pulso: quanto menor a duração do pulso, melhor a resolução transversal. Esta resolução é expressa por:

$$r_t = \frac{c\tau}{2\sin\theta} \quad (2.5)$$

onde c é a constante para a velocidade da luz, e τ é a duração de um pulso. Já a resolução

transversal na linha de visada pode ser representada por:

$$r_{lv} = \frac{c\tau}{2} \quad (2.6)$$

Para se diminuir a duração do pulso, a fim de se ter uma resolução transversal mais fina, tem-se que aumentar a potência de pico exigida do sistema, para que se mantenha a mesma potência média.

A melhor resolução azimutal para dados *SAR* independe da distância entre a antena (sensor) e o alvo, e é igual à metade do tamanho físico da antena real, ou seja (Ulaby e Dobson, 1989)

$$r_a \cong \frac{L}{2} \quad (2.7)$$

A resolução em *range* ou resolução transversal à linha de vôo para sistemas *SAR* é a mesma que para os sistemas *RAR*, mas os sistemas *SAR* melhoram a resolução em azimuth, utilizando técnicas derivadas da compressão de pulso (Ulaby e Dobson, 1989).

2.2.1.2 Processamento *Multilook*

O processamento *multilook* ou em multivisadas consiste em dividir a abertura sintética da antena em alguns setores (*looks* ou visadas), processando-os independentemente e somando em seguida cada um destes *looks*, com objetivo de reduzir o efeito do *speckle*. Como consequência deste processo, tem-se a degradação da resolução azimutal da imagem.

Desta forma, pode-se representar a resolução azimutal por

$$r_a \cong \frac{nL}{2} \quad (2.8)$$

onde n é o número de visadas independentes (Ulaby e Dobson, 1989).

2.2.2 Propriedades Estatísticas da Imagem *SAR*

Os dados *SAR* são complexos devido à demodulação coerente fase-quadratura do sinal eco recebido pelo radar. Cada valor complexo correspondente a um *pixel*, que é o resultado da soma coerente (vetorial) do sinal retroespalhado por cada um dos elementos difusores de uma célula de resolução. O sinal total recebido, Z , de uma célula de resolução na

posição u pode ser escrita por:

$$Z(u) = \sum_{i=1}^N A_i e^{j\Phi_i} \quad (2.9)$$

onde N é o número de elementos dentro da célula imageada, A_i são as amplitudes individuais do sinal retroespalhado, e ϕ_i são as fases dos sinais (Caves, 1993).

As componentes real e imaginária do sinal de retorno são descritas como $Z_{\Re}$ e $Z_{\Im}$, respectivamente. Quando o alvo apresentar uma superfície rugosa ou quando o elemento de resolução possuir dimensões muito maiores que o comprimento de onda, a fase difusora será distribuída uniformemente entre $[-\pi, \pi]$ e é independente da amplitude. $Z_{\Re}$ e $Z_{\Im}$ podem ser dadas por:

$$Z_{\Re}(u) = \sum_{i=1}^N A_i \cos \Phi_i \quad (2.10)$$

$$Z_{\Im}(u) = \sum_{i=1}^N A_i \sin \Phi_i \quad (2.11)$$

Tanto a parte real quanto a parte imaginária apresentam média zero e a mesma variância. Fazendo uso da notação $E[\cdot]$ para representar a esperança de uma variável aleatória, tem-se que:

$$\begin{aligned} E[Z_{\Re}(u)] &= E \left[\sum_{i=1}^N A_i \cos \Phi_i \right] \\ &= \sum_{i=1}^N E[A_i] E[\cos \Phi_i] = 0 \end{aligned} \quad (2.12)$$

uma vez que A_i e Φ_i são independentes e $E[\cos \Phi_i] = 0, \forall i$.

Similarmente, tem-se que:

$$\begin{aligned} E[Z_{\Im}(u)] &= E \left[\sum_{i=1}^N A_i \sin \Phi_i \right] \\ &= \sum_{i=1}^N E[A_i] E[\sin \Phi_i] = 0 \end{aligned} \quad (2.13)$$

pois $E[\text{sen}\Phi_i] = 0, \forall i$.

As variâncias são obtidas por:

$$\text{Var}[Z_{\Re}(u)] = E[(Z_{\Re}(u))^2] - (E[Z_{\Re}(u)])^2 \quad (2.14)$$

$$\text{Var}[Z_{\Im}(u)] = E[(Z_{\Im}(u))^2] - (E[Z_{\Im}(u)])^2 \quad (2.15)$$

Como as esperanças da parte real e da parte imaginária são iguais a zero, as variâncias podem ser representadas por:

$$\begin{aligned} \text{Var}[Z_{\Re}(u)] &= E[Z_{\Re}(u)^2] \\ &= E\left[\left(\sum_{j=1}^N A_j \cos\Phi_j\right)\left(\sum_{i=1}^N A_i \cos\Phi_i\right)\right] \\ &= \sum_{j=1}^N \sum_{i=1}^N E[A_j A_i] E[\cos\Phi_j \cos\Phi_i] \\ &= \frac{1}{2} \sum_{i=1}^N E[A_i^2] \end{aligned} \quad (2.16)$$

$$\begin{aligned} \text{Var}[Z_{\Im}(u)] &= E[Z_{\Im}(u)^2] \\ &= E\left[\left(\sum_{j=1}^N A_j \text{sen}\Phi_j\right)\left(\sum_{i=1}^N A_i \text{sen}\Phi_i\right)\right] \\ &= \sum_{j=1}^N \sum_{i=1}^N E[A_j A_i] E[\text{sen}\Phi_j \text{sen}\Phi_i] \\ &= \frac{1}{2} \sum_{i=1}^N E[A_i^2] \end{aligned} \quad (2.17)$$

dado que $E[\cos\Phi_j \cos\Phi_i] = E[\text{sen}\Phi_j \text{sen}\Phi_i] = \frac{1}{2}$ se $j = i$ e zero se $j \neq i$ (Caves, 1993).

As componentes de $Z(u)$ não são correlacionadas, visto que a covariância entre as duas

componentes é nula, devido à ortogonalidade entre $\cos\Phi_j$ e $\sin\Phi_i$. Dessa forma:

$$\begin{aligned} E[Z_{\Re}(u)Z_{\Im}(u)] &= E\left[\left(\sum_{j=1}^N A_j \cos\Phi_j\right)\left(\sum_{i=1}^N A_i \sin\Phi_i\right)\right] \\ &= \sum_{j=1}^N \sum_{i=1}^N E[A_j A_i] E[\cos\Phi_j \sin\Phi_i] = 0 \end{aligned} \quad (2.18)$$

já que $E[\cos\Phi_j \sin\Phi_i] = 0, \forall j, i$.

Quando o número de difusores N for muito grande, satisfazendo as condições do teorema do limite central, pode se provar que $Z_{\Re}$ e $Z_{\Im}$ possuem distribuição aproximadamente Gaussiana, com média zero e variâncias iguais (Yanasse, 1991). Assim, a função densidade de probabilidade conjunta é dada por:

$$f(Z_{\Re}, Z_{\Im}) = \frac{1}{2\pi \text{Var}(Z)} \exp\left\{-\frac{(Z_{\Re}^2 + Z_{\Im}^2)}{2\text{Var}(Z)}\right\} \quad (2.19)$$

onde se tem que $\text{Var}(Z) = \text{Var}(Z_{\Re}) = \text{Var}(Z_{\Im})$.

A intensidade do elemento de resolução é definido por

$$Z_I(u) = |Z(u)|^2 = Z_{\Re}(u)^2 + Z_{\Im}(u)^2. \quad (2.20)$$

$Z_I(u)$ tem então uma densidade de probabilidade exponencial com média dada por

$$\mu_I = E(Z_I(u)) = \sum_{i=1}^N E(A_i^2). \quad (2.21)$$

onde A_i^2 representa o sinal de cada difusor elementar através da seção transversal imageada pelo sensor de radar. A resposta média em intensidade é diretamente proporcional à seção transversal imageada e, portanto do coeficiente de retroespalhamento.

O sinal retroespalhado (σ^0) é usualmente expresso em decibéis dB , e definido como a razão da energia recebida pelo sensor sobre a energia que o sensor deveria receber se a superfície imageada tivesse um comportamento isotrópico (Elachi, 1987).

Caves (1993) mostra que o momento da intensidade de ordem m pode ser generalizado

na forma

$$E(Z_I(u)^m) = m! \cdot \left(\sum_{i=1}^N E[A_i^2] \right)^m \quad (2.22)$$

O m -ésimo momento da intensidade de uma variável aleatória exponencial de média unitária é $m!$. O m -ésimo momento da intensidade pode ser expresso por

$$E(Z_I(u)^m) = E(X(u)^m) \cdot E(Y(u)^m) \quad (2.23)$$

onde Y é uma *v.a.* exponencial com média unitária e X é uma *v.a.* definida por:

$$X(u) = \sum_{i=1}^N A_i^2 \quad (2.24)$$

Como a Equação 2.23 aplica-se a todos os momentos, pode-se concluir que a intensidade é dada por

$$Z_I(u) = X(u) \cdot Y(u) \quad (2.25)$$

Esta Equação é conhecida como modelo multiplicativo e é comumente usado para explicar o comportamento estatístico de dados obtidos por fontes de radiação coerente. Em princípio, o modelo baseia-se na suposição que o valor observado (Z) em cada *pixel* é resultante da multiplicação de duas variáveis aleatórias independentes (X e Y), onde X representa a variável aleatória relativa à componente da informação retroespalhada pelos alvos imageados (aqui denominada *backscatter*), e Y é a componente do ruído *speckle*.

A variável aleatória X (*backscatter*) para regiões homogêneas é modelada como um valor constante e desconhecido, tanto para imagens em intensidade quanto para imagens em amplitude.

A variável aleatória Y (*speckle*) com n visadas pode ser modelada como uma soma de n variáveis aleatórias com distribuições exponenciais para imagens em intensidade resultando numa distribuição Gama ($\Gamma(n, n)$) com média igual a 1. Para imagens em amplitude, o *speckle* pode ser representado por uma distribuição Raiz da Gama ($\Gamma^{1/2}(n, n)$) (FRERY, 1993; Yanasse et al., 1995).

Quando a intensidade está de acordo com o modelo multiplicativo (2.25), pode-se dizer que a amplitude (Z_A) é obtida pelo produto da raiz quadrada do sinal retroespalhado

(*backscatter*) pela raiz quadrada da Gama com média unitária (*speckle*)

$$Z_A = \sqrt{Z_I} = \sqrt{X(u)} \cdot \sqrt{Y(u)} \quad (2.26)$$

onde a $\sqrt{Y}$ tem uma distribuição raiz quadrada da Gama ($\Gamma^{1/2}(n, n)$) (Caves, 1993).

Para regiões heterogêneas, é comum supor que a *v.a.* X possua uma distribuição Gama com dois parâmetros para imagens em intensidade ($\Gamma(\alpha, \lambda)$), ou equivalentemente, a uma distribuição Raiz da Gama também com dois parâmetros para imagens em amplitude ($\Gamma^{1/2}(\alpha, \lambda)$) (Jakeman, 1980). Para regiões extremamente heterogêneas, Frery et al. (1997) propõem uma distribuição Recíproca da Gama a dois parâmetros para a *v.a.* X , em imagens em intensidade ($\Gamma^{-1}(\alpha, \gamma)$), ou equivalente a uma distribuição Raiz da Recíproca da Gama para imagens em amplitude ($\Gamma^{-1/2}(\alpha, \gamma, \lambda)$).

Nas Tabelas 2.1 e 2.2, são encontradas as várias distribuições obtidas para o sinal de retorno em intensidade (Z_I) e amplitude (Z_A), respectivamente, para n visadas, tomando como base diferentes distribuições para modelar o *backscatter*.

TABELA 2.1 – Modelagem do sinal de retorno em intensidade para n visadas.

Regiões	<i>Backscatter</i> (X_I)	<i>Speckle</i> (Y_I)	$Z_I = X_I \cdot Y_I$
Homogêneas	$C(\mu)$	$\Gamma(n, n)$	$\Gamma(n, \frac{n}{\mu})$
Heterogêneas	$\Gamma(\alpha, \lambda)$	$\Gamma(n, n)$	$K_I(\alpha, \lambda, n)$
Ext. Heterogêneas	$\Gamma^{-1}(\alpha, \gamma)$	$\Gamma(n, n)$	$\mathcal{G}_I^0(\alpha, \gamma, n)$

FONTE: : Modificada de VIEIRA (1996).

TABELA 2.2 – Modelagem do sinal de retorno em amplitude para n visadas.

Regiões	<i>Backscatter</i> (X_A)	<i>Speckle</i> (Y_A)	$Z_A = X_A \cdot Y_A$
Homogêneas	$C(\sqrt{\mu})$	$\Gamma^{1/2}(n, n)$	$\Gamma^{1/2}(n, \frac{n}{\mu})$
Heterogêneas	$\Gamma^{1/2}(\alpha, \lambda)$	$\Gamma^{1/2}(n, n)$	$K_A(\alpha, \lambda, n)$
Ext. Heterogêneas	$\Gamma^{-1/2}(\alpha, \gamma, \lambda)$	$\Gamma^{1/2}(n, n)$	$\mathcal{G}_A^0(\alpha, \gamma, n)$

FONTE: : Modificada de VIEIRA (1996).

Para regiões homogêneas, o sinal de retorno Z é modelado por uma distribuição Gama

a dois parâmetros para o sinal em intensidade e uma Raiz da Gama também a dois parâmetros para o sinal em amplitude, cujas funções densidade de probabilidade são dadas por:

$$f_{Z_I}(x) = \frac{\left(\frac{n}{\mu}\right)^n}{\Gamma(n)} x^{n-1} \exp\left(-\frac{n}{\mu}x\right), \quad n, \mu > 0 \quad (2.27)$$

$$f_{Z_A}(x) = \frac{\left(2\frac{n}{\mu}\right)^n}{\Gamma(n)} x^{2n-1} \exp\left(-\frac{n}{\mu}x^2\right), \quad n, \mu > 0. \quad (2.28)$$

Já para regiões heterogêneas, a intensidade pode ser modelada por uma distribuição K -intensidade (K_I) a três parâmetros e por uma distribuição K -amplitude (K_A) com os mesmos parâmetros para o sinal em amplitude. As funções de densidade de probabilidade que representam estas distribuições K são dadas por:

$$f_{Z_I}(x) = \frac{2\lambda n}{\Gamma(\alpha)\Gamma(n)} (\lambda n x)^{(\alpha+n)/2-1} K_{\alpha-n}(2\sqrt{\lambda n x}), \quad \alpha, \lambda, n, x > 0, \quad (2.29)$$

onde $K_{\alpha-n}$ é a função de Bessel modificada de terceiro tipo e ordem $\alpha - n$.

$$f_{Z_A}(x) = \frac{4\lambda n x}{\Gamma(\alpha)\Gamma(n)} (\lambda n x^2)^{(\alpha+n)/2-1} K_{\alpha-n}(2x\sqrt{\lambda n}), \quad \alpha, \lambda, n, x > 0. \quad (2.30)$$

E por fim, para regiões extremamente heterogêneas, o sinal em intensidade pode ser modelado por uma distribuição $\mathcal{G}_I^0$ a três parâmetros e por uma distribuição $\mathcal{G}_A^0$, também a três parâmetros para o sinal em amplitude, cujas funções densidade de probabilidade podem ser representadas respectivamente por:

$$f_{Z_I}(x) = \frac{n^n \Gamma(n - \alpha) x^{n-1}}{\gamma^\alpha \Gamma(n) \Gamma(-\alpha) (\gamma + n x)^{n-\alpha}}, \quad -\alpha, \gamma, n, x > 0, \quad (2.31)$$

$$f_{Z_A}(x) = \frac{2n^n \Gamma(n - \alpha) \gamma^{-\alpha} x^{2n-1}}{\Gamma(n) \Gamma(-\alpha) (\gamma + n x^2)^{n-\alpha}}, \quad -\alpha, \gamma, n, x > 0. \quad (2.32)$$

Portanto, as distribuições que são usadas para modelar dados *SAR* dependem do tipo de detecção se amplitude, intensidade ou complexo; do número de *looks* e da homogeneidade da região que está sendo imageada. Em Freitas et al. (2005) é proposta a distribuição G_p polarimétrica. Esta distribuição apresenta-se como sendo um caso mais geral, pois dela pode-se obter todas as outras distribuições citadas em Frery et al. (1997).

Mais detalhes sobre distribuições estatísticas usadas para modelar dados de radar podem ser encontrados em Yanasse (1991), FRERY (1993), Caves (1993), Yanasse et al. (1995), Frery et al. (1997), e Freitas et al. (2005).

CAPÍTULO 3

SEGMENTAÇÃO DE IMAGENS

Na interpretação de imagens, busca-se identificar regiões cujos elementos da imagem apresentem características visualmente comuns, tais como cor, textura ou intensidade. Já a técnica de segmentação busca prover uma identificação automática dessas regiões e assegurar uma forma computacional de manipulação dos dados. A importância da segmentação está na possibilidade de identificar todos os objetos (alvos) distintos que compõem uma imagem, facilitando a extração de informações.

A segmentação pode ser definida como o processo de agrupar os *pixels* de uma imagem em partições ou regiões disjuntas, usando como critério de agrupamento alguma propriedade intrínseca da imagem, tal como intensidade, média, contraste ou textura. Este processo representa o menor nível descritivo no qual o entendimento de uma imagem, para uma dada aplicação, possa ser baseado (Caves et al., 1998).

Uma região numa imagem é também definida como um conjunto de *pixels* conectados e que apresentam propriedades similares (Jain et al., 1995). O particionamento da imagem em seus elementos constituintes (regiões), cada um mais ou menos homogêneo com relação a uma propriedade específica, é tido como um dos primeiros passos do processo de análise de uma imagem digital (Gonzales e Wintz, 1987; Gerbrands, 1996).

A segmentação pode ser manual ou automática. A segmentação manual apresenta bons resultados, mas é mais demorada, extremamente dependente da habilidade do intérprete e inviável quando se deseja trabalhar com um volume muito grande de imagens. O processo de segmentação automático ou computacional é geralmente rápido, quando comparado com o processo manual.

Os principais fatores que impõem limitações à segmentação automática é a falta de aprendizagem do segmentador para identificar padrões, e a informação da própria imagem que dependendo do sensor pode não apresentar elementos suficientes para uma boa discriminação.

Segundo Yong et al. (2004), a segmentação de imagens é um problema de percepção física e psíquica, não sendo solucionável de forma analítica. Assim, para se obter um bom resultado, os algoritmos de segmentação devem ter como base modelos matemáticos, que podem ser complementados por heurísticas que envolvem informação semântica e informação a priori sobre a imagem que está sendo segmentada.

A abordagem para a segmentação de imagens *SAR* pode ser dividida em duas categorias: a baseada nos níveis de cinza ou a baseada na textura da imagem. A segmentação de imagens *SAR* baseada em níveis de cinza é abordada por Zaart et al. (1999) e Zaart et al. (2002). Este método apresenta como principal problema a estimação do limiar para separação das classes, já que é preciso fazer uso da análise de histograma para atribuir *pixels* às classes, selecionando-se limiares de separação para os vales do histograma multi-modal.

Um segmentador específico para imagens de radar é o *RWSEG* (White, 1986), que faz uso de técnica de detecção de bordas para fazer o crescimento de regiões. O processo de detecção de borda é sucessivo e no final é feito um agrupamento (*merging*) para gerar a segmentação final. A cada iteração é calculado o contraste médio das regiões e o processo pára quando o contraste médio não estiver mais diminuindo. No final do processo, a imagem segmentada é usada para gerar um mapa de bordas.

Outro segmentador para imagens de radar é o *MUM* (*Merge Using Moments*). Assim como o segmentador *RWSEG*, baseia-se no nível de cinza dos *pixels* da imagem para fazer o crescimento de regiões. O *MUM* adota um modelo para os dados em amplitude como sendo provenientes de uma distribuição Raiz da Gama (modelo de manchas), e faz uso da suposição que todos os *pixels* da imagem não são correlacionados. No início da segmentação, todos os *pixels* são regiões e esses *pixels* são comparados com seus vizinhos, agrupando os valores que são significativamente iguais. A segmentação termina quando não exista mais regiões que possam ser agrupadas (Cook et al., 1994).

Beaulieu e Touzi (2002) desenvolveram um algoritmo de segmentação para imagens *SAR* e comentam sobre a necessidade de se interromper a segmentação em algumas regiões, para priorizar o processo em outras regiões específicas, reduzindo o tempo de processamento e evitando que ocorra sub-segmentação em algumas áreas e uma super-segmentação em outras.

Na literatura existem descritos vários algoritmos de segmentação. Contudo não existe um algoritmo geral e simples que seja bom para todas as imagens, como também todos os algoritmos não são bons para uma imagem particular.

3.1 Modelos de Representação dos Dados

Na segmentação dos dados *SAR*, geralmente adota-se o modelo de manchas (*Cartoon*) que tem como base a homogeneidade das regiões, ou o modelo de textura (*Texture*) que supõe a presença de textura dentro de cada região.

No modelo de manchas, supõe-se que cada região que compõe a imagem *SAR* é homogênea. Portanto, para dados no formato intensidade é utilizada a distribuição Gama para descrever os dados de cada região. Para imagens ópticas é feita a suposição de que a variância das regiões é a mesma para todas as regiões da imagem.

Já no modelo de textura, o *backscatter* das regiões que compõem a imagem não é constante. Neste caso a distribuição Gama não é a melhor distribuição para descrever esses dados, sendo os mesmos melhor representados por distribuições como a *K* e a *G* (Yanasse et al., 1995). Para imagens ópticas, faz-se uso da variância de cada região, para o agrupamento de *pixels*, resultando assim numa segmentação com menos regiões, quando comparado com uma segmentação feita usando o modelo de manchas.

As descrições das técnicas de textura podem ser agrupadas em três grupos: a estatística, a espectral e a estrutural. A descrição estatística está baseada no histograma da região, suas extensões e seus momentos. A descrição espectral é baseada em função de autocorrelação da região ou na distribuição de intensidade no domínio da transformada de Fourier. A descrição estrutural usa modelos primitivos acompanhados de um número de regras (Pitas, 2000).

3.2 Representação de Imagens

As regiões podem ser usadas em vários contextos e podem ser representadas de muitas formas. As principais representações para regiões pertencem a uma das três classes abaixo (Jain et al., 1995):

- Representação por matriz (*array*)
- Representação hierárquica
- Representação simbólica.

3.2.1 Representação por Matriz

A representação de regiões por matriz (*array*) é tida como básica. Esta representação tem o mesmo tamanho da imagem original apresentando uma estrutura que indica a qual região cada *pixel* pertence. Se um elemento (i, j) de uma matriz tem um valor z , então o *pixel* correspondente na imagem pertence à região z .

Este tipo de representação preserva todos os detalhes das regiões requeridas em muitas aplicações. A preservação dos detalhes das regiões tem feito com que o uso de máscaras

binárias tenham se tornado a representação mais popular em computação e a maioria dos *hardwares* tem suporte disponível para manipular este tipo de estrutura (Jain et al., 1995).

3.2.2 Representação Hierárquica

Nesta forma de representação, a imagem pode ser tratada com diferentes resoluções. Assim, ao se degradar a resolução, diminui-se também a matriz que representa a imagem, e por consequência alguns dados podem ser perdidos, e a informação perdida dificilmente poderá ser recuperada no processo de descompressão da imagem. Entretanto, a degradação da resolução resulta numa redução da memória e da capacidade computacional requerida no processamento. A representação hierárquica de imagens permite manipular múltiplas resoluções (Jain et al., 1995). As duas formas de representação hierárquica mais comumente usadas são as pirâmides e os *quad tree*.

3.2.2.1 Forma de Representação por Pirâmide

A representação por pirâmide de uma imagem de tamanho $n \times n$ *pixels* contém a imagem original e k versões reduzidas da mesma. Usualmente, n é potência de 2 e as outras imagens possuem tamanho $n/2 \times n/2$, $n/4 \times n/4$, $n/8 \times n/8$, $\dots$, 1×1 *pixels*. Na representação de uma imagem por pirâmide, o *pixel* que está no nível N é obtido pela combinação de informações de vários *pixels* da imagem que está no nível $N - 1$. A imagem é representada como um simples *pixel* no topo da pirâmide, nível N , e neste nível, a imagem original não pode ser mais reduzida.

A Figura 3.1 mostra uma representação de uma pirâmide em três níveis ($N = 3$). Nesta representação tem-se uma imagem original com 16×16 *pixels* e uma imagem no nível 3 com 2×2 *pixels*.




FIGURA 3.1 – Exemplo de representação hierárquica por pirâmide com 3 níveis.

Um *pixel* em um nível da pirâmide contém informação agregada representada por vários *pixels* de um nível anterior. A pirâmide pode ser obtida de várias formas; a mais comum é fazendo a média dos valores dos níveis de cinza numa vizinhança 2×2 , ou seja, cada 4 *pixels* é representado no próximo nível por um único *pixel*. Outras formas de reduzir a resolução da imagem podem ser implementadas, assim como é possível estruturar uma pirâmide de um modo não linear (Jain et al., 1995). Uma desvantagem de se usar o método hierárquico por pirâmide é que ocorre uma perda de informação ao longo do processo de compressão e alvos pequenos na imagem original tem uma grande probabilidade de desaparecer e não serem detectados durante a segmentação (Rosenfeld, 1984).

A Figura 3.2 exemplifica a perda de informação decorrente do processo de compressão por pirâmide de uma imagem de radar simulada em amplitude, onde o *pixel* da imagem que sofre uma compressão é formado pela média de quatro *pixels* da imagem que está sendo comprimida. Partindo da imagem no nível três e fazendo somente o processo inverso de descompressão, a informação perdida não pode ser mais recuperada. Mas a idéia é fazer a segmentação na imagem no nível três, fazer uma descompressão na imagem segmentada e usar as regiões da segmentação no nível três para continuar segmentando, agora sobre a imagem do nível 2, e não sobre a imagem resultante da descompressão do nível 3.

3.2.2.2 Representação por *Quad Tree*

O *quad tree* é uma estrutura de dados hierárquica que fornece um rápido acesso aos dados, no sentido de recuperação dos mesmos. O *quad tree* é baseado no princípio de decomposição recursiva da imagem. Cada decomposição produz quatro quadrantes de tamanhos iguais. Se a imagem quadrada $N \times N$ tem dimensões que são potência de 2 ($N = 2^n$), então todas as regiões produzidas são quadradas tendo dimensões $M \times M$, onde M é uma potência de 2 dado por: $M = 2^m$, $m \leq n$. (Chang, 1989; Pitas, 2000). Um exemplo da representação de uma estrutura *quad tree* pode ser visto na Figura 3.3.

O *quad tree* contém três tipos de nós: brancos, pretos e cinzas. Estes nós são obtidos por divisões recursivas na imagem, onde cada região na imagem é dividida em quatro sub-regiões de tamanhos idênticos. Os nós pretos indicam que o quadrante pertence a um objeto, os nós cinza representam nós sem folhas que requerem futuras subdivisões, caso contrário os nós são brancos (Jain et al., 1995; Jähne, 1997).




FIGURA 3.2 – Perda de informação numa imagem degradada de resolução através da representação piramidal.




FIGURA 3.3 – Representação espacial do *quad tree*.

3.2.3 Representação Simbólica

A representação de regiões usando características simbólicas é uma outra forma de se trabalhar com imagens em formato digital. Outras características como média e variância da intensidade dos valores dos *pixels*, que não são representações simbólicas, também são comumente utilizadas para representar regiões em uma imagem. A representação de uma imagem para interpretação pode requerer a representação da relação de vizinhança entre regiões.

3.3 Técnicas de Segmentação de Imagens

As técnicas empregadas para a segmentação automática de imagens podem ser agrupadas em três categorias principais: ajuste de regiões (*region fitting*), crescimento de regiões (*region growing*) e detecção de bordas (*edge detection*) (White, 1986).

3.3.1 Ajuste de Regiões

A técnica de ajuste de regiões consiste na tentativa de ajustar um padrão para cada porção da imagem, sendo a divisão e o agrupamento de regiões (*split and merge*) uma técnicas simples de ser implementada, e opera agrupando regiões adjacentes que sejam similares ou dividindo as regiões que não sejam homogêneas (Jain et al., 1995).

A aplicação desta técnica em imagens *SAR* requer que o tamanho das janelas que irá dividir a imagem seja suficientemente grande para permitir a identificação de descontinuidades provocadas pelo ruído *speckle* (White, 1986). De modo geral a principal limitação no uso desta técnica é o uso de janelas com tamanho fixo, não permitindo um ajuste do tamanho da janela às características de descontinuidade da imagem.

3.3.2 Crescimento de Regiões

Esta técnica busca a identificação direta de regiões, através do agrupamento de *pixels* e regiões, para formar regiões maiores. O agrupamento é feito usando critérios de similaridade entre as regiões vizinhas. Como exemplo de critério de similaridade, pode-se citar o uso da média das regiões.

A utilização de um critério fixo ou valor de similaridade, seja para unir pares de regiões ou um *pixel* a uma região, é tido como um dos problemas no uso desta técnica. Ao se estabelecer um limiar muito baixo, podem-se gerar pequenos segmentos principalmente nas regiões de fronteira entre classes. Já, ao se usar um limiar muito alto, pequenas regiões podem vir a ser agrupadas em regiões maiores, e com isso podem ser eliminadas

regiões que representem feições distintas.

A aplicação da técnica de crescimento de regiões em imagens *SAR* não restringe o tamanho nem a forma dos segmentos gerados no processo, mas apresenta como principal limitante a escolha de parâmetros de similaridade que sirvam para diferentes imagens. O segmentador *MUM* é um exemplo clássico do uso dessa técnica para dados *SAR* (Cook et al., 1994). O segmentador *MUM* foi desenvolvido com o objetivo de melhorar a segmentação realizada com modelos de manchas (*cartoon*), o qual decompõe a imagem em conjuntos de regiões nas quais todos os *pixels* dentro de cada região tem *backscatter* constante (Oliver e Quegan, 1998).

O modelo de manchas mostra baixa eficiência para representar mudanças graduais e feições lineares, mas apresenta-se muito eficiente na segmentação de regiões limitadas por bordas abruptas (Caves et al., 1998). O uso de uma modelagem estatística adequada para dados neste tipo de modelo pode trazer ganhos no processo de segmentação. Com o uso da compressão, o crescimento da região se torna mais eficiente, pois as regiões ficam mais homogêneas.

O uso de métodos hierárquicos para a segmentação por crescimento de regiões de imagens multiespectrais e hiperespectrais pode ser encontrado nos trabalhos de (Tilton, 1999; Tilton e Lawrence, 2000).

Beaulieu e Touzi (2002) utilizam métodos hierárquicos *stepwise* para segmentar 580 imagens *SAR* polarimétricas com 1-look, e usam como critério de teste para as regiões adjacentes os valores das matrizes de covariância; a princípio se faz um crescimento de regiões para formar pequenos segmentos, que posteriormente passarão a formar regiões maiores.

3.3.3 Detecção de Bordas

A técnica de detecção de bordas consiste em encontrar limites entre regiões com características homogêneas. Para esta detecção, faz-se uso de operadores específicos que realcem as bordas antes de iniciar o processo de segmentação. Uma borda pode ser definida como o limite entre duas regiões e é expressa pela diferença entre níveis de cinza, sua detecção é feita automaticamente por operadores de gradiente (Haralick e Shapiro, 1992).

A representação por pirâmide é um método hierárquico que pode ser usado para detecção de bordas. Esse método combina a detecção de borda usual com uma sofisticada detecção de bordas em diferentes níveis (Chang, 1989). Exemplos da aplicação de detecção de

bordas para imagens *SAR* podem ser encontrados em Frost et al. (1982) e White (1986).

3.4 Avaliação da Segmentação

O resultado de uma segmentação muitas vezes não coincide com o que a percepção humana aceitaria como boa, mas o quão bom é o resultado depende muito do uso e da aplicação que se vai fazer da segmentação (Mezaris et al., 2003).

A avaliação sobre a imagem segmentada por ser qualitativa ou quantitativa. A avaliação qualitativa permite uma inspeção visual com questões relativas ao número de polígonos gerados, a coerência das bordas entre regiões, e a preservação de feições lineares e alvos isolados. Já, a avaliação quantitativa, permite mensurar características dos segmentos gerados, tais como: o número de segmentos, os valores médios dos mesmos, o tamanho, entre outros.

Segundo Zhang (1996), os algoritmos de segmentação podem ser avaliados por métodos analíticos ou métodos empíricos. Os métodos analíticos examinam diretamente o algoritmo de segmentação analisando seus princípios e suas propriedades, e a aplicação desse método é independente da natureza da segmentação. Os métodos empíricos julgam indiretamente o algoritmo de segmentação aplicando imagens de teste e medindo a qualidade do resultado da segmentação.

Os métodos empíricos podem ainda ser classificados como: métodos de qualidade e métodos de discrepância. No primeiro, a avaliação é feita com base em propriedades desejáveis na segmentação seguindo freqüentemente a intuição humana. Já o método de discrepância avalia o segmentador através da comparação da segmentação produzida com uma segmentação de referência. As medidas de discrepância tais como: tamanho, forma, posição e valor médio de intensidade dos segmentos, indicam o quanto o algoritmo é preciso e eficiente (Zhang, 1996).

Segundo Min et al. (2004), dado $P(r)$ um predicado que assume os valores verdadeiro ou falso, uma segmentação de uma imagem R com as regiões $r_1, \dots, r_n$ é definida pelas seguintes propriedades:

- a) $r_1 \cup r_2 \cup \dots \cup r_n = R$. A união de todas as regiões tem que ser igual a imagem.
- b) Cada região está espacialmente conectada.
- c) $\forall r_i, r_j \in R$, tal que $i \neq j$, $r_i \cap r_j = \emptyset$. As regiões são disjuntas.
- d) $\forall r_i \in R$ $P(r_i) = \text{verdade}$. Todos os *pixels* de uma região satisfazem o critério

de similaridade.

- e) $\forall r_i, r_j \in R$ tal que $i \neq j$ and r_i, r_j são conectados e adjacentes, $P(r_i \cup r_j) = \textit{false}$. Então as regiões representam diferentes superfícies.

O primeiro passo no processo de avaliar a qualidade de uma segmentação produzida por um algoritmo, é comparar as regiões resultantes de uma segmentação com regiões de uma imagem de referência, através da comparação de pares de elementos (Delves et al., 1992). Este procedimento é descrito abaixo, utilizando a notação de LUCCA (1998).

Seja $S = \{1, \dots, l\} \times \{1, \dots, c\}$ uma grade retangular, onde l é o número de linhas e c é o número de colunas. Uma imagem monoespectral é uma função $f : S \rightarrow \mathbb{R}$, definida sobre o suporte S . Cada *pixel* desta imagem poder ser representado pelo par $\{s, f(s)\}$, onde s representa a coordenada contida na grade suporte e $f(s)$ é o valor (v_i) da imagem na coordenada s . Logo a imagem pode ser representada pela função $f : S \rightarrow \{v_1, v_2, \dots, v_p\}$.

Uma segmentação é uma função $g : S \rightarrow \{r_1, r_2, \dots, r_k\}$ que a cada coordenada de S associa uma região (r_i). Para expressar grandezas de uma região r_i de uma segmentação g , deve-se determinar o conjunto de coordenadas que g atribui a r_i , ou seja, definir o conjunto $\{s \in S : g(s) = r_i\}$, que é determinado pela função inversa de g sobre as partes de S , denotada por $g^{-1}(r_i)$.

O centro geométrico $\bar{g}^{-1}(r_i)$ e a intensidade média $< r_i >$ de uma região r_i da segmentação g de uma imagem f são dados por:

$$\bar{g}^{-1}(r_i) = \frac{1}{\#g^{-1}(r_i)} \left(\sum_{s \in g^{-1}(r_i)} s \right) = [(\bar{g}^{-1}(r_i))_x, (\bar{g}^{-1}(r_i))_y] \quad (3.1)$$

$$< r_i > = \frac{1}{\#g^{-1}(r_i)} \sum_{s \in g^{-1}(r_i)} f(s) \quad (3.2)$$

onde $(\bar{g}^{-1}(u))_x$, $(\bar{g}^{-1}(u))_y$, representam, respectivamente, a média das abcissas e a média das ordenadas da região u , ou seja o centro geométrico, enquanto que $\#g^{-1}(u)$, representa o número de *pixels* dos valores radiométricos na região u .

O processo de comparação está baseado no ajuste de regiões, que é obtido pelo processo de sobreposição das imagens. Considere $g_1 : S \rightarrow \{r_1, r_2, \dots, r_k\}$ e $g_2 : S \rightarrow \{m_1, m_2, \dots, m_q\}$ duas segmentações de uma mesma imagem $f : S \rightarrow \mathbb{R}$, onde g_1 e g_2 têm a mesma dimensão. Suponha que g_1 é a segmentação de referência e que g_2 é a segmentação produzida pelo algoritmo de segmentação. O processo de ajuste é feito de

forma que para cada região de g_1 tenha uma região g_2 que melhor a represente.

Os critérios que medem o ajuste entre as regiões são de posicionamento (X, Y), número de *pixels*, de intensidade média e de forma das regiões. A definição dos pares de regiões ajustadas pode ser obtida a partir das matrizes de forma (Gf) e de posição (Fit), que são obtidas por:

$$Gf(r_i, m_j) = \frac{\#g^{-1}(r_i \cap m_j)}{\#g^{-1}(r_i \cup m_j)} \quad (3.3)$$

e

$$Fit(r_i, m_j) = \frac{\left[xd(r_i, m_j) + yd(r_i, m_j) + \left(\frac{pd(r_i, m_j) + id(r_i, m_j)}{2} \right) \right]}{Gf(r_i, m_j)} \quad (3.4)$$

sendo r_i a i -ésima região na segmentação g_1 , m_j a j -ésima região na segmentação g_2 . onde:

$$xd(r_i, m_j) = \frac{|\left[\bar{g}_1^{-1}(r_i) \right]_x - \left[\bar{g}_2^{-1}(m_j) \right]_x|}{c}, \quad (3.5)$$

$$yd(r_i, m_j) = \frac{|\left[\bar{g}_1^{-1}(r_i) \right]_y - \left[\bar{g}_2^{-1}(m_j) \right]_y|}{l}, \quad (3.6)$$

$$pd(r_i, m_j) = \frac{|\#g_1^{-1}(r_i) - \#g_2^{-1}(m_j)|}{\#g_1^{-1}(r_i) + \#g_2^{-1}(m_j)}, \quad (3.7)$$

e

$$id(r_i, m_j) = \frac{|\langle r_i \rangle - \langle m_j \rangle|}{\langle r_i \rangle + \langle m_j \rangle}, \quad (3.8)$$

com $i = 1, \dots, k$ e $j = 1, \dots, q$.

Os valores dos elementos da matriz de posição (Gf) indicam se há ou não sobreposição entre os pares de regiões (r_i, m_j) formados. Valores iguais a 1 na matriz indicam uma sobreposição perfeita, ou seja, as regiões são iguais, enquanto valores iguais a zero indicam que não há intercessão entre as regiões, ou seja, as regiões são disjuntas.

Já os valores da matriz de posição (Fit) envolvem medidas de posicionamento no plano XY (xd e yd), de intensidade média (id) e de tamanho (pd) das regiões comparadas. Para cada região r_i na segmentação de referência, define-se como a sua região ajustada correspondente m_j como aquela que possuir o menor valor na linha i da matriz $Fit(r_i, m_j)$.

Após definir as regiões que melhor se ajustaram às regiões da imagem de referência, faz-se a avaliação da qualidade do ajuste através de medidas de qualidade, as quais permitem avaliar a segmentação como um todo a partir da qualidade individual de ajuste de cada região. As medidas de ajuste de posição, ajuste de intensidade, ajuste de tamanho e ajuste da forma, descritas em Delves et al. (1992), são as medidas utilizadas para quantificar a qualidade da segmentação. Essas medidas são obtidas por:

Ajuste de posição

$$Fit_{xy}(r_i, m_j) = 1 - \frac{xd(r_i, m_j) + yd(r_i, m_j)}{2} \quad (3.9)$$

Ajuste de intensidade

$$Fit_i(r_i, m_j) = 1 - \frac{|\langle r_i \rangle - \langle m_j \rangle|}{\langle r_i \rangle + \langle m_j \rangle} \quad (3.10)$$

Ajuste de tamanho

$$Fit_t(r_i, m_j) = 1 - \frac{|\#g_1^{-1}(r_i) - \#g_2^{-1}(m_j)|}{\#g_1^{-1}(r_i) + \#g_2^{-1}(m_j)} \quad (3.11)$$

Ajuste da forma

$$Gf(r_i, m_j) = \frac{\#g^{-1}(r_i \cap m_j)}{\#g^{-1}(r_i \cup m_j)} \quad (3.12)$$

Os valores obtidos nas medidas descritas acima estão padronizados no intervalo $[0, 1]$, onde o valor 1 representa o ajuste perfeito. Para quantificar uma segmentação a partir de um único valor toma-se a média dos valores destas medidas, a qual é denominada média geral.

CAPÍTULO 4

O SEGMENTADOR *SegSAR*

Este capítulo apresenta o segmentador denominado *SegSAR* que foi desenvolvido inicialmente levando-se em conta as propriedades estatísticas dos dados *SAR* no formato intensidade. No decorrer do trabalho, optou-se por considerar também as propriedades estatísticas de dados ópticos, face à simplicidade das adaptações a serem realizadas no algoritmo que tal inclusão acarretaria, assim como pela maior variedade de dados que poderiam ser processados por este segmentador. Desta forma, o *SegSAR* pode ser aplicado tanto a dados *SAR* quanto a dados ópticos.

O *SegSAR* é um segmentador híbrido porque usa técnicas de crescimento de regiões, agrupamento de regiões, ajuste de bordas e separação de regiões não homogêneas (*Split*); é multi-nível uma vez que trabalha em pirâmide hierárquica; multi-bandas pois pode-se ter várias imagens como entrada fornecendo informação para a segmentação e hierárquico já que usa informações de um nível para a segmentação da imagem no outro nível.

O *SegSAR* foi implementado em *Interactive Data Language (IDL)* e utiliza algumas funcionalidades do ambiente ENVI (*The Environment for Visualizing Images*). Na Figura 4.1 são mostradas as interfaces para o modelo de manchas e de textura para imagens de radar, e a Figura 4.2 corresponde à interface para imagens ópticas que contem os campos de entrada de dados: *Loaded Images*, *Levels*, *Image Model Representation*, *Image Type*, *Parameters of Segmentation*, *Image of Segmentation* e *Image Format*, que podem ser alterados pelo usuário dependendo da imagem de entrada. Estes campos de entrada são descritos a seguir.

O primeiro passo no processo de segmentação é a escolha da imagem ou do conjunto de imagens que será segmentada. Isto é feito através do botão *Input Image* da interface principal. Este botão ao ser acionado apresenta uma interface do ENVI que permite ao usuário selecionar as imagens a serem segmentadas (Figura 4.3). A partir do botão *Spatial Subset* presente nesta janela de seleção de imagens de entrada é facultado ao usuário definir apenas uma região da imagem a qual deseja segmentar.




FIGURA 4.1 – Interface principal do segmentador *SegSAR* ilustrando os campos de entrada de dados, para imagens de radar, usando os modelos de manchas (a) e de textura (b).

As imagens selecionadas aparecem listadas no campo *Loaded Images*; sempre a primeira imagem aparecerá selecionada e cabe ao usuário escolher uma outra imagem ou imagens, caso queira fazer uma segmentação multi-banda. Logo abaixo da lista com as imagens selecionadas podem ser vistos os números de linhas e colunas da imagem original, o número máximo de níveis de compressão (*Levels*) que será utilizado na segmentação e à direita deste, os números de linhas e colunas da imagem resultante desta compressão. O processo de segmentação sempre será iniciado na imagem comprimida com o valor determinado no campo *Levels*. O usuário pode modificar o número máximo de níveis de compressão, alterando o valor do campo *Levels*. Este parâmetro está relacionado à característica piramidal empregada no segmentador.

O próximo item a ser selecionado é o que define qual o modelo de representação que será usado no processo de segmentação (*Image Model Representation*). A segmentação pode ser feita usando o modelo de manchas (*Cartoon*) no qual supõe, para imagens de radar, que cada região possui um *backscatter* constante, ou o modelo de textura (*Texture*),




FIGURA 4.2 – Interface do segmentador *SegSAR* no caso de imagem de ópticas.

onde se supõe que existe uma variação interna no *backscatter* dentro de cada região. Este último modelo é mais apropriado para imagens que apresentem alvos não homogêneos, pois leva em consideração esta variabilidade interna do *backscatter*. O uso do modelo de manchas para imagens ópticas supõe que a variância das regiões é a mesma para todas as regiões da imagem, já o modelo de textura faz uso das variâncias das regiões para fazer a segmentação.

Uma vez definido o modelo de representação, o item a ser selecionado é o *Image Type*, o qual define se a imagem provém de um sensor de radar ou de um sensor óptico. Dependendo da opção escolhida pelo usuário, a interface pode ser a da Figura 4.1 para permitir a entrada dos parâmetros da segmentação para imagens de radar ou a da Figura 4.2 para a entrada dos parâmetros da segmentação para imagens ópticas.

Os parâmetros do campo de entrada *Segmentation Parameters* estão relacionados diretamente com a maioria dos testes estatísticos que são realizados no processo de segmentação e devem ser definidos pelo usuário. O conjunto de parâmetros da segmentação variará de acordo com o tipo de entrada (radar ou óptica) e o seu modelo de representação (manchas ou textura), os quais são listados na Tabela 4.1 e mostrados nas




FIGURA 4.3 – Interface do ENVI para selecionar imagens de entrada para o programa de segmentação *SegSAR*.

interfaces das Figuras 4.1 e 4.2. Os parâmetros similaridade (*Similarity*) e área mínima (*Minimum Area*) estão presentes em todos os conjuntos de parâmetros. Entretanto o valor do parâmetro similaridade será expresso em decibéis (*db*) ou em níveis de cinza, respectivamente, se a imagem de entrada for proveniente de um sensor de radar ou de um sensor óptico. Os parâmetros número equivalente de *looks* (*ENL*) e o nível de confiança (*Conf(%)*) fazem parte do conjunto de parâmetros para imagens de radar representada pelo modelo de manchas, os quais são substituídos pelo coeficiente de variação (*CV*) quando o modelo de textura é usado para representar a imagem de radar. No caso de imagem óptica representada através do modelo de manchas ou do modelo de textura, o nível de confiança (*Conf(%)*) e o coeficiente de variação (*CV*) integram o conjunto de parâmetros da segmentação. A descrição desses parâmetros e suas funcionalidades é feita na Seção 4.1.1, onde se aborda a primeira etapa do processo de segmentação.

Após definido os parâmetros da segmentação, o item seguinte é o *Image for Segmentation* o qual permite determinar se a segmentação será feita sobre as imagens selecionadas ou somente sobre as componentes principais do conjunto de imagens. Caso se decida usar componentes principais o usuário deve indicar quais componentes deverão ser segmentadas. O programa usa a informação de todas as bandas selecionadas para fazer a segmentação, onde uma região será formada quando a informação de todas as imagens satisfizer os critérios definidos no processo de segmentação, os quais estão descritos nas Seções 4.1.3 e 4.3.

TABELA 4.1 – Conjunto de parâmetros de segmentação para cada tipo de imagem de entrada representada pelos diferentes modelos.

Tipo de Imagem	Representação da Imagem	Conjunto de Parâmetros
Radar	modelo de manchas	Similarity(dB), Min. Area, ENL e Conf(%)
	modelo de textura	Similarity(dB), Min. Area, e CV
Óptico	modelo de manchas	Similarity, Min. Area, Conf(%) e CV
	modelo de textura	Similarity, Min. Area, Conf(%) e CV

O campo *Image Format* é específico para imagens de radar e permitem definir os formatos das imagens de entrada, os quais podem ser em amplitude, intensidade ou em *dB*. Na seleção de imagens ópticas este campo é desabilitado, não permitindo ao usuário fazer esta seleção.

O tipo de compressão utilizado pelo *SegSAR* é a compressão piramidal, a qual permite diminuir a dimensionalidade dos dados. Nas imagens de radar isso implica na diminuição do ruído *speckle* deixando as distribuições dos dados mais próximas de uma distribuição Gaussiana, o que justifica o uso de teste que pressupõem normalidade para esses dados. Quanto mais níveis de compressão forem aplicados à imagem de radar, mais a distribuição dos dados vai tender para uma distribuição Normal e mais eficiente serão os testes de crescimento e agrupamento de regiões utilizados, os quais supõem normalidade dos dados.

Quando termina o processo de segmentação no nível de compressão C ($C = 1, \dots, N$), a imagem segmentada neste nível sofre uma descompressão passando a ter o dobro de linhas e colunas e as regiões contidas na imagem segmentada são associadas à imagem do nível $C - 1$. Para imagens de radar, a influência do ruído *speckle* é maior a cada descompressão e os testes para crescimento e agrupamento de regiões terão menor eficiência. Entretanto, à medida que isso ocorre as regiões presentes na imagem já são suficientemente grandes, o que pode vir compensar essa perda de eficiência dos testes.

No processo de segmentação, uma região é formada quando os critérios da segmentação definidos pelo usuário são satisfeitas; no caso de imagens multibandas uma região é formada se os critérios da segmentação forem satisfeitos em todas as bandas.

No modelo de textura, a cada descompressão o coeficiente de variação (*cv*) das regiões tende a aumentar. Se as regiões não forem homogêneas esse valor de *cv* tende a aumentar ainda mais. Através de testes de homogeneidade, descritos na Seção 4.3.2, se a região for

considerada heterogênea ela será resegmentada.

Com o intuito de explicar o funcionamento do programa *SegSAR*, o processo de segmentação foi dividido em quatro etapas. Na Figura 4.4 é ilustrado o fluxograma do processo de segmentação de imagens do *SegSAR* com cada uma das etapas.




FIGURA 4.4 – Fluxograma do processo de segmentação de imagens com o *SegSAR*.

4.1 Primeira Etapa

A primeira etapa está dividida em três blocos: entrada dos dados, compressão dos dados e segmentação por crescimento de regiões sobre a imagem com maior compressão (Figura 4.5).

4.1.1 Entrada de Dados

No processo de segmentação do *SegSAR*, a imagem a ser segmentada (imagem de entrada) pode ser representada através do modelo de manchas (também conhecido como modelo *cartoon*) ou do modelo de textura. As características estatísticas da imagem de entrada determinarão qual dos modelos a representará mais adequadamente. Isto é, o modelo de manchas será mais apropriado às imagens formadas por regiões homogêneas, enquanto o modelo de textura será mais adequado às imagens que possuem regiões heterogêneas. Desta forma, torna-se evidente que os resultados da segmentação serão




FIGURA 4.5 – Fluxograma da primeira etapa do processo de segmentação.

fortemente influenciados pelo tipo de modelo adotado para representar a imagem de entrada.

Os dados de entrada podem ser imagens de radar ou ópticas, em uma banda ou multi-bandas, em 8, 16 ou 32 bits. No caso de imagens multi-bandas, existe a possibilidade de aplicar componentes principais sobre o conjunto de bandas e selecionar quais componentes serão utilizadas no processo de segmentação. O uso de componentes principais é feito quando se quer diminuir a quantidade de imagens no processo de segmentação sem deixar, contudo, de usar a informação contida nessas imagens. Esta técnica permite reduzir a dimensionalidade dos dados, fazendo com que uma única banda contenha grande parte da informação de todas as imagens envolvidas no processo.

O processamento das imagens de radar é feito em intensidade; caso o formato da imagem de entrada seja amplitude ou em dB , a mesma é convertida para intensidade. Para começar o processo de segmentação em imagens de radar são necessários alguns parâmetros de entrada:

- a) *Levels* - Este parâmetro (representado por N neste trabalho) define o número máximo de níveis de compressão a que a imagem será submetida antes de começar o processo de segmentação. Existe uma relação muito forte entre os níveis de compressão e o tamanho dos alvos na imagem original, já que durante a compressão ocorre uma generalização da informação e alvos que são representados por poucos *pixels* tem uma grande probabilidade de não serem detectados quando a imagem é muito comprimida. Por outro lado, quanto mais níveis de compressão tiver, menor é o efeito do ruído *speckle* e o resultado da segmentação neste nível tende a ser melhor.

Na representação da imagem através do modelo de manchas, as suas regiões são consideradas como homogêneas. Para dados no formato intensidade, isto

implica que os dados podem ser modelados através de uma distribuição Gama (modelo multiplicativo) (Frery et al., 1995). Neste caso, os dados terão uma distribuição Gama, denotado por $\Gamma(n, n/\mu)$, a qual é o resultado do produto entre uma distribuição Constante $\mathcal{C}(\mu)$ representando o *backscatter*, e uma distribuição Gama $\Gamma(n, n)$ representando o ruído *speckle*, como apresentado no Capítulo 2. O parâmetro n representa o número equivalente de *looks*¹ (*nel*) dos dados enquanto que o parâmetro μ é a intensidade média dos dados. Em Yanasse et al. (1995) é demonstrado que, para um valor de n suficientemente grande, a distribuição Gama $\Gamma(n, n)$ aproxima-se de uma distribuição Normal (Figura 4.6).




FIGURA 4.6 – Distribuições $\Gamma(n, n)$ para diferentes valores de n .
FONTE: Modificada de Yanasse et al. (1995).

Como pode ser visto na Figura 4.6, para valores de n igual a 1 ocorre um caso particular da distribuição Gama que é a distribuição Exponencial. Para $n \geq 2$ se tem uma distribuição Gama a dois parâmetros, mas pode-se verificar que para $n \geq 8$ a distribuição Gama se aproxima de uma distribuição Normal.

O número de níveis que se deve comprimir uma imagem de radar para que se

¹Número equivalente de *looks* (*nel*) equivale ao número de *pixels* que deve ser somado, de modo a se obter a mesma quantidade de informação que a soma dos *pixels* da imagem original, que apresentam informação redundante. Desta forma, o *nel* é sempre menor ou igual ao número de *looks* de uma imagem e é único para toda a imagem.

possa aproximar uma distribuição Gama por uma distribuição Normal será dependente do número de *looks* desta imagem original. Isto porque o número equivalente de *looks* das imagens em cada nível de compressão é função do número de *looks* da imagem de entrada (no nível *zero*), da quantidade de *pixels* da imagem original usada na geração de um dado *pixel* no nível seguinte, e de uma somatória de autocorrelações da imagem de entrada. Isto é melhor detalhado na Seção 4.1.2.

- b) *Similarity (dB)* - Este parâmetro de similaridade, denotado por $Simil_{dB}$ no decorrer desta tese, é fornecido pelo usuário em decibéis, e define o limiar de similaridade para os testes de crescimento e agrupamento de regiões. Este valor é alterado automaticamente a cada nível de compressão C ($C = 1, \dots, N$), como descrito na Seção 4.1.2, e será denotado no que se segue por $Simil_C$. O valor de similaridade *default* sugerido ao usuário é de 1 *dB*, o que significa que duas regiões serão consideradas similares se a diferença entre as suas médias, calculadas em *dB*, não exceder a 1 *dB*.

Sejam, então duas regiões r_A e r_B , com intensidade médias dadas por $\bar{X}_{r_A}$ e $\bar{X}_{r_B}$ respectivamente, possuindo uma diferença entre as médias de 1 *dB*, então:

$$10\log_{10}\bar{X}_{r_A} - 10\log_{10}\bar{X}_{r_B} = 1$$

ou

$$\log_{10}\frac{\bar{X}_{r_A}}{\bar{X}_{r_B}} = 0,1$$

o que acarreta em $\bar{X}_{r_A} = \bar{X}_{r_B} \cdot 10^{0,1}$, portanto a diferença entre $\bar{X}_{r_A}$ e $\bar{X}_{r_B}$, em intensidade, pode ser expressa por:

$$\bar{X}_{r_A} - \bar{X}_{r_B} = \bar{X}_{r_B} (10^{0,1} - 1) \cong 0,26 \cdot \bar{X}_{r_B}$$

implicando em uma diferença entre as intensidades médias de r_A e r_B de aproximadamente 26% da intensidade média de r_B . Desta forma, pode se dizer que duas regiões são similares se a intensidade média de uma não ultrapassar a aproximadamente 26% da intensidade média da outra. Cabe ressaltar que não foi realizado nenhum estudo exaustivo para definir qual o melhor valor do parâmetro para similaridade, mas nas diferentes segmentações realizadas o valor de 1*dB* apresentou-se como sendo um bom valor para iniciar a segmentação.

O valor de similaridade, em intensidade, no nível zero é, então, calculado por:

$$Simil_0 = \bar{X}_I \left(10^{\frac{Simil_{dB}}{10}} - 1 \right) \quad (4.1)$$

onde $\bar{X}_I$ é a média da imagem no nível inicial (nível *zero*).

- c) *Conf*(%) - Nível de confiança utilizado para os testes de crescimento, homogeneidade e agrupamento de regiões, descritos nas Seções 4.1.3.2, 4.3.2 e 4.3.3. Este parâmetro é denotado por $(1 - \vartheta)$ no decorrer deste trabalho. É permitido ao usuário escolher os níveis de 99,9%, 99,5%, 99%, 95%, 90%, 85%, e 80%, sendo o *default* o valor de 95%.
- d) *ENL* - O número equivalente de *looks*, denotado por *nel* é uma informação importante pois, como é mostrado no restante deste trabalho, vários testes utilizados para segmentar a imagem sob a hipótese do modelo de manchas fazem uso deste parâmetro. O *nel* é comumente estimado através de regiões homogêneas em dados de intensidade, considerando as propriedades estatísticas da distribuição Gama (VIEIRA, 1996). O valor de *nel* fornecido pelo usuário refere-se ao número equivalente de *looks* da imagem original. Posteriormente, ele é recalculado automaticamente a cada nível de compressão C , como será descrito na Seção 4.1.2, e denominado nel_C .
- e) *CV* - O coeficiente de variação é um parâmetro de entrada que é usado quando se adota o modelo de textura. Este valor, denotado por $cv_{crítico}$ no decorrer deste trabalho, é usado nos testes para segmentar a imagem sob a hipótese do modelo de textura. O usuário deve fornecer o valor do $cv_{crítico}$ que será usado nos testes da imagem original (nível *zero*). Este valor é recalculado automaticamente a cada nível de compressão C , como será descrito na Seção 4.1.2, e denominado $(cv_{crítico})_C$. O valor *default* adotado para o *CV* é de 0,6, podendo ser alterado pelo usuário.
- f) *Minimum Area* - Indica o tamanho mínimo em *pixels* que devem ter as regiões na segmentação final. Este parâmetro é muito útil quando se conhece o tamanho dos alvos de interesse na imagem, já que evita que apareçam regiões muito pequenas na segmentação final.

No caso de imagens ópticas, os parâmetros de entrada para o processo de segmentação são:

- a) *Levels* - Este parâmetro define o número de compressões que será aplicado sobre a imagem original. O uso da compressão tem como principal vantagem a diminuição do tempo no início da segmentação, pois no começo do processo de crescimento de regiões a imagem tem o tamanho bem menor que a imagem original.
- b) *Similarity* - É o valor em níveis de cinza (NC) usado como limiar de similaridade nos testes de crescimento de região e agrupamento de regiões. O valor sugerido é igual a 2 desvios padrões da imagem. Este limiar é alterado automaticamente a cada nível de compressão C ($C = 1, \dots, N$), como descrito na Seção 4.1.2, e será denotado no que se segue por $Simil_C$.
- c) *Conf(%)* - Nível de confiança utilizado para os testes de crescimento e agrupamento de regiões descritos nas Seções 4.1.3.3 e 4.3.3. Este parâmetro é denotado por $(1 - \vartheta)$ no decorrer deste trabalho. O valor *default* sugerido pelo programa é de 95%, podendo ser modificado pelo usuário.
- d) *CV* - O coeficiente de variação é utilizado no teste de homogeneidade de regiões. Este valor é denotado por $cv_{crítico}$ no decorrer deste trabalho. O usuário deve fornecer o valor do $cv_{crítico}$ que será usado nos testes da imagem original (nível *zero*). Este valor é recalculado automaticamente a cada nível de compressão C ($C = 1, \dots, N$), como será descrito na Seção 4.1.2, e denominado $(cv_{crítico})_C$. Regiões que apresentarem cv menor que o $(cv_{crítico})_C$ serão consideradas não homogêneas e serão resegmentadas. O programa fornece como valor *default* de *CV* 0,3 para o modelo de manchas e 0,6 para o modelo de textura.
- e) *Minimum Area* - Indica o tamanho mínimo em *pixels* das regiões no último nível da segmentação. Este parâmetro evita o aparecimento de regiões muito pequenas na segmentação resultante.

4.1.2 Compressão

4.1.2.1 O Processo Hierárquico

A compressão dos dados é feita seguindo o critério hierárquico de pirâmide, onde cada nível é representado por uma imagem de médias que tem a metade do número de linhas e colunas da imagem anterior. Isso ocorre porque o *pixel* da imagem que está um nível acima (nível C) é formado pela média de quatro *pixels* da imagem anterior (nível $C - 1$). A base da pirâmide é a imagem original (sem compressão), nível *zero*; no primeiro nível

acima da base está a imagem comprimida em um nível, e assim por diante. A Figura 4.7 exemplifica o processo de compressão de uma imagem original de 16×16 *pixels* em três níveis de compressão ($N = 3$), resultando numa imagem de 2×2 *pixels* no último nível.




FIGURA 4.7 – Pirâmide de compressão com quatro níveis.
FONTE: Modificada de Rosenfeld (1984).

No início do processo de segmentação, a imagem está comprimida em N níveis e cada *pixel* representa a média de 2^{2N} *pixels* da imagem original. Assim, para uma imagem comprimida em três níveis ($C = 3$), tem-se que um *pixel* no nível 1 é formado pela média de $2^{1 \times 2} = 4$ *pixels* da imagem original; para o segundo nível um *pixel* representa $2^{2 \times 2} = 16$ *pixels* da imagem original e finalmente, no terceiro nível um *pixel* corresponde à média de $2^{3 \times 2} = 64$ *pixels* da imagem original.

Rosenfeld (1984) estabelece uma relação entre o número de compressões e o número de linhas e colunas da imagem. Esta relação é dada por:

$$N = \log_2 l \quad (4.2)$$

onde N é o número máximo de compressões da imagem e l corresponde ao menor valor de linhas ou colunas. Assim, para uma compressão em 5 níveis, a imagem de entrada

tem que ter como tamanho mínimo 32 linhas por 32 colunas.

Quando a imagem tem um valor ímpar no número de colunas e/ou de linhas, essa última coluna e/ou linha é duplicada para que ocorra a compressão da imagem. A coluna e/ou linha que é adicionada à imagem é posteriormente eliminada durante a descompressão; para fazer esta correção no número de linhas e colunas se utilizam os valores armazenados na estrutura, onde se pode obter o número de colunas e linhas da imagem em todos os níveis. Por exemplo, uma imagem de 641 colunas por 480 linhas que é submetida a uma compressão de 5 níveis possuirá o tamanho das imagens em cada um dos níveis como mostrado na Tabela 4.2.

TABELA 4.2 – Compressão e descompressão de imagem com 641 colunas por 480 linhas.

	Nível	Colunas	Linhas
Compressão	0	641	480
	1	321	240
	2	161	120
	3	81	60
	4	41	30
	5	21	15
Descompressão	4	41	30
	3	81	60
	2	161	120
	1	321	240
	0	641	480

4.1.2.2 Alteração dos Parâmetros de Entrada a cada Nível de Compressão

Ao se comprimir uma imagem ocorre uma alteração na variância da imagem comprimida em relação a imagem original, e esta variância tende a diminuir a cada compressão. Esta alteração na variância, provocada pela adição de *pixels* a cada compressão, acarreta a necessidade de se adequar alguns parâmetros de entrada para as imagens comprimidas. Assim, os parâmetros de entrada, similaridade, número equivalente de *looks* e coeficiente de variação, são modificados a cada nível. Mostra-se a seguir que a variância em cada nível (σ_C^2) $C = 0, \dots, N$), pode ser estimada em função da variância da imagem no nível *zero* (σ_0^2). Após, descreve-se como os parâmetros de similaridade, número equivalente de *looks* e coeficiente de variação estipulados pelo usuário são recalculados a cada nível de compressão através da relação entre as variâncias nos níveis *zero* e C .

No caso de dados em uma dimensão (série temporal), a variância da média de M valores

com variância (σ_0^2) é dada por (Fishman, 1973):

$$\sigma^2 = \frac{\sigma_0^2}{M} \left[1 + 2 \sum_{s=1}^{M-1} \left(1 - \frac{s}{M} \right) \rho(s) \right] \quad (4.3)$$

onde $\rho(s)$ é a autocorrelação unidimensional de *lag* s . O valor de $\rho(s)$ é geralmente desconhecido e necessita ser estimado. Entretanto, o uso de uma grande quantidade de *lags* na Equação (4.3) fornecerá um estimador muito tendencioso para σ^2 . Na verdade, se o somatório é efetuado até o *lag* $M - 1$, (isto é, usando-se todas as autocorrelações estimadas) pode-se provar que o estimador é igual a zero (Fishman, 1973). Portanto, Fishman (1973) propôs o uso de um estimador truncado, que faz uso das k primeiras autocorrelações estimadas, sendo o mesmo dado por:

$$\hat{\sigma}^2 = \frac{\hat{\sigma}_0^2}{M - k} \left[1 + 2 \sum_{s=1}^k \left(1 - \frac{s}{k} \right) \hat{\rho}(s) \right] \quad (4.4)$$

onde $\hat{\sigma}_0^2$ é variância estimada dos dados iniciais e $\hat{\rho}(s)$ é o estimador unidimensional da autocorrelação de *lag* s . Para um conjunto de valores $x_1, x_2, \dots, x_M$, estes estimadores são calculados por:

$$\hat{\sigma}_0^2 = \frac{1}{M - 1} \sum_{t=1}^M (x_t - \bar{x})^2$$

$$\hat{\rho}(s) = \frac{1}{M} \sum_{t=1}^{M-|s|} (x_t - \bar{x})(x_{t+|s|} - \bar{x})$$

onde $\bar{x}$ é a média dos M valores de x .

No caso desta tese, em que se trabalha com imagens (dados bidimensionais), as Equações (4.3) e (4.4) devem ser adequadamente alteradas usando as autocorrelações bidimensionais $\rho(s_x, s_y)$ de *lags* s_x e s_y . Tem-se também que cada *pixel* no nível de compressão C é formado pela média de M *pixels* no nível *zero*, onde $M = M_x M_y = 2^{2C}$ e $M_x = M_y = 2^C$, com M_x e M_y representando o número de *pixels* nas direções x e y , respectivamente. Na Equação (4.4) é suposto que as autocorrelações são estimadas através do conjunto de *pixels* usados para obter a média. No entanto, no caso do modelo de manchas, onde a autocorrelação é única para toda a imagem, estimadores

melhores para a autocorrelação podem ser obtidos utilizando-se os dados de toda a imagem. Portanto, nesta tese, optou-se por se utilizar um estimador que fizesse uso de apenas algumas autocorrelações estimadas, mas ao mesmo tempo que elas fossem ponderadas pelo número exato de *pixels* utilizados na formação do *pixel* do nível de compressão C . Assim, utilizou-se o seguinte estimador da variância dos dados no nível de compressão C ($\hat{\sigma}_C^2$), baseado no estimador da variância dos dados no nível *zero* ($\hat{\sigma}_0^2$), e nas autocorrelações estimadas $\hat{\rho}(s_x, s_y)$ para os *lags* s_x e s_y até os *lags* k_x e k_y ,

$$\hat{\sigma}_C^2 = \frac{\hat{\sigma}_0^2}{M} \left[1 + 2 \sum_{s_x=1}^{k_x} \sum_{s_y=1}^{k_y} \left(1 - \frac{s_x}{M_x} \right) \left(1 - \frac{s_y}{M_y} \right) \hat{\rho}(s_x, s_y) \right] \quad (4.5)$$

onde $M_x = M_y = 2^C$ são os números de *pixels* nas direções x e y , respectivamente, do nível *zero* que foram utilizados para calcular o *pixel* no nível C e $M = 2^{2C}$.

Além disso, optou-se por utilizar somente as correlações de *lags* $(1, 0)$, $(0, 1)$ e $(1, 1)$, uma vez que para o nível $C = 1$ o número máximo de *lags* para calcular a autocorrelação é igual a 1 nas duas direções. Assim, a razão entre as variâncias estimadas nos níveis C e *zero* passa a ser obtida por:

$$\begin{aligned} \frac{\hat{\sigma}_C^2}{\hat{\sigma}_0^2} &= \frac{1}{2^{2C}} \left\{ 1 + 2 \left[\left(1 - \frac{1}{2^C} \right) \hat{\rho}(0, 1) + \left(1 - \frac{1}{2^C} \right) \hat{\rho}(1, 0) + \left(1 - \frac{1}{2^C} \right)^2 \hat{\rho}(1, 1) \right] \right\} \\ &= \frac{1}{2^{2C}} \left\{ 1 + 2 \left(1 - \frac{1}{2^C} \right) \left[\hat{\rho}(0, 1) + \hat{\rho}(1, 0) + \left(1 - \frac{1}{2^C} \right) \hat{\rho}(1, 1) \right] \right\} \end{aligned} \quad (4.6)$$

onde C é o nível de compressão, $\hat{\rho}(0, 1)$ é o estimador da autocorrelação de *lag* 1 em y , $\hat{\rho}(1, 0)$ é o estimador da autocorrelação de *lag* 1 em x , e $\hat{\rho}(1, 1)$ é o estimador da autocorrelação de *lag* 1 em x e y , todos obtidos a partir da imagem original (nível *zero*). O termo à direita da Equação (4.6) será um número real entre 0 e 1, sempre que as autocorrelações estimadas de *lag* $(1, 0)$, $(0, 1)$ e $(1, 1)$ forem positivas.

A partir desta razão de variâncias (Equação 4.6), os parâmetros de similaridade, número equivalente de *looks* e coeficiente de variação são recalculados a cada nível C , a partir dos parâmetros iniciais do nível *zero*.

O cálculo da similaridade para cada nível de compressão é dado por:

$$Simil_C = Simil_0 \frac{\hat{\sigma}_C^2}{\hat{\sigma}_0^2}$$

$$Simil_C = \frac{Simil_0}{2^{2C}} \left\{ 1 + 2 \left(1 - \frac{1}{2^C} \right) \left[\hat{\rho}(0,1) + \hat{\rho}(1,0) + \left(1 - \frac{1}{2^C} \right) \hat{\rho}(1,1) \right] \right\}, \quad (4.7)$$

onde $Simil_0$ é dado pela Equação (4.1). Assim, para cada compressão se tem um valor de similaridade diferente, sendo que este valor diminui a medida que C aumenta.

A alteração no coeficiente de variação crítico é feita através da razão entre variâncias. Lembrando que, para uma mesma região nos níveis *zero* e C , a razão entre os coeficientes de variação é dada pela razão entre os desvios padrões, já que a média da região é a mesma nos níveis *zero* e C , então

$$\begin{aligned} \frac{\hat{cv}_C^2}{\hat{cv}_0^2} &= \frac{\hat{\sigma}_C^2}{\hat{\sigma}_0^2} \\ \hat{cv}_C^2 &= \frac{\hat{cv}_0^2}{2^{2C}} \left\{ 1 + 2 \left(1 - \frac{1}{2^C} \right) \left[\hat{\rho}(0,1) + \hat{\rho}(1,0) + \left(1 - \frac{1}{2^C} \right) \hat{\rho}(1,1) \right] \right\} \\ \hat{cv}_C &= \frac{\hat{cv}_0}{2^C} \sqrt{\left\{ 1 + 2 \left(1 - \frac{1}{2^C} \right) \left[\hat{\rho}(0,1) + \hat{\rho}(1,0) + \left(1 - \frac{1}{2^C} \right) \hat{\rho}(1,1) \right] \right\}} \end{aligned} \quad (4.8)$$

Portanto, o $cv_{crítico}$, necessário para o modelo de textura, é recalculado a cada nível usando a mesma relação apresentada na Equação (4.8):

$$(cv_{crítico})_C = \frac{(cv_{crítico})_0}{2^C} \sqrt{\left\{ 1 + 2 \left(1 - \frac{1}{2^C} \right) \left[\hat{\rho}(0,1) + \hat{\rho}(1,0) + \left(1 - \frac{1}{2^C} \right) \hat{\rho}(1,1) \right] \right\}} \quad (4.9)$$

onde $(cv_{crítico})_C$ é o valor do coeficiente de variação no nível C ($C = 0, \dots, N$), $(cv_{crítico})_0$ corresponde ao valor do cv crítico fornecido pelo usuário no nível *zero* (imagem de entrada), e C é o nível de compressão. Da mesma maneira que a similaridade, o $cv_{crítico}$ tende a diminuir a cada nível de compressão.

Quando se adota o modelo de manchas para imagens de radar, é necessário modificar também o número equivalente de *looks* a cada compressão. O modelo de manchas pressupõe que os dados de cada região possuem uma distribuição Gama $\Gamma(nel, nel/\mu)$, onde μ é a média em intensidade da região. Para esta distribuição, tem-se que $cv^2 = \frac{1}{nel}$ (ver Apêndice A), e portanto a razão entre os números equivalente de *looks* no nível C e no nível *zero* é dada por:

$$\frac{nel_C}{nel_0} = \frac{\hat{cv}_0^2}{\hat{cv}_C^2}$$

Usando a Equação (4.8) tem-se que:

$$nel_C = \frac{nel_0 \cdot 2^{2C}}{1 + 2 \left(1 - \frac{1}{2^C}\right) [\hat{\rho}(0, 1) + \hat{\rho}(1, 0) + \left(1 - \frac{1}{2^C}\right) \hat{\rho}(1, 1)]} \quad (4.10)$$

onde nel_0 corresponde ao valor do número equivalente de *looks* estipulado pelo usuário. Ao contrário do valor de similaridade e do valor coeficiente de variação crítico, o nel tende a aumentar a cada compressão.

A principal vantagem do uso da representação por pirâmide é que, mesmo trabalhando com grandes imagens, a segmentação inicial sempre é feita sobre uma imagem com dimensões reduzidas, tornando o processo de segmentação por crescimento de região mais rápido. A desvantagem quando se usa esta representação é que quanto mais níveis são utilizados, maior é a quantidade de memória necessária para armazenar as imagens de cada nível de compressão.

4.1.3 Segmentação por Crescimento de Regiões

O processo de crescimento de regiões é igual para os dois tipos de imagens (radar e ópticas). O processo começa na imagem que tem a máxima compressão, onde cada *pixel* é considerado como uma região e é construída a relação de vizinhança quatro para cada um destes *pixels*. Nesta etapa é criada uma estrutura para armazenar os endereços ou identificadores (*id's*) dos *pixels*.

Antes de começar o processo de crescimento de regiões os *id's* são colocados de forma aleatória numa lista, para evitar que o processo seja tendencioso. O início do processo de crescimento de regiões se dá pelo primeiro valor da lista de *id's*. A medida que os *pixels* são visitados e agrupados a uma região, os *id's* que os representam deixam de pertencer à lista e o processo termina quando não houver mais *id's* a serem visitados.

À medida que os *pixels* vão sendo agrupados tem-se a formação de regiões e é preciso testar então se um *pixel* será agrupado à uma região, ou se duas regiões podem ser agrupadas. A seguir estão descritos os testes aplicados para agrupar *pixel* com *pixel*, e *pixel* com região, os quais são efetuados na primeira etapa do segmentador. O teste para agrupar regiões é efetuado na terceira etapa e descrito na Seção 4.3.3.

4.1.3.1 Teste para Agrupar *Pixel* com *Pixel*

O processo de crescimento de regiões se inicia com o cálculo da distância Euclidiana dos valores entre o primeiro *pixel* da lista (p_s) e os seus vizinhos. Se essa distância for menor

ou igual ao limiar de similaridade, deve-se então verificar se o *pixel* p_s é também o mais próximo em vizinhança quatro do *pixel* p_v ; se houver reciprocidade, o *pixel* p_v é agrupado ao *pixel* p_s , caso contrário escolhe-se o próximo *pixel* da lista para começar o crescimento de região. Esta condição de reciprocidade torna o processo mais exigente: dois *pixels* só serão agrupados se eles tiverem os valores mais próximos entre si.

O teste para agrupar *pixels* é igual tanto para imagens de radar quanto para ópticas. Dado um *pixel* semente p_s e o *pixel* vizinho p_v que tenha o valor mais próximo do *pixel* p_s , se faz o teste abaixo:

$$|p_s - p_v| < Simil_C, \quad (4.11)$$

onde $Simil_C$ é calculado segundo a Equação (4.7). O próximo passo é saber se o *pixel* p_v tem como vizinho com valor mais próximo o *pixel* p_s ; caso isso aconteça se tem a formação de uma nova região tal que $p_s, p_v \in r_{novo}$. O processo de crescimento de região continua até que não exista mais *pixels* vizinhos a essa região que satisfaça o critério de crescimento. Este critério é válido tanto para o modelo de manchas como para o modelo de textura.

4.1.3.2 Teste para Agrupar *Pixel* com Região - Imagem de Radar

Modelo de manchas

Para o modelo de manchas, foi desenvolvido um teste para agrupar *pixel* a uma região com base na distribuição Gama. Dada uma variável aleatória (*v.a.*) X' com distribuição Gama Padrão, representada por $\Gamma(\alpha, 1)$, existe um valor crítico (v'_{critic}), tal que com probabilidade $1 - \vartheta$

$$P(X' \leq v'_{critic}) = 1 - \vartheta \quad (4.12)$$

Portanto, uma *v.a.* $X = \frac{X'}{\beta}$ possuirá uma distribuição Gama, denotada por $\Gamma(\alpha, \beta)$, (ver Apêndice A), e para a mesma probabilidade de $1 - \vartheta$ o seu valor crítico fica modificado também pela razão $\frac{1}{\beta}$, ou seja

$$\begin{aligned} P\left(\frac{X'}{\beta} \leq \frac{v'_{critic}}{\beta}\right) &= 1 - \vartheta \\ P\left(X \leq \frac{v'_{critic}}{\beta}\right) &= 1 - \vartheta \\ P(X \leq v_{critic}) &= 1 - \vartheta. \end{aligned} \quad (4.13)$$

Para o caso de regiões homogêneas em intensidade, tem-se que $\alpha = nel_C$ e $\beta = \frac{nel_C}{\mu_I}$ (ver Apêndice A), onde μ_I é a média em intensidade da região, e nel_C é o número equivalente de *looks* no nível de compressão C ($C = 1, \dots, N$). O teste para pertinência de um *pixel* a uma região, consiste em se determinar um valor crítico (v'_{critic}) de uma Gama Padrão $\Gamma(nel_C, 1)$, ao nível de confiança $(1 - \vartheta)$ e se calcular $v_{critic} = \frac{v'_{critic} \bar{X}_I}{nel_C}$, onde $\bar{X}_I$ é a intensidade média amostral da região. Se o valor do *pixel* p_i for menor ou igual ao valor crítico calculado, esse *pixel* passará a fazer parte da região a qual está sendo testado, caso contrário não fará parte desta região. O nível de confiança $1 - \vartheta$ é o parâmetro de entrada *Conf* selecionado pelo usuário no modelo de manchas.

A segmentação se inicia com $C = N$ (máxima compressão), mas o processo de crescimento de regiões será efetuado em qualquer nível de compressão C quando uma região não for considerada homogênea. Os testes de homogeneidade de regiões são descritos na Seção 4.3.2.

Modelo de textura

No modelo de textura, é aplicado um teste que usa o coeficiente de variação (cv) da região. Calcula-se o cv da região com o *pixel* que está sendo testado. Se o valor do coeficiente de variação da região não aumentar, então o *pixel* passa a fazer parte da região, caso contrário esse *pixel* não será agrupado à região. Quanto maior for a região menos eficaz é este teste, mas como no início do crescimento de regiões as regiões são pequenas este teste é mais eficiente.

4.1.3.3 Teste para Agrupar *Pixel* com Região - Imagem Óptica

Modelo de manchas

No modelo de manchas, para imagens ópticas, supõe-se que a distribuição dos dados é uma Gaussiana com variância comum a todas as regiões. Neste caso, tem-se que, se o *pixel* p_i pertence a uma região com média $\bar{X}_r$ e variância s^2 comum a todas as regiões, então

$$\frac{p_i - \mu}{\sigma} \sim N(0, 1) \quad (4.14)$$

onde $N(0, 1)$ é a distribuição Normal Padrão.

Portanto, diz-se que o *pixel* p_i pertence à região se

$$\left| \frac{p_i - \bar{X}_r}{s} \right| \leq z_{\vartheta/2} \quad (4.15)$$

onde $z_{\vartheta/2}$ é o valor da distribuição Normal Padrão tal que $P(Z \leq z_{\vartheta/2}) = 1 - \vartheta/2$, e s é o desvio padrão estimado sobre toda a imagem. O nível de confiança $1 - \vartheta$ é o parâmetro de entrada *Conf* selecionado pelo usuário no modelo de manchas para imagens ópticas.

Ainda assim, o *pixel* somente será agrupado à região se não existir nenhum outro *pixel* p_v , vizinho de p_i , tal que

$$|p_v - p_i| < |p_i - \bar{X}_r| \quad (4.16)$$

Os testes para agrupar um *pixel* ou *pixels* a uma região são realizados para todos os vizinhos da região r .

Modelo de textura

No modelo de textura, utiliza-se o mesmo teste descrito anteriormente para o modelo de manchas, mas o desvio padrão s é substituído por s_r , onde s_r é o desvio padrão da região que está sendo testada.

Como resultado da primeira fase, tem-se a imagem segmentada gerada a partir da imagem com resolução mais degradada, devido às compressões aplicadas sobre a imagem original.

4.2 Segunda Etapa

Esta etapa pode ser denominada de intermediária no processo de segmentação, por ser responsável pelo controle da descompressão da imagem segmentada, do armazenamento dos dados, e pela parada do processo de segmentação (Figura 4.8).




FIGURA 4.8 – Fluxograma da segunda etapa do processamento.

Nesta etapa, é realizada a descompressão dos dados. As imagens resultantes da primeira

e terceira etapa (próximo item) passam por esta rotina, sofrendo uma descompressão até que a imagem esteja no nível mais baixo (imagem original). Com isso, as regiões formadas na segmentação anterior (nível C) passam a ser representadas por regiões com o quádruplo do tamanho, e são recalculados a média, a variância e topologia de cada região neste nível ($C - 1$). Uma vez que o processo de descompressão tenha sido aplicado em todos os níveis, a imagem segmentada passa para a quarta e última etapa.

O gerenciamento e armazenamento dos dados são realizados de forma que, a medida que ocorre uma descompressão, os dados do nível anterior são liberados da estrutura, diminuindo assim o espaço ocupado na memória. Desta maneira, quanto mais avançada a segmentação, menor é o tamanho da estrutura armazenada na memória.

4.3 Terceira Etapa

Quando esta etapa é iniciada no nível $C - 1$, a imagem já está segmentada, pois passou pela descompressão do nível C e contém uma estrutura que armazena toda a informação das regiões que foram geradas no nível anterior (Figura 4.9).




FIGURA 4.9 – Fluxograma da terceira etapa do processamento.

Como já se tem uma imagem segmentada, o próximo passo é aplicar testes às regiões para buscar melhorar a segmentação inicial. O primeiro teste realizado é um teste de ajuste de bordas, o qual tem a finalidade de refinar as bordas desta nova imagem que passou por uma descompressão. Após o ajuste de bordas é aplicado um teste de homogeneidade para

cada região, e aquelas regiões que forem identificadas como sendo não homogêneas serão segmentadas novamente. Posteriormente, faz-se um teste para agrupar regiões similares em toda a imagem, pois, com a resegmentação das regiões não homogêneas, são criadas novas regiões que podem vir a ser similares às regiões vizinhas já previamente existentes. Esses procedimentos estão detalhados a seguir.

4.3.1 Teste de Ajuste de Bordas

O teste de ajuste de bordas utiliza o critério de menor distância entre o valor do *pixel* de borda com a média amostral da região a qual pertence e à região vizinha a qual está conectado. O objetivo deste teste é fazer um refinamento das fronteiras das regiões criadas na segmentação do nível anterior. Este teste é necessário porque a imagem segmentada foi gerada a partir de uma imagem degradada, o que implica que as bordas geradas podem ser grosseiras, dado o aumento da resolução da imagem.

Para o modelo de manchas, o teste de ajuste de bordas é realizado entre *pixel* de bordas e regiões, ponderando através do desvio padrão amostral da região, o valor absoluto da diferença entre o valor do *pixel* e a média amostral da região em questão. Sejam r_A a região que contém o *pixel* de borda p_{r_A} e r_B a região vizinha de r_A , que contém o *pixel* de borda p_{r_B} , onde p_{r_A} e p_{r_B} são vizinhos (ver Figura 4.10). Então os seguintes valores são calculados

$$\begin{aligned} V_{Aa} &= \frac{|p_{r_A} - \bar{X}_{r_A}|}{s_{r_A}} & ; & \quad V_{Ba} = \frac{|p_{r_A} - \bar{X}_{r_B}|}{s_{r_B}} \\ V_{Bb} &= \frac{|p_{r_B} - \bar{X}_{r_B}|}{s_{r_B}} & ; & \quad V_{Ab} = \frac{|p_{r_B} - \bar{X}_{r_A}|}{s_{r_A}} \end{aligned} \quad (4.17)$$

onde $\bar{X}_{r_A}$ e $\bar{X}_{r_B}$ são as médias das regiões r_A e r_B , respectivamente e s_{r_A} e s_{r_B} os desvios padrões. Para as imagens de radar usando o modelo de manchas, os desvios padrões das regiões r_η ($\eta = A, B$) são estimados por $\frac{\bar{X}_{r_\eta}}{\sqrt{nel_C}} * 2$, onde nel_C é o número equivalente de *looks* da imagem no nível de compressão C , sendo calculado através da Equação (4.10). Para imagens ópticas no modelo de manchas, o desvio padrão é estimado por $s_{r_A} = s_{r_B} = s_C$, onde s_C é o desvio padrão de toda a imagem no nível de compressão C e computado usando a Equação (4.6).

Já para o modelo de textura, tanto para imagens de radar como ópticas, os valores de V_{Aa}

²Este é o estimador de momentos do desvio padrão de uma variável aleatória com distribuição Gama $\Gamma(nel, nel/\mu)$, onde μ é média da intensidade, estimada por $\bar{X}$ (ver Equação (A.14) no Apêndice A).

e V_{B_b} , são calculados utilizando os coeficientes de variação de cada região, e os valores de V_{B_a} e V_{A_b} utilizando os coeficientes de variação das regiões com o *pixel* de borda incluído na mesma. Assim se tem:

$$\begin{aligned} V_{A_a} &= cv(r_A) \quad ; \quad V_{B_a} = cv(r_B \cup \{p_{r_A}\}) \\ V_{B_b} &= cv(r_B) \quad ; \quad V_{A_b} = cv(r_A \cup \{p_{r_B}\}) \end{aligned}$$

onde $cv(r_A)$ e $cv(r_B)$ são os valores do coeficiente de variação calculados para as regiões r_A e r_B respectivamente, $cv(r_A \cup \{p_{r_B}\})$ é o coeficiente de variação calculado para região r_A com o valor do *pixel* p_{r_B} incluído, e $cv(r_B \cup \{p_{r_A}\})$ é o coeficiente de variação calculado para a região r_B com o valor do *pixel* p_{r_A} incluído.

Tanto para o modelo de manchas, como para o modelo de textura, a borda será alterada, se e somente se as seguintes condições forem satisfeitas:

$$\begin{aligned} V_{A_a} < V_{B_a} \quad e \quad V_{B_b} \geq V_{A_b} &\implies p_{r_B} \in r_A \\ V_{A_a} > V_{B_a} \quad e \quad V_{B_b} \leq V_{A_b} &\implies p_{r_A} \in r_B \end{aligned} \tag{4.18}$$

A Figura (4.10) ilustra o processo que é realizado para ajustar as bordas tanto para as imagens de radar como para as ópticas, independentemente do modelo adotado para a segmentação.

4.3.2 Teste de Homogeneidade para Regiões

Os critérios adotados para testar a homogeneidade de uma região em uma imagem no nível de compressão C foram estabelecidos pela comparação do valor do coeficiente de variação (cv) da região com o $(cv_{crítico})_C$. A seguir estão descritos os testes de homogeneidade para imagens de radar e ópticas usando os modelos de manchas e de textura.

Para as imagens de radar no modelo de manchas, o valor do $(cv_{crítico})_C$ foi calculado sobre uma distribuição de cv , obtida através simulações de uma variável aleatória possuindo distribuição Gama com parâmetro nel e nel/μ e denotada por $\Gamma(nel, nel/\mu)$, para diferentes valores de nel e diferentes tamanhos de regiões.

Como a distribuição do cv amostral de uma variável aleatória com distribuição Gama depende do tamanho da amostra e do nel , foi realizada uma simulação *Monte Carlo* para obter os valores de $cv_{crítico}$ para diferentes tamanhos de amostra, e diferentes valores de




FIGURA 4.10 – Ilustração do teste de ajuste de bordas.

nel , para alguns níveis de significância. Foram simuladas amostras com tamanhos entre 10 a 9.000, com nel variando de 1 a 250, e níveis de confiança de 99,9%, 99,5%, 99%, 95%, 90%, 85% e 80%. Para obter os valores de $cv_{crítico}$, para cada par de tamanho de amostra e nel , foram realizadas 5.000 simulações. Assim, o $cv_{crítico}$ para um dado nel e um dado tamanho de amostra, ao nível de confiança $(1 - \vartheta)$ é tal que

$$P(\hat{cv} \leq cv_{crítico}) = 1 - \vartheta. \quad (4.19)$$

Dada uma região r , o seu coeficiente de variação é estimado por

$$\hat{cv}_r = \frac{\bar{x}_r}{s_r}$$

onde $\bar{x}_r$ e s_r são, respectivamente, a média amostral e o desvio padrão amostral da região. Esta região será considerada homogênea, ao nível de confiança $1 - \vartheta$, se

$$\hat{cv}_r \leq cv_{crítico}.$$

O valor de $1 - \vartheta$ é o parâmetro de entrada correspondente a um nível de confiança,

estipulado pelo usuário.

Os valores de $cv_{crítico}$ resultantes das simulações *Monte Carlo* foram organizados em tabelas, onde os tamanhos da amostra (tamanho da região) se distribuem nas colunas e os valores de nel se distribuem nas linhas. A cada nível de compressão C , o nel utilizado é o nel_C obtido segundo a Equação (4.10).

Na Tabela 4.3 são apresentados os valores críticos do coeficiente de variação para o nível de significância de 5% para alguns tamanhos de amostras e de nel_C . Os valores críticos para os demais níveis de significância encontram-se no Apêndice B.

TABELA 4.3 – Valores críticos de cv a 5% obtidos por simulação *Monte Carlo*.

nel_C	Tamanho da amostra												
	10	20	30	40	50	...	100	...	500	...	1000	...	9000
1	1,358	1,295	1,254	1,230	1,213		1,154		1,072		1,051		1,016
2	0,959	0,908	0,874	0,859	0,846		0,808		0,753		0,739		0,717
3	0,795	0,741	0,712	0,697	0,683		0,651		0,613		0,602		0,585
4	0,684	0,637	0,612	0,599	0,588		0,566		0,529		0,520		0,506
5	0,615	0,567	0,544	0,534	0,524		0,503		0,472		0,465		0,452
6	0,557	0,518	0,500	0,489	0,479		0,459		0,431		0,424		0,413
7	0,519	0,480	0,458	0,448	0,443		0,424		0,398		0,393		0,382
8	0,483	0,452	0,431	0,419	0,415		0,397		0,372		0,367		0,357
9	0,454	0,420	0,408	0,394	0,387		0,374		0,351		0,346		0,337
10	0,433	0,400	0,383	0,374	0,369		0,356		0,332		0,328		0,319
⋮													
50	0,191	0,177	0,170	0,168	0,164		0,157		0,148		0,146		0,143
⋮													
100	0,138	0,126	0,121	0,118	0,116		0,111		0,105		0,103		0,101
⋮													
200	0,097	0,088	0,085	0,083	0,082		0,078		0,074		0,073		0,071
⋮													
250	0,087	0,079	0,076	0,074	0,073		0,070		0,066		0,065		0,063

As regiões consideradas não homogêneas serão segmentadas novamente. O processo de segmentação das regiões selecionadas é feito pelo método de crescimento e agrupamento de regiões.

Para o modelo de textura aplicado a imagens de radar, supõe-se que o valor do *backscatter* não é constante dentro de cada região, ou seja que os dados das regiões não são modeladas por uma distribuição Gama. Assim, o teste é feito usando o parâmetro de entrada CV fornecido pelo usuário, o qual é recalculado a cada nível de compressão C segundo a

Equação (4.9), fornecendo o valor de $(cv_{crítico})_C$. Uma região r de uma imagem no nível de compressão C será considerada homogênea, se o seu coeficiente de variação estimado for menor ou igual que o $(cv_{crítico})_C$.

Para imagens ópticas, seja no modelo de manchas ou no modelo de textura, o teste de homogeneidade de regiões é feito usando o parâmetro de entrada CV fornecido pelo usuário, o qual é recalculado a cada nível de compressão C segundo a Equação (4.9), fornecendo o valor de $(cv_{crítico})_C$. Uma região r de uma imagem no nível de compressão C será considerada homogênea, se o seu coeficiente de variação estimado for menor ou igual que o $(cv_{crítico})_C$.

4.3.3 Teste para Agrupar Regiões

Depois de fazer o teste de bordas e segmentar as regiões que foram detectadas como não homogêneas, é necessário aplicar um teste para determinar se essas novas regiões presentes na imagem podem ser agrupadas ou não com as regiões vizinhas previamente existentes.

O teste usado para o modelo de manchas foi o teste $t - Student$. Embora este teste suponha normalidade dos dados, ele foi usado para imagens de radar. Isto pode ser justificado pois, neste modelo, faz-se a suposição de que as regiões homogêneas estão representadas por uma distribuição Gama, e devido às compressões o nel da imagem tende a aumentar e a distribuição Gama tende para uma distribuição Normal. Já para o modelo de textura, o teste utilizado para imagens de radar foi o de comparação do coeficiente de variação das regiões, e para imagens ópticas foi usado também o teste $t - Student$. A seguir estão descritos estes testes.

O teste $t-Student$ é usado para comparar igualdade de médias de amostras com distribuição Normal e pode ser calculado através do teste homocedástico, o qual supõe igualdade de variâncias, ou a partir do teste heterocedástico, que supõe que essas amostras tem variâncias diferentes. A forma de se obter a estatística t está descrita a seguir.

Teste $t-Student$ Homocedástico

Considere duas amostras com m_A e m_B elementos, obtidas independentemente de duas populações A e B , normalmente distribuídas com médias μ_A e μ_B e variâncias $\sigma_A^2 = \sigma_B^2 = \sigma^2$, respectivamente. Para testar a igualdade das médias, usa-se o teste

t – *Student* e considerando $\sigma_A^2 = \sigma_B^2 = \sigma^2$ desconhecidas mas iguais, tem-se

$$t = \frac{\frac{(\bar{x}_A - \bar{x}_B) - (\mu_A - \mu_B)}{\sqrt{\frac{1}{m_A} + \frac{1}{m_B}}}}{\sqrt{\frac{(m_A - 1)s_A^2 + (m_B - 1)s_B^2}{m_A + m_B - 2}}} \sim t_{m_A + m_B - 2} \quad (4.20)$$

onde $\bar{x}_A$ e $\bar{x}_B$ são as médias amostrais de A e B , s_A^2 e s_B^2 suas respectivas variâncias amostrais (supondo que as amostras são independentes), e $m_A + m_B - 2$ são os graus de liberdade (DeGroot e Schervish, 2002).

Sob a hipótese $H_0 : \mu_A = \mu_B$ tem-se

$$t = \frac{\frac{\bar{x}_A - \bar{x}_B}{\sqrt{\frac{1}{m_A} + \frac{1}{m_B}}}}{\sqrt{\frac{(m_A - 1)s_A^2 + (m_B - 1)s_B^2}{m_A + m_B - 2}}} \sim t_{m_A + m_B - 2}, \quad (4.21)$$

ou

$$t = \frac{\bar{x}_A - \bar{x}_B}{\sqrt{\frac{(m_A - 1)s_A^2 + (m_B - 1)s_B^2}{m_A + m_B - 2} \cdot \left(\frac{1}{m_A} + \frac{1}{m_B}\right)}} \sim t_{m_A + m_B - 2} \quad (4.22)$$

A hipótese H_0 é aceita a um nível de confiança $1 - \vartheta$ se $|t| \leq t_{m_A + m_B - 2; 1 - \vartheta}$, onde $t_{m_A + m_B - 2; 1 - \vartheta}$ é obtido pela distribuição t – *Student* com $m_A + m_B - 2$ graus de liberdade, tal que $P(t_{m_A + m_B - 2} \leq t_{m_A + m_B - 2; 1 - \vartheta}) = 1 - \vartheta$.

Teste *t-Student* Heterocedástico

Dadas duas amostras com m_A e m_B elementos, obtidas independentemente de duas populações A e B , normalmente distribuídas com médias μ_A e μ_B e variâncias σ_A^2 e σ_B^2 diferentes entre si e desconhecidas, sob a hipótese $H_0 : \mu_A = \mu_B$ tem-se (DeGroot e Schervish, 2002)

$$t = \frac{\bar{x}_A - \bar{x}_B}{\sqrt{\frac{s_A^2}{m_A} + \frac{s_B^2}{m_B}}} \sim t_v \quad (4.23)$$

onde v são os graus de liberdade obtidos por:

$$v = \frac{\left(\frac{s_A^2}{m_A} + \frac{s_B^2}{m_B}\right)^2}{\frac{\left(\frac{s_A^2}{m_A}\right)^2}{m_A-1} + \frac{\left(\frac{s_B^2}{m_B}\right)^2}{m_B-1}} \quad (4.24)$$

A hipótese H_0 é aceita a um nível de confiança $1 - \vartheta$ se $|t| \leq t_{v;1-\vartheta}$, onde $t_{v;1-\vartheta}$ é obtido pela distribuição $t - Student$ com v graus de liberdade, tal que $P(t_v \leq t_{v;1-\vartheta}) = 1 - \vartheta$.

4.3.3.1 Teste *t-Student* para Agrupar Regiões - Modelo de Manchas

Imagens de Radar

Sejam duas regiões r_A e r_B de uma imagem no nível de compressão C , cujos dados são distribuídos com médias μ_{r_A} e μ_{r_B} e variâncias $\sigma_{r_A}^2$ e $\sigma_{r_B}^2$.

Para o modelo de manchas, tem-se que, sob a hipótese H_0 , as médias são iguais ($\mu_{r_A} = \mu_{r_B} = \mu$) e, portanto, as variâncias das duas regiões são também iguais já que $\sigma_{r_A}^2 = \sigma_{r_B}^2 = \frac{\mu^2}{nel_C}$, onde nel_C é o número equivalente de *looks* da imagem no nível de compressão C . Portanto, o teste utilizado é o $t - Student$ homocedástico, com o estimador da variância dado por $s_{r_\eta}^2 = \frac{\bar{x}_{r_\eta}^2}{nel_C}$, $\eta = A$ ou B . Utilizando a Equação (4.22) tem-se que

$$t = \frac{\bar{x}_{r_A} - \bar{x}_{r_B}}{\sqrt{\frac{(m_{r_A}-1) \cdot \bar{x}_{r_A}^2 + (m_{r_B}-1) \cdot \bar{x}_{r_B}^2}{nel_C \cdot (m_{r_A} + m_{r_B} - 2)} \cdot \left(\frac{1}{m_{r_A}} + \frac{1}{m_{r_B}}\right)}} \sim t_{m_{r_A} + m_{r_B} - 2} \quad (4.25)$$

onde $\bar{x}_{r_A}$ e $\frac{\bar{x}_{r_A}^2}{nel_C}$ são a média e a variância amostrais da região r_A , $\bar{x}_{r_B}$ e $\frac{\bar{x}_{r_B}^2}{nel_C}$ são a média e variância amostrais da região r_B e $m_{r_A} + m_{r_B} - 2$ é o número de graus de liberdade.

As regiões r_A e r_B são agrupadas se as seguintes condições forem satisfeitas:

- $t \leq t_{crítico}$, onde $t_{crítico}$ é obtido pela distribuição t com $m_{r_A} + m_{r_B} - 2$ graus de liberdade, tal que $P(t_{m_{r_A} + m_{r_B} - 2} \leq t_{crítico}) = 1 - \vartheta$, onde $1 - \vartheta$ é o parâmetro de entrada relativo ao nível de confiança, estipulado pelo usuário.
- A diferença entre as médias for menor que o limiar de similaridade no nível de compressão C :

$$|\bar{x}_{r_A} - \bar{x}_{r_B}| \leq Simil_C \quad (4.26)$$

onde $Simil_C$ é calculado segundo a Equação (4.7).

Imagens Ópticas

Sejam duas regiões r_A e r_B de uma imagem no nível de compressão C , cujos dados são distribuídos normalmente com médias μ_{r_A} e μ_{r_B} e variâncias $\sigma_{r_A}^2$ e $\sigma_{r_B}^2$.

Para as imagens ópticas, o modelo de manchas faz uso do teste homocedástico, já que se supõe que a variância das regiões é causada somente pelo ruído aditivo, único para toda a imagem. Assim, as variâncias das regiões r_A e r_B são estimadas usando-se os dados de toda a imagem. O teste utilizado para agrupar as regiões é o t - *Student* homocedástico dado por

$$t = \frac{\bar{x}_{r_A} - \bar{x}_{r_B}}{s \sqrt{\left(\frac{1}{m_{r_A}} + \frac{1}{m_{r_B}}\right)}} \sim t_{m_{r_A} + m_{r_B} - 2} \quad (4.27)$$

onde $\bar{x}_{r_A}$ é a média da região r_A , $\bar{x}_{r_B}$ é a média da região r_B , s é o desvio padrão de toda a imagem e $m_{r_A} + m_{r_B} - 2$ é o número de graus de liberdade. As regiões r_A e r_B são agrupadas se as seguintes condições forem satisfeitas:

- a) $t \leq t_{crítico}$, onde $t_{crítico}$ é obtido pela distribuição t com $m_{r_A} + m_{r_B} - 2$ graus de liberdade, tal que $P(t_{m_{r_A} + m_{r_B} - 2} \leq t_{crítico}) = 1 - \vartheta$, onde $1 - \vartheta$ é o parâmetro de entrada relativo ao nível de confiança, estipulado pelo usuário.
- b) A diferença entre as médias for menor que o limiar de similaridade no nível de compressão C :

$$|\bar{x}_{r_A} - \bar{x}_{r_B}| \leq Simil_C \quad (4.28)$$

onde $Simil_C$ é calculado segundo a Equação (4.7).

4.3.3.2 Teste para agrupar regiões - modelo de textura

Imagens de Radar

Para saber se duas regiões r_A e r_B de uma imagem no nível de compressão C serão agrupadas, estima-se o coeficiente de variação da região formada pela união das duas regiões ($cv(r_A \cup r_B)$) e compara-se com o valor do $(cv_{crítico})_C$ calculado segundo a Equação (4.9). Caso o $cv(r_A \cup r_B)$ seja menor que este valor crítico, essas regiões serão agrupadas, ou seja

$$cv(r_A \cup r_B) < (cv_{crítico})_C \Rightarrow r_A \text{ e } r_B \text{ são agrupadas.} \quad (4.29)$$

Imagens Ópticas

Para o modelo de textura faz-se uso das variâncias das regiões. Assim, o teste utilizado para verificar a igualdade de médias é t heterocedástico dado pela Equação (4.23):

$$t = \frac{\bar{x}_{r_A} - \bar{x}_{r_B}}{\sqrt{\frac{s_{r_A}^2}{m_{r_A}} + \frac{s_{r_B}^2}{m_{r_B}}}} \sim t_v \quad (4.30)$$

onde v são os graus de liberdade obtidos por:

$$v = \frac{\left(\frac{s_{r_A}^2}{m_{r_A}} + \frac{s_{r_B}^2}{m_{r_B}}\right)^2}{\frac{\left(\frac{s_{r_A}^2}{m_{r_A}}\right)^2}{m_{r_A}-1} + \frac{\left(\frac{s_{r_B}^2}{m_{r_B}}\right)^2}{m_{r_B}-1}} \quad (4.31)$$

onde $\bar{x}_{r_A}$ é a média da região r_A , $\bar{x}_{r_B}$ é a média da região r_B , $s_{r_A}^2$ e $s_{r_B}^2$ são as variâncias das regiões r_A e r_B , respectivamente e $m_{r_A} + m_{r_B} - 2$ é o número de graus de liberdade. As regiões r_A e r_B são agrupadas se as seguintes condições forem satisfeitas:

- a) $t \leq t_{crítico}$, onde $t_{crítico}$ é obtido pela distribuição t com v graus de liberdade, tal que $P(t_v \leq t_{crítico}) = 1 - \vartheta$, onde $1 - \vartheta$ é o parâmetro de entrada relativo ao nível de confiança, estipulado pelo usuário.
- b) A diferença entre as médias for menor que o limiar de similaridade no nível de compressão C :

$$|\bar{x}_{r_A} - \bar{x}_{r_B}| \leq Simil_C \quad (4.32)$$

onde $Simil_C$ é calculado segundo a Equação (4.7).

4.4 Quarta Etapa

Nesta etapa (Figura 4.11), obtém-se a imagem segmentada final, a qual passa por um teste para identificar se existem regiões menores que o limiar de área mínima definido pelo usuário. Caso existam, estas regiões serão agrupadas com as regiões vizinhas, usando um critério de menor diferença absoluta entre as médias. A região menor passará a fazer parte da região que possuir a média mais próxima desta região menor.

Por último, é gerada a imagem segmentada final, a qual é armazenada em disco em três produtos: a imagem *id* que é uma imagem onde a cada polígono está associado um valor

único de identificação (*id*); a imagem de médias, onde cada polígono está associado ao valor médio dos *pixels* que formam a região; e, o terceiro produto é uma imagem que contém somente as bordas das regiões.




FIGURA 4.11 – Fluxograma da quarta etapa do processamento.

CAPÍTULO 5

APLICAÇÕES E DISCUSSÕES

Neste capítulo, apresentam-se alguns resultados obtidos da aplicação do segmentador *SegSAR* em diferentes tipos de imagens. Para a avaliação dos resultados sobre imagens de radar, foram utilizadas imagens simuladas e imagens dos sensores JERS-1 e AeroSensing (AeS-1). A avaliação dos resultados do segmentador sobre imagens ópticas foi efetuada sobre uma imagem Landsat/TM e uma imagem ETM+. A avaliação quantitativa foi feita sobre as imagens de radar simuladas. Para as demais imagens, a avaliação foi somente qualitativa.

5.1 Aplicações do *SegSAR* sobre Imagens de Radar

Inicialmente foram simuladas imagens de radar e sobre estas foram aplicadas as medidas quantitativas descritas na Seção 3.4 para avaliar os resultados das segmentações. Sobre os resultados das segmentações também se fez uma análise qualitativa do desempenho do segmentador. Posteriormente, o segmentador *SegSAR* também foi aplicado sobre uma imagem do radar aerotransportado AeS-1 e sobre uma imagem *Jers*, sendo que os resultados desta última foram comparados com os resultados obtidos sobre uma imagem *TM/Landsat* da mesma área.

5.1.1 Imagens Simuladas

Para avaliar o segmentador *SegSAR* com imagens simuladas, foram utilizados dois conjuntos de imagens, em amplitude, de 480 linhas por 480 colunas. O algoritmo utilizado para gerar as imagens simuladas foi o mesmo utilizado por LUGA (1998), e foi implementado em *IDL*. O primeiro conjunto de imagens, denominado Gama, contém 200 imagens, cada uma com 36 regiões homogêneas modeladas em amplitude, por distribuições Raiz Quadrada da Gama $\sqrt{\Gamma}$, sendo 100 imagens com 3 *looks* e 100 imagens com 8 *looks*. Posteriormente, como mencionado na Seção 4.1, o sistema faz a transformação destas imagens para intensidade e, portanto, os dados das regiões passam a ter distribuições Gama.

O segundo conjunto de imagens denominado Textura, também contém 200 imagens simuladas em amplitude, sendo 100 imagens com 3 *looks* e 100 imagens com 8 *looks*. As 36 regiões que compõem a cena estão distribuídas em três classes com 21 regiões homogêneas, três classes com 11 heterogêneas e duas classes com 4 extremamente heterogêneas (Figura 5.1), modeladas segundo Frery et al. (1997) por distribuições $\sqrt{\Gamma}$, K_A e G_A^0 . Quando transformadas para intensidade, estas regiões possuirão distribuições

Γ , K_I e G_I^0 , respectivamente.




FIGURA 5.1 – Imagem com as regiões da imagem referência (*phantom*).
FONTE: Modificada de LUGCA (1998).

A avaliação quantitativa das segmentações foi efetuada utilizando as medidas descritas na Seção 3.4. A Figura 5.2 apresenta uma segmentação ideal, a qual foi utilizada para calcular as medidas de posição, intensidade, número de elementos e forma dos polígonos.




FIGURA 5.2 – Segmentação ideal utilizada no processo de avaliação do segmentador *SegSAR*.


Os parâmetros usados para fazer as segmentações foram os valores *default* do programa: similaridade igual a $1dB$, área mínima igual a $40\ pixels$, nível de confiança igual a 95% e coeficiente de variação igual a $0,6$, sendo este último utilizado somente para o modelo de textura. O número máximo de níveis de compressão variou entre 3 e 7, sendo que, para cada um destes níveis, foram aplicadas as medidas de qualidade no resultado final da segmentação em cada nível (imagens no nível *zero*). Para efeitos de estimativa de tempo, os processamentos foram realizados em computador com as seguintes características: processador *pentium* 4 com velocidade de $2,2\ GHz$ e $512Mb$ de memória *ram*.

Para as imagens Gama, foi utilizado o modelo de manchas, por ser o modelo mais adequado. Para as imagens Textura, aplicaram-se, para fins de comparação, os modelos de manchas e textura.


A Figura 5.3 ilustra o processo de segmentação para cada nível de compressão, para uma imagem simulada com os dados das regiões possuindo uma distribuição Gama, com 8 *looks* e tamanho de 480 linhas por 480 colunas. Neste caso, foi usado o modelo de manchas com nível de compressão máximo igual a 5 ($N = 5$). No nível 5, a imagem passa a ter um tamanho de $15 \times 15\ pixels$, onde é efetuada a primeira segmentação, e a cada nível a imagem é descomprimida e uma nova segmentação é efetuada para as regiões heterogêneas. Os valores dos parâmetros de entrada no segmentador no nível *zero* são: similaridade igual a $1dB$, que equivale a um valor de similaridade em intensidade de $3916,11$ e o valor do número equivalente de *looks* da imagem de entrada que é igual a 8. Estes parâmetros são modificados a cada nível de compressão de acordo com a diminuição da variância da imagem. Na Tabela 5.1 se apresentam os valores de similaridade e número equivalente de *looks* calculados para cada um dos cinco níveis de compressão, segundo as equações da Seção 4.1.2.2.




Nível $C = 5$ (15 x 15 pixels) 82 regiões




Nível $C = 4$ (30 x 30 pixels) 406 regiões




Nível $C = 3$ (60 x 60 pixels) 643 regiões



Nível $C = 2$ (120 x 120 pixels) 687 regiões



Nível $C = 1$ (240 x 240 pixels) 750 regiões



Nível $C = 0$ (480 x 480 pixels) 144 regiões

FIGURA 5.3 – Processo de segmentação de uma imagem Gama 8 *looks* com nível máximo de compressão igual a 5.

TABELA 5.1 – Valores de similaridade e número equivalente de *looks* para a imagem Gama com 8 *looks*, segundo o modelo de manchas.

Parâmetros	Níveis					
	$C = 0$	$C = 1$	$C = 2$	$C = 3$	$C = 4$	$C = 5$
Similaridade	3916,11	2825,81	1005,62	293,07	78,74	20,38
Nel	8,00	11,08	31,15	106,89	250,00	250,00

5.1.2 Modelo de Manchas

O modelo de manchas foi usado para segmentar as imagens Gama e Textura com 3 e 8 *looks*. Os resultados das segmentações estão descritos nas seções a seguir.

5.1.2.1 Imagens Gamas Simuladas de 3 e 8 *Looks*

A análise visual dos resultados da segmentação das imagens Gama de 3 *looks* mostrou que à medida que se aumenta o nível máximo de compressões, ocorre, em geral, uma melhora na qualidade da segmentação. Isto vai de acordo com a teoria que quanto maior o número máximo de compressões, menor é o efeito do ruído *speckle* presente na imagem, portanto melhor é o desempenho do segmentador.

A Figura 5.4 apresenta uma imagem simulada com 3 *looks* e as segmentações para os diferentes níveis máximos de compressão ($N = 1, \dots, 7$); na parte inferior de cada imagem se especifica o número de regiões geradas e o tempo do processo de segmentação. Visualmente, a imagem com nível de compressão máximo igual a 6 é a que apresenta o melhor resultado. As segmentações realizadas com níveis máximos de 3, 4 e 5 apresentaram um número muito grande de regiões. A segmentação com 7 níveis de compressão apresentou um resultado muito próximo da segmentação com 6 níveis, no entanto algumas áreas se apresentaram supersegmentadas.







Imagem 3 *looks*




N = 3 852 regiões 7,96 minutos




N = 4 649 regiões 0,98 minutos



N = 5 345 regiões 0,67 minutos



N = 6 254 regiões 0,57 minutos



N = 7 313 regiões 0,65 minutos

FIGURA 5.4 – Imagem original Gama com 3 *looks* e as respectivas segmentações para diferentes níveis máximos de compressão, usando o modelo de manchas.

A Figura 5.5 apresenta, para o total de 100 simulações, os valores médios gerais das medidas de qualidade e o tempo médio do processo para as segmentações com diferentes níveis máximos de compressão. As barras de erros correspondem a ± 1 desvio padrão. Nesta avaliação quantitativa, tem-se a confirmação da análise qualitativa, pois os resultados médios globais de acerto do segmentador aumentam com o aumento do número máximo de níveis de compressão até o nível 6, que foi o que apresentou o melhor resultado. Para o nível de compressão 7, pode-se observar que ocorre uma diminuição na qualidade da segmentação, apesar desta diferença não ser estatisticamente significativa. Esta diminuição no desempenho pode ser causada pela generalização da informação que ocorre neste nível de compressão, e classes diferentes podem estar sendo agrupadas, diminuindo assim o acerto global do segmentador.




FIGURA 5.5 – Valores médios globais obtidos da segmentação sobre as 100 imagens Gama de 3 *looks* para os diferentes níveis de compressão, usando o modelo de manchas.

O tempo de processamento diminui com o aumento do nível de compressão, pois quanto maior a compressão sobre a imagem original, menor é a matriz que representa a imagem no início do processo. Há uma grande diferença entre os tempos de processamento usando três e quatro níveis máximos de compressão. Outro aspecto que deve ser considerado é a eficiência do método de crescimento de regiões, pois, se durante este processo forem agrupadas várias classes, o tempo da segmentação como um todo aumentaria, e um número maior de regiões seria resegmentado a cada nível.

Os valores médios e os desvios padrões das medidas de qualidade são apresentados na Tabela 5.2. Todas as medidas apresentam melhores resultados quando se aumenta o número máximo de compressão, atingindo valores máximos com 6 níveis de compressão, muito embora não haja diferença estatisticamente significativa entre os resultados obtidos com 5, 6 e 7 níveis máximos de compressão. Os menores valores de acerto do segmentador correspondem à medida de forma das regiões (Gf), confirmando que em dados de radar a definição da borda das regiões é difícil de ser determinada, o que é justificado pela forte influência do ruído *speckle*. As medidas de posição dos polígonos ($Fitxy$) e de intensidade ($Fiti$) estão em todos os níveis próximas de um e o desvio padrão é muito pequeno para os diferentes níveis máximos de compressão. Já a medida de tamanho das regiões ($Fitt$) possui valores não muito altos, provavelmente causados pelo grande número de regiões da segmentação final.

TABELA 5.2 – Valores de média e desvio padrão das medidas de qualidade para as 100 imagens Gama simuladas com 3 *looks*, usando o modelo de manchas.

Número de compressões	Medida	Média	Desvio Padrão	Número Médio de regiões	Tempo Médio (minutos)
3	Fitxy	0,9782	0,0033	844,4375	7,9277
	Fiti	0,9473	0,0070		
	Fitt	0,6082	0,0229		
	Gf	0,4300	0,0194		
	Global	0,7409	0,0109		
4	Fitxy	0,9782	0,0040	661,6900	1,0010
	Fiti	0,9511	0,0061		
	Fitt	0,6490	0,0227		
	Gf	0,4678	0,0215		
	Global	0,7615	0,0111		
5	Fitxy	0,9795	0,0028	339,8600	0,6423
	Fiti	0,9563	0,0040		
	Fitt	0,7150	0,0215		
	Gf	0,5453	0,0240		
	Global	0,7990	0,0115		
6	Fitxy	0,9805	0,0029	271,2700	0,5838
	Fiti	0,9585	0,0053		
	Fitt	0,7242	0,0248		
	Gf	0,5609	0,0232		
	Global	0,8060	0,0125		
7	Fitxy	0,9769	0,0029	308,8900	0,5537
	Fiti	0,9569	0,0056		
	Fitt	0,6998	0,0259		
	Gf	0,5331	0,0288		
	Global	0,7917	0,0140		

Na Figura 5.6 são apresentados os valores de média e as barras de erros correspondente a ± 1 desvio padrão obtidos para cada uma das medidas que são usadas para avaliar o desempenho do segmentador.




FIGURA 5.6 – Valores médios globais das medidas de qualidade sobre as 100 imagens Gama de 3 *looks* para diferentes níveis máximos de compressão, usando o modelo de manchas.

Os resultados da análise qualitativa das imagens Gama com 8 *looks* segmentadas utilizando o modelo de manchas são ainda melhores que os das imagens de 3 *looks* (Figura 5.7). Na parte inferior de cada imagem segmentada se encontra o número de regiões geradas e o tempo de processamento. Os níveis de compressão 5, 6 e 7 apresentam um desempenho similar, sendo difícil determinar qual a melhor segmentação somente pela análise visual.

As Figuras 5.8, 5.9 e a Tabela 5.3 apresentam os resultados da análise quantitativa. Os resultados médios globais de acerto do segmentador para o conjunto de imagens usando diferentes níveis máximos de compressão são maiores que 0,83 (Figura 5.8). Os melhores resultados são obtidos quando se aplica inicialmente mais compressão às imagens. O maior valor é obtido com o nível de compressão máximo de 5, quando se obtém um acerto médio global de 0,87. O tempo de processamento diminui rapidamente à medida que aumenta o número de compressão.







Imagem 8 *looks*




N = 3 428 regiões 4,83 minutos




N = 4 335 regiões 1,19 minutos



N = 5 160 regiões 0,80 minutos



N = 6 122 regiões 0,66 minutos



N = 7 144 regiões 0,62 minutos

FIGURA 5.7 – Imagem original Gama com 8 *looks* e as respectivas segmentações com diferentes níveis máximos de compressão, usando o modelo de manchas.




FIGURA 5.8 – Valores médios globais das medidas de qualidade para segmentação das 100 imagens Gama de 8 *looks* para os diferentes níveis de compressão, usando o modelo de manchas.

A Figura 5.9 apresenta os valores médios para as quatro medidas de qualidade usadas na avaliação das segmentações com diferentes níveis máximos de compressão. Os menores valores de acerto do segmentador ocorrem na medida de forma (*Gf*). As medidas de posição (*Fitxy*) e intensidade (*Fiti*) são as mais elevadas e se mantêm quase que invariáveis para os diferentes níveis máximos de compressão.




FIGURA 5.9 – Valores médios globais das medidas de qualidade sobre as 100 imagens Gama de 8 *looks* para diferentes níveis de compressão, usando o modelo de manchas.

TABELA 5.3 – Valores de média e desvio padrão das medidas de qualidade para as 100 imagens Gama simuladas com 8 *looks*, usando o modelo de manchas.

Número de compressões	Medida	Média	Desvio Padrão	Número Médio de regiões	Tempo Médio
3	Fitxy	0,9856	0,0027	439,5700	5,4665
	Fiti	0,9682	0,0045		
	Fitt	0,7577	0,0206		
	Gf	0,6393	0,0215		
	Global	0,8377	0,0111		
4	Fitxy	0,9848	0,0028	335,2300	1,4258
	Fiti	0,9715	0,0047		
	Fitt	0,7864	0,0225		
	Gf	0,6591	0,0260		
	Global	0,8504	0,0128		
5	Fitxy	0,9866	0,0026	177,3000	0,7802
	Fiti	0,9732	0,0030		
	Fitt	0,8334	0,0170		
	Gf	0,7159	0,0219		
	Global	0,8773	0,0100		
6	Fitxy	0,9864	0,0027	130,9200	0,6877
	Fiti	0,9709	0,0049		
	Fitt	0,8159	0,0200		
	Gf	0,7018	0,0234		
	Global	0,8687	0,0115		
7	Fitxy	0,9825	0,0028	143,6207	0,5854
	Fiti	0,9660	0,0048		
	Fitt	0,7856	0,0206		
	Gf	0,6687	0,0253		
	Global	0,8507	0,0122		

Na Figura 5.10 compara-se o desempenho médio da segmentação sobre as imagens Gama com 3 e 8 *looks*. Através da análise desta figura é possível confirmar que o número de *looks* da imagem original influi principalmente na qualidade da segmentação, mas não no tempo de processamento.

A Figura 5.11 apresenta o número médio de regiões formado quando se segmentam as imagens Gama com 3 e 8 *looks* usando o modelo de manchas. Pode-se observar que as imagens segmentadas de 3 *looks* apresentam um número maior de regiões do que as imagens de 8 *looks*. Portanto, a quantidade de segmentos gerados tende a aumentar quando o número equivalente de *looks* diminui. Assim, tem-se um pior desempenho do segmentador para a imagem com menor número equivalente de *looks*, devido a grande quantidade de ruído, e consequentemente um maior tempo de processamento para se obter a segmentação.




FIGURA 5.10 – Média geral e o tempo médio das segmentações das imagens Gama de 3 e 8 *looks* para os diferentes níveis máximos de compressão, usando o modelo de manchas.




FIGURA 5.11 – Número médio de regiões formado ao segmentar as imagens Gama com 3 e 8 *looks* no modelo de manchas.

5.1.2.2 Imagens Textura Simuladas de 3 e 8 *Looks*

As segmentações das imagens Textura usando o modelo de manchas foram realizadas utilizando os mesmos parâmetros que para as imagens Gama.

A Figura 5.12 apresenta uma das imagens Textura simuladas com 3 *looks*, e as segmentações resultantes quando se aplica diferentes níveis máximos de compressão. Através da análise visual destes resultados, é possível observar que ocorreu uma supersegmentação para todos os níveis máximos de compressão, sendo que o melhor desempenho ocorreu quando se usou seis níveis de compressão.







Imagem 3 looks




N = 3 1233 regiões 18,71 minutos




N = 4 980 regiões 9,04 minutos



N = 5 705 regiões 9,30 minutos



N = 6 712 regiões 8,64 minutos



N = 7 706 regiões 8,34 minutos

FIGURA 5.12 – Imagem original Textura com 3 looks e as respectivas segmentações para os diferentes níveis de compressão, usando o modelo de manchas.

Comparando-se as Figuras 5.4 e 5.12, pode-se observar que o tempo médio de processamento, assim como o número de regiões resultantes para as imagens Textura, é maior em todos os níveis do que para as imagens Gama. Isto é devido ao número de vezes que é feita a resegmentação, pois os critérios de homogeneidade no modelo de manchas não são adequados para imagens de Textura, resegmentando a cada nível, as regiões que não são homogêneas e gerando uma supersegmentação.

As Figuras 5.13, 5.14 e a Tabela 5.4 apresentam os resultados da análise quantitativa. Através da Figura 5.13, pode-se verificar que os resultados médios globais de acerto do segmentador para essas imagens de Textura melhoram com aumento do nível máximo de compressão sobre as imagens. O melhor resultado atinge o valor de 0,75, quando se utiliza seis níveis de compressão. Quando se utiliza sete níveis, obtém-se um resultado inferior (0,74), embora a diferença entre os resultados usando seis e sete níveis não seja estatisticamente diferente a qualquer nível de significância usados na prática. Esta tendência de diminuir após certo nível máximo de compressão pode indicar que exista um número máximo ótimo de compressões, o qual provavelmente está relacionado com o tamanho dos alvos na imagem original.

A Figura 5.14 apresenta os valores de média e as barras de erros correspondente a ± 1 desvio padrão, das medidas usadas para avaliar o segmentador. Os melhores valores são obtidos para as medidas de posição (*Fitxy*) e de intensidade (*Fiti*). Já a medida de forma (*Gf*) apresenta valores abaixo de 0,5. Os maiores desvios padrões correspondem à medida de tamanho (*Fitt*). Esse resultado indica que o critério usado para avaliar a segmentação tende a ser mais rigoroso com as medidas de forma e de tamanho.




FIGURA 5.13 – Valores médios globais obtidos da segmentação sobre as 100 imagens Textura de 3 *looks* para os diferentes níveis de compressão, usando o modelo de manchas.




FIGURA 5.14 – Valores médios globais das medidas de qualidade sobre as 100 imagens Textura de 3 *looks* para os diferentes níveis máximos de compressão, usando o modelo de manchas.

TABELA 5.4 – Valores de média e desvio padrão das medidas de qualidade para as 100 imagens Textura simuladas com 3 *looks*, usando o modelo de manchas.

Número de compressões	Medida	Média	Desvio Padrão	Número Médio de regiões	Tempo Médio
3	Fitxy	0,9744	0,0038	1247,8500	20,5909
	Fiti	0,9321	0,0097		
	Fitt	0,5572	0,0245		
	Gf	0,3600	0,0210		
	Global	0,7059	0,0118		
4	Fitxy	0,9757	0,0035	1002,0300	9,1966
	Fiti	0,9368	0,0079		
	Fitt	0,5829	0,0233		
	Gf	0,3788	0,0194		
	Global	0,7185	0,0109		
5	Fitxy	0,9756	0,0038	736,4900	9,2576
	Fiti	0,9434	0,0087		
	Fitt	0,6241	0,0252		
	Gf	0,4281	0,0213		
	Global	0,7428	0,0122		
6	Fitxy	0,9764	0,0036	738,9200	9,9617
	Fiti	0,9423	0,0076		
	Fitt	0,6596	0,0293		
	Gf	0,4512	0,0248		
	Global	0,7574	0,0137		
7	Fitxy	0,9745	0,0035	762,1600	9,5462
	Fiti	0,9416	0,0083		
	Fitt	0,6336	0,0272		
	Gf	0,4287	0,0229		
	Global	0,7446	0,0129		

A Figura 5.15 apresenta a segmentação de uma das imagens simuladas com textura em 8 *looks* para os níveis de compressão considerados. A análise visual dos resultados mostra um desempenho melhor do que as de 3 *looks*, sendo o melhor resultado obtido usando seis níveis de compressão. Todos os resultados apresentaram supersegmentações.

As Figuras 5.16, 5.17 e a Tabela 5.5 apresentam os resultados para a análise quantitativa para as imagens Textura com 8 *looks* usando o modelo de manchas.

TABELA 5.5 – Valores de média e desvio padrão das medidas de qualidade para as 100 imagens Textura simuladas com 8 *looks*, usando o modelo de manchas.

Número de compressões	Medida	Média	Desvio Padrão	Número Médio de regiões	Tempo Médio
3	Fitxy	0,9806	0,0030	1138,8100	11,4704
	Fiti	0,9488	0,0089		
	Fitt	0,6318	0,0203		
	Gf	0,4939	0,0171		
	Global	0,7638	0,0099		
4	Fitxy	0,9808	0,0032	826,0900	2,3541
	Fiti	0,9541	0,0070		
	Fitt	0,6575	0,0187		
	Gf	0,5015	0,0179		
	Global	0,7735	0,0097		
5	Fitxy	0,9821	0,0032	451,2600	0,6990
	Fiti	0,9583	0,0061		
	Fitt	0,7215	0,0187		
	Gf	0,5692	0,0222		
	Global	0,8078	0,0105		
6	Fitxy	0,9833	0,0026	354,7200	0,8604
	Fiti	0,9614	0,0069		
	Fitt	0,7388	0,0207		
	Gf	0,5831	0,0194		
	Global	0,8166	0,0104		
7	Fitxy	0,9785	0,0030	394,3000	0,9014
	Fiti	0,9585	0,0065		
	Fitt	0,7178	0,0259		
	Gf	0,5612	0,0267		
	Global	0,8040	0,0137		







Imagem 8 looks




N = 3 1139 regiões 11,77 minutos




N = 4 806 regiões 2,35 minutos



N = 5 459 regiões 0,59 minutos



N = 6 323 regiões 0,79 minutos



N = 7 381 regiões 0,67 minutos

FIGURA 5.15 – Imagem original Textura com 8 looks e as respectivas segmentações para os diferentes níveis de compressão, usando o modelo de manchas.




FIGURA 5.16 – Valores médios globais obtidos da segmentação sobre as 100 imagens Textura de 8 *looks* para os diferentes níveis de compressão, usando o modelo de manchas.




FIGURA 5.17 – Valores médios globais das medidas de qualidade sobre as 100 imagens Textura de 8 *looks* para os diferentes níveis de compressão, usando o modelo de manchas.

O melhor valor médio global (Figura 5.16) para a imagem simulada em 8 *looks* foi de 0,82 quando se usa seis níveis de compressão, e o pior valor foi de 0,76 para o nível máximo de compressão igual a três. Com o aumento do nível máximo de compressões se observa um ganho no resultado da segmentação até o nível seis, sendo que usando sete níveis de compressão o valor de acerto do segmentador diminui embora, esta diferença não seja estatisticamente significativa. Isto ocorre tanto para imagens Gamas como para imagens de Textura, podendo indicar que usando sete níveis de compressão, classes diferentes são agrupadas e o critério de homogeneidade não é sensível o suficiente para vir a resegmentar essas regiões. O tempo médio global é bem menor do que para a imagem Textura com 3

looks, o que é um reflexo do número de regiões gerado no processo de segmentação.

A Figura 5.17 apresenta os valores de média e as barras de erros correspondente a ± 1 desvio padrão, para as medidas usadas para avaliar o segmentador. Da mesma maneira que nos casos anteriores, as medidas de posição (*Fitxy*) e intensidade (*Fiti*) apresentaram valores superiores a 0,9 e pouca variação para os diferentes níveis máximos de compressão. Já as medidas de tamanho e forma apresentaram valores em torno de 0,7 e 0,5 respectivamente; estas medidas apresentaram variações quando se utiliza diferentes valores para os níveis máximos de compressão, sendo que a utilização de seis níveis leva a melhores resultados. Cabe observar que, entretanto, não há diferença estatisticamente significativa entre os resultados dos níveis 5, 6 e 7.

A Figura 5.18 permite comparar o desempenho médio da segmentação das imagens Textura de 3 e 8 *looks* sob o modelo de manchas. Os melhores resultados para ambas as imagens ocorre quando se utiliza seis níveis de compressão, muito embora não haja diferença significativa entre os resultados dos níveis 5, 6 e 7.




FIGURA 5.18 – Média geral e o tempo médio das segmentações das imagens Textura de 3 e 8 *looks* para os diferentes níveis de compressão, usando o modelo de manchas.

A Figura 5.19 apresenta o número médio de regiões formado quando se segmentam as imagens Textura com 3 e 8 *looks* usando o modelo de manchas. Pode-se observar que as imagens segmentadas de 3 *looks* apresentam um número maior de regiões do que as imagens de 8 *looks*. Portanto, a quantidade de segmentos gerados tende a aumentar quando o número equivalente de *looks* diminuiu. Assim, tem-se um pior desempenho do segmentador para a imagem com menor número equivalente de *looks*, e consequentemente um maior tempo de processamento para se obter a segmentação.




FIGURA 5.19 – Número médio de regiões formado ao segmentar as imagens Textura com 3 e 8 *looks* no modelo de manchas.

5.1.3 Modelo de Textura

O modelo de textura foi utilizado somente para segmentar as imagens Textura. Os parâmetros usados para fazer as segmentações foram os valores *default* do programa: similaridade igual a 1dB, área mínima igual a 40 *pixels*, e coeficiente de variação igual a 0,6. A Figura 5.20 apresenta uma imagem Textura simulada com 3 *looks*, e as segmentações resultantes quando se aplica diferentes níveis máximos de compressão. A Figura 5.21 corresponde a uma imagem Textura simulada com 8 *looks*, assim como as segmentações resultantes quando se aplica diferentes níveis máximos de compressão.







Imagem 3 looks




N = 3 1890 regiões 55,71 minutos




N = 4 1398 regiões 62,18 minutos



N = 5 1474 regiões 32,80 minutos



N = 6 1369 regiões 41,40 minutos



N = 7 1379 regiões 36,13 minutos

FIGURA 5.20 – Imagem original Textura com 3 looks e as respectivas segmentações para os diferentes níveis de compressão, usando o modelo de textura.







Imagem 8 looks




N = 3 996 regiões 69,89 minutos




N = 4 430 regiões 26,48 minutos



N = 5 386 regiões 3,76 minutos



N = 6 330 regiões 13,49 minutos



N = 7 340 regiões 13,87 minutos

FIGURA 5.21 – Imagem original Textura com 8 looks e as respectivas segmentações para os diferentes níveis de compressão, usando o modelo de textura.

Os resultados da análise quantitativa para as imagens de 3 *looks* são mostrados nas Figuras 5.22, 5.23 e Tabela 5.6. Pela análise da Figura 5.22, pode-se observar que o modelo apresentou um desempenho abaixo do esperado. Os valores de acerto do segmentador *SegSAR*, abaixo de 0,7 em todos os níveis, estão abaixo dos valores obtidos pelo modelo de manchas para estas imagens. Este baixo desempenho pode estar relacionado como os testes implementados para o modelo de textura, os quais se baseiam somente no coeficiente de variação.




FIGURA 5.22 – Valores médios globais obtidos da segmentação sobre as 100 imagens Textura de 3 *looks* para os diferentes níveis de compressão, usando o modelo de textura.




FIGURA 5.23 – Valores médios globais das medidas de qualidade sobre as 100 imagens Textura de 3 *looks* para os diferentes níveis de compressão, usando o modelo de textura.

TABELA 5.6 – Valores de média e desvio padrão das medidas de qualidade para as 100 imagens Textura simuladas com 3 *looks*, usando o modelo de textura.

Número de compressões	Medida	Média	Desvio Padrão	Número Médio de regiões	Tempo Médio
3	Fitxy	0,9528	0,0073	990,8000	80,4333
	Fiti	0,9186	0,0079		
	Fitt	0,4848	0,0317		
	Gf	0,3373	0,0209		
	Global	0,6734	0,0145		
4	Fitxy	0,9504	0,0093	792,2000	96,0140
	Fiti	0,9204	0,0103		
	Fitt	0,4962	0,0250		
	Gf	0,3509	0,0191		
	Global	0,6795	0,0125		
5	Fitxy	0,9522	0,0124	791,0500	91,1747
	Fiti	0,9218	0,0092		
	Fitt	0,5346	0,0293		
	Gf	0,3753	0,0238		
	Global	0,6960	0,0166		
6	Fitxy	0,9535	0,0102	805,8500	78,2013
	Fiti	0,9186	0,0093		
	Fitt	0,5099	0,0243		
	Gf	0,3598	0,0219		
	Global	0,6855	0,0137		
7	Fitxy	0,9533	0,0096	803,0500	77,7325
	Fiti	0,9211	0,0073		
	Fitt	0,5188	0,0263		
	Gf	0,3657	0,0208		
	Global	0,6897	0,0128		

Analisando a Figura 5.23 se observa que as medidas de posição e intensidade apresentam valores superiores a 0,9, resultados estes similares aos obtidos pelo modelo de manchas. Os resultados apresentaram um baixo desempenho para as medidas de tamanho e forma, fazendo com que a média global apresente baixos valores de acerto para o segmentador.

Os resultados das segmentações para o conjunto de imagens Textura com 8 *looks* apresentaram valores superiores ao das imagem de 3 *looks*, mas esses valores ainda são muito baixos quando comparados com os resultados obtidos usando o modelo de manchas para o mesmo conjunto de imagens. Os resultados dos níveis 4 a 7 têm valores similares, sendo que o valor do nível 3 é inferior aos demais (Figura 5.24 e Figura 5.25). Os valores médios para cada medida, assim como os respectivos desvios padrões são mostrados na Tabela 5.7.




FIGURA 5.24 – Valores médios globais obtidos da segmentação sobre as 100 imagens Textura de 8 *looks* para os diferentes níveis de compressão, usando o modelo de textura.




FIGURA 5.25 – Valores médios globais das medidas de qualidade sobre as 100 imagens Textura de 8 *looks* para os diferentes níveis de compressão, usando o modelo de textura.

A Figura 5.26 permite comparar o desempenho médio da segmentação das imagens Textura de 3 e 8 *looks*, segundo o número máximo de níveis de compressão. Apesar do desempenho médio ter sido menor para o modelo de textura, este modelo apresenta resultados melhores quanto ao número de regiões da imagem segmentada final. A imagem Textura segmentada com o modelo de textura apresenta um número sistematicamente menor de segmentos que quando segmentadas pelo modelo de manchas, como pode ser visto nas Figuras 5.27 e 5.28, para as imagens com 3 e 8 *looks*.

TABELA 5.7 – Valores de média e desvio padrão das medidas de qualidade para as 100 imagens Textura simuladas com 8 *looks*, usando o modelo de textura.

Número de compressões	Medida	Média	Desvio Padrão	Número Médio de regiões	Tempo Médio
3	Fitxy	0,9355	0,0152	491,2000	138,1936
	Fiti	0,9221	0,0080		
	Fitt	0,5522	0,0422		
	Gf	0,4215	0,0382		
	Global	0,7078	0,0239		
4	Fitxy	0,9502	0,0191	240,4500	48,3983
	Fiti	0,9320	0,0109		
	Fitt	0,6316	0,0582		
	Gf	0,4975	0,0482		
	Global	0,7528	0,0331		
5	Fitxy	0,9467	0,0199	197,0000	23,6758
	Fiti	0,9261	0,0089		
	Fitt	0,6175	0,0475		
	Gf	0,4909	0,0364		
	Global	0,7453	0,0271		
6	Fitxy	0,9484	0,0166	195,5000	26,4537
	Fiti	0,9299	0,0087		
	Fitt	0,6232	0,0465		
	Gf	0,4991	0,0326		
	Global	0,7489	0,0247		
7	Fitxy	0,9504	0,0215	208,1000	25,2240
	Fiti	0,9318	0,0090		
	Fitt	0,6292	0,0452		
	Gf	0,4967	0,0360		
	Global	0,7520	0,0265		




FIGURA 5.26 – Média geral das segmentações das imagens Textura de 3 e 8 *looks* para os diferentes níveis de compressão, usando o modelo de textura.




FIGURA 5.27 – Número médio de regiões formado ao segmentar as imagens Textura com 3 *looks* nos modelos de mancha e textura.




FIGURA 5.28 – Número médio de regiões formado ao segmentar as imagens Textura com 8 *looks* nos modelos de mancha e textura.

5.1.4 Imagens Reais

O segmentador *SegSAR* foi utilizado para segmentar uma imagem de radar na banda X do sensor aerotransportado AeS-1 (800 x 1000 *pixels*), com resolução de 1m e número equivalente de *looks* igual a 6 (Figura 5.29). Esta imagem foi segmentada usando os modelos de manchas e de textura, utilizando como parâmetros de entrada: similaridade igual a 1db, área mínima de 20 *pixels*, nível de confiança de 95% para o modelo de manchas, e coeficiente de variação de 0,6 para o modelo de textura (*default* do programa); em ambos os casos o nível máximo de compressão utilizado foi 6.



Banda X com 6 looks

FIGURA 5.29 – Imagem de radar Banda X com 6 *looks* e resolução de 1 metro.

A Figura 5.30 mostra os resultados da segmentação para os dois modelos. O resultado do modelo de manchas mostra que todas as feições que aparecem na imagem foram discriminadas, porém houve uma supersegmentação de todas as classes; já a análise visual da segmentação resultante do modelo de textura apresenta uma boa separação das classes que constam na imagem, principalmente para as áreas com altos valores de *backscatter*.

5.2 Aplicações do *SegSAR* sobre Imagens Ópticas

A seguir serão mostrados os resultados obtidos da aplicação do segmentador *SegSAR* em imagens ópticas. No primeiro caso, foi realizada uma comparação das segmentações de uma mesma área geográfica com imagens *Jers* e *TM/Landsat*; no segundo caso, foi segmentada uma imagem *ETM+* de uma área agrícola.




FIGURA 5.30 – Imagem banda X segmentada com o modelo de manchas e com o modelo textura.

5.2.1 Segmentação *TM/Landsat* Versus *JERS*

Foram utilizadas duas imagens de 1996, uma óptica e uma de radar, correspondentes a uma mesma região da Floresta Nacional do Tapajós, Estado do Pará. (Figura 5.31). A imagem *TM/Landsat* (300 colunas e 278 linhas) tem uma resolução de 30 m e foram utilizadas as bandas 3, 4 e 5. Já a imagem *JERS* (720 colunas e 667 linhas) tem uma resolução de 12,5 m e número equivalente de *looks* estimado em 3,5.

A imagem *TM/Landsat* foi segmentada nos níveis 4, 5 e 6 utilizando como limiares de área e similaridade o valor 10, e o nível de confiança de 95%. A imagem *Jers* foi segmentada nos níveis 5, 6 e 7 com limiar de similaridade igual a 5 *dB*, área mínima igual a 20 e nível de confiança de 95%. Para ambas as imagens, foi utilizado o modelo de manchas.

Os melhores resultados foram obtidos com os níveis de compressão 4 para a imagem *TM/Landsat* e 6 para a imagem *Jers*. A Figura 5.32 mostra os resultados da segmentação para as duas imagens. O número de regiões da imagem segmentada foi de 425 para a imagem óptica e 672 para a imagem de radar. Pode-se observar que, apesar do maior número de segmentos, a imagem segmentada de radar apresenta, em muitos casos, regiões

aparentemente coincidentes com o resultado da imagem óptica. Pode-se considerar bom este resultado sobre a imagem de radar, pois se tem apenas uma banda (polarização) da imagem *Jers* contra três bandas da imagem *Landsat*.




FIGURA 5.31 – Imagem *TM/LANDSAT* na composição RGB-543 e a imagem *JERS*.




FIGURA 5.32 – Imagem *TM/LANDSAT* segmentada com 4 níveis de compressão e imagem *JERS* segmentada com 6 níveis.

5.2.2 Segmentação de Imagem *ETM+/Landsat*

O segmentador *SegSAR* foi aplicado em uma imagem do sensor *ETM+/Landsat*, bandas ETM+3, ETM+4 e ETM+5 com resolução de 30 metros e tamanho da imagem de 600 linhas x 600 colunas. Esta imagem corresponde a uma área de uso agrícola localizada no Município de Miguelópolis, ao norte do Estado de São Paulo (Figura 5.33).




FIGURA 5.33 – Imagem do sensor *ETM+/Landsat* da região de Miguelópolis (SP) composição 453.

Inicialmente, a imagem foi segmentada com os valores *default* para o modelo de manchas: 5 níveis de compressão, limiar de similaridade 62, limiar de área 20, nível de confiança 95%, e coeficiente de variação 0,30. Posteriormente foram realizadas diferentes segmentações mudando apenas os níveis de compressão (para 3 e 7), e num outro caso, mudando o coeficiente de variação (para 0,6 e 0,9).

Foi realizada uma análise visual sobre os resultados das segmentações e verificou-se que a imagem segmentada com os parâmetros *default* apresentou o melhor resultado, tanto na separação das feições na imagem quanto na precisão das bordas (Figura 5.34). O tempo de processamento para esta imagem foi de 2,03 minutos e o número de regiões igual a 823.




FIGURA 5.34 – Imagem segmentada da região de Miguelópolis (SP) usando o *SegSAR* com 5 níveis de compressão.

Adicionalmente, se observou que com o aumento do coeficiente de variação para 0,60 e 0,90 houve uma diminuição tanto no tempo de processamento (1,39 e 1,35 respectivamente) quanto no número de regiões obtido (774 e 769). Na imagem resultante da segmentação no nível 7, verificou-se que houve alguns casos em que parte da borda de uma região não coincidia com o limite real do alvo, sendo isto causado pela generalização da informação neste nível.

CAPÍTULO 6

CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES

O segmentador *SegSAR* apresenta-se como um novo segmentador que tem flexibilidade para segmentar tanto imagens de radar como imagens ópticas, fazendo uso de modelos de manchas e de textura. A combinação com uma estrutura de compressão piramidal e com as técnicas de segmentação, faz com que o *SegSAR* torne-se um segmentador com características únicas.

A compressão por pirâmide hierárquica junto com os testes de segmentação apresentados neste trabalho, mostraram-se ser muito eficientes para segmentação de imagens. O processo de segmentação se inicia sobre a imagem com maior compressão, e a cada nível da pirâmide essa segmentação vai sendo melhorada. Com isso obtém-se um ganho no processo de segmentação, sendo esse ganho mais evidente para os resultados sobre imagens de radar.

O *SegSAR* apresenta um grande potencial, pois faz um processo diferenciado para cada modelo adotado para representar a imagem no processo de segmentação. No geral, as segmentações sobre os modelos de manchas apresentam resultados melhores que os obtidos pelo modelo de textura.

O uso dos modelos de mancha e de textura, tanto para imagens de radar como para ópticas, apresenta-se como uma nova possibilidade de se fazer segmentação, pois o usuário tem a opção de escolher um modelo que melhor representa a imagem que está sendo segmentada, podendo assim obter melhores resultados.

A segmentação de imagens de radar com regiões homogêneas utilizando o modelo de manchas apresentou resultados excelentes, mostrando que este modelo quando combinado como o processo de pirâmide de compressão é muito eficiente. Já o modelo de textura para imagens de radar apresentou um desempenho abaixo do esperado quando usado nas imagens simuladas. Esse baixo desempenho do segmentador usando o modelo de textura não ocorreu quando utilizado sobre imagens reais, o que leva a concluir que é necessário se fazer mais testes para ver a verdadeira eficiência deste modelo.

A segmentação sobre imagens ópticas, no geral, apresentou resultados satisfatórios, sendo que o modelo de manchas apresentou resultados melhores que o modelo de textura.

Este trabalho apresenta inovações de grande relevância para segmentação de imagens, como o uso da representação hierárquica por pirâmide, a qual permite a obtenção de

segmentações intermediárias, uma inovação no processo de segmentação.

A segmentação incremental é mais uma inovação neste trabalho, pois permite que a cada nível seja agregada informação à segmentação existente para melhorar o resultado da segmentação final. O *SegSAR* permite trabalhar com multi-bandas, segmentando a imagem em multi-níveis para gerar uma segmentação mais precisa.

Para uma melhoria no processo de segmentação usando *SegSAR*, são recomendados para trabalhos futuros:

- a) Melhorar o teste de homogeneidade para regiões, acrescentando a relação espacial.
- b) Fazer testes em diversos tipos de imagens, de vários sensores, para avaliar o potencial do segmentador *SegSAR*, principalmente para os modelos de textura para imagens de radar e óptica.
- c) Desenvolver um teste que seja melhor que o teste de coeficiente de variação para segmentar as imagens.
- d) Implementar a opção de segmentar partes da imagem durante o processo de segmentação.
- e) Desenvolver testes para imagens de radar usando a distribuição G . Esta distribuição apresenta-se como sendo um caso mais geral, pois dela pode-se obter todas as outras distribuições que modelam dados de radar.
- f) Melhorar a forma com que os dados são armazenados na estrutura, para diminuir a quantidade de memória ocupada durante o processo de segmentação.

REFERÊNCIAS BIBLIOGRÁFICAS

- Beaulieu, J. M.; Touzi, R. Hierarchical segmentation of polarimetric SAR images. In: International Geoscience and Remote Sensing Symposium (IGARSS'02) and Canadian Symposium on Remote Sensing, 24., 2002. **Proceedings...** Toronto, Canada: IGARSS, 2002. p. 2590–2592. [38](#), [44](#)
- Caves, R.; Quegan, S.; White, R. G. Quantitative comparison of the performance of SAR segmentation algorithms. **IEEE Transactions on Image Processing**, v. 7, n. 11, p. 1534–1546, Nov. 1998. [37](#), [44](#)
- Caves, R. G. **Automatic matching of features in synthetic aperture radar data to digital map data**. Tese – (Doctor in Applied and Computational Mathematics) - University of Sheffield, Sheffield, 1993. [29](#), [30](#), [31](#), [33](#), [35](#)
- Chang, S.-K. **Principles of pictorial information systems design**. Englewood Cliffs: Prentice Hall, 1989. 369 p. [41](#), [44](#)
- Cook, R.; McConnell, I.; Stewart, D.; Oliver, C. MUM (Merge Using Moments) segmentation for SAR images. In: Euro SAR Data Processing for Remote Sensing, 1994, Rome. **Proceedings...** Rome, Italy: SPIE, 1994. p. 92–103. [38](#), [44](#)
- DeGroot, M. H.; Schervish, M. J. **Probability and statistics**. 3. ed. Boston: Addison-Wesley., 2002. 816 p. [23](#), [75](#)
- Delves, L. M.; Wilkinson, R.; Oliver, C. J.; White, R. G. Comparing the performance of SAR segmentation algorithms. **International Journal of Remote Sensing**, v. 13, n. 11, p. 21221–21249, Jul. 1992. [46](#), [48](#)
- Elachi, C. **Spaceborne radar remote sensing**:. applicatons and techniques. New York: IEEE PRESS, 1987. 255 p. [27](#), [31](#)
- Fishman, G. S. **Concepts and methods in discrete event digital simulation**. New York: John Willey, 1973. 400 p. [62](#)
- Freitas, C. C.; Frery, A. C. O.; Correia, A. H. The polarimetric $\mathcal{G}$ distribution for SAR data analysis. **Environmetrics**, v. 16, n. 1, p. 13–31, Jan. 2005. [34](#), [35](#)
- FRERY, A. C. O. **Algumas ferramentas estatísticas na síntese, processamento e análise de imagens de radar de abertura sintética**. 242 p. Tese – (Doutorado em Computação Aplicada) Instituto Nacional de Pesquisas Espaciais - INPE, São José dos Campos - SP, Out. 1993. [32](#), [35](#)

Frery, A. C. O.; Müller, H.; Freitas, C. C.; Sant'Anna, S. J. S. A model for extremely heterogeneous clutter. **IEEE Transactions on Geoscience and Remote Sensing**, v. 35, n. 3, p. 648–659, May 1997. [33](#), [34](#), [35](#), [81](#)

Frery, A. C. O.; Yanasse, C. C. F.; Sant'Anna, S. J. S. Statistical characterization of SAR data: the multiplicative model and extensions. In: SELPER '95 Simpósio Latinoamericano de Percepción Remota, 7. **Proceedings...** Puerto Vallarta, 1995. p. 505–515. Memorias. [56](#)

Frost, V. S.; Shanmugan, K.; Holtzman, J. C. Edge detection for synthetic aperture radar and other noisy images. In: 1982 International Geoscience and Remote Sensing Symposium (IGARSS'82). **Proceedings...** Munich, Germany, 1982. v. FA2, p. 4.1–4.9. [45](#)

Gerbrands, J. J. **Land observation by remote sensing: theory and applications**. 2ed. Amsterdam: Gordon and Breach Science, 1996. p. 275–286. [37](#)

Gonzales, R. C.; Wintz, P. **Digital image processing**. New York: Addison-Wesley, 1987. [37](#)

Haralick, R. M.; Shapiro, L. G. **Computer and robot vision**. New York: Addison-Wesley Publishing Company, 1992. 672 p. [44](#)

Henderson, F. M.; Lewis, A. J., ed. **Principle and applications of imaging radar - Manual of remote sensing**. 3. ed. New York: John Wiley and Sons, Inc., 1999. v. 2, Ryerson, A. R., American Society for Photogrammetry and Remote Sensing. 869 p. [25](#)

Hoel, P. G.; Port, S. C.; Stone, C. J. **Introduction to probability theory**. Boston: Addison-Wesley, 1978. 269 p. [23](#)

Jain, R.; Kasturi, R.; Schunck, B. G. **Machine vision**. New York: McGraw-Hill, 1995. 549p. [37](#), [39](#), [40](#), [41](#), [43](#)

Jakeman, E. On the statistics of K-distributed noise. **Journal of Physics A: Mathematical and General**, v. 13, n. 1, p. 31–48, 1980. [33](#)

Jähne, B. **Digital image processing - concepts, algorithms, and scientific applications**. 4. ed. Berlin: Springer-Verlag, 1997. 555 p. [41](#)

LUCCA, E. V. D. **Avaliação e comparação de algoritmos de segmentação de imagens de radar de abertura sintética**. 207 p. Dissertação – (Mestrado em

Sensoriamento Remoto) Instituto Nacional de Pesquisas Espaciais - INPE, São José dos Campos - SP, Dez. 1998. [46](#), [81](#), [82](#)

Marque, O. F.; Viera, H. N. **Processamento digital de imagens**. [S.l.]: BRASPORT,, 1999. 406p. [23](#)

Mascarenhas, N. D. A.; Frery, A. C. SAR image filtering with the ICM algorithm. In: 1994 Geoscience and Remote Sensing Symposium (IGARSS'94). Surface and Atmospheric Remote Sensing Technologies, Data, Analysis and Interpretation. **Proceedings...** Pasadena, CA, USA, 1994. v. 4, p. 2185–2187. [24](#)

Mezaris, V.; Kompatsiaris, I.; Strintzis, M. G. Still image objective segmentation evaluation using ground truth. In: COST 276 Workshop on Information and Knowledge Management for Integrated Media Communication, 5., 2003, Prague. **Proceedings...** Czech Republic, 2003. p. 9–14. [45](#)

Min, J.; Powell, M.; Bowyer, K. W. Automated performance evaluation of range image segmentation algorithms. **IEEE Transaction on Systems, Man, and Cybernetics**, v. 34, n. 1, p. 263–271, Feb. 2004. [45](#)

Nathanson, F. D. **Radar design principles**. 2. ed. New York: McGraw-Hill, 1991. 720 p. [24](#), [25](#)

Oliver, C.; Quegan, S. **Understanding synthetic aperture radar images**. London: Artech House, 1998. 479 p. [44](#)

Pitas, I. **Digital image processing algorithms and applications**. New York: John Wiley & Sons, 2000. 419 p. [39](#), [41](#)

Rosenfeld, A. **Multiresolution image processing and analysis**. New York: Springer-Verlag,, 1984. 12, 385 p. [41](#), [60](#)

Tilton, J. C. Hierarchical image segmentation: as applied to remotely sensed multispectral or hyperspectral imagery. Disponivel em: <<http://backserv.gsfc.nasa.gov/code935/tilton/>>. Acesso em: 11 jun. 2000., 1999. [44](#)

Tilton, J. C.; Lawrence, W. T. Interactive analysis of hierarchical image segmentation. In: 2000 International Geoscience and Remote Sensing Symposium (IGARSS'00). **Proceedings...** Honolulu, HI, USA, 2000. v. 2, p. 733–735. [44](#)

Ulaby, F. T.; Dobson, M. C. **Handbook of radar scattering statistics for terrain**. Norwood, MA: Artech House, 1989. 357 p. [24](#), [26](#), [28](#)

Ulaby, F. T.; Moore, R. K.; Funk, A. K. **Microwave remote sensing: active and passive: radar remote sensing and surface scattering and emission theory.** 2. ed. Norwood, MA: Artech House, 1986. v. II. Radar remote sensing and surface scattering and emission theory., 608 p. [24](#), [25](#)

VIEIRA, P. R. **Desenvolvimento de classificadores de máxima verossimilhança para imagens SAR.** Dissertação – (Mestrado em Sensoriamento Remoto) Instituto Nacional de Pesquisas Espaciais - INPE, São José dos Campos - SP, Ago. 1996. [33](#), [58](#)

White, R. G. **Low-level segmentation of noise imagery.** Memorandum 3900, 1986. [S.l.]:Royal Signal and Radar Establishment,. [38](#), [43](#), [45](#)

Yanasse, C. C. F. **Statistical analysis of synthetic aperture radar images and its applications to system analysis and change detection.** Tese – (Doctor in Probability and Statistics) - University of Sheffield, Sheffield, UK, 1991. [31](#), [35](#)

Yanasse, C. C. F.; Frery, A. C. O.; Sant´Anna, S. J. S. **Stochastic distributions and the multiplicative model: relations, properties, estimators and applications to SAR image analysis.** São José dos Campos: INPE, 1995. [32](#), [35](#), [39](#), [56](#)

Yong, X.; Feng, D. D.; Rongchun, Z. Optimal selection of image segmentation algorithms based on performance prediction. In: 2003 Pan-Sydney Area Workshop on Visual Information Processing (VIP2003). Conferences in Research and Practice in Information Technology. **Proceedings...** Sydney. Australia, 2004. v. 36, p. 105–108. [37](#)

Zaart, A. E.; Ziou, D.; Wang, S.; Jiang, Q. Segmentation of SAR images. **Pattern Recognition**, v. 35, p. 713–724, 2002. [38](#)

Zaart, A. E.; Ziou, D.; Wang, S.; Jiang, Q.; Bénie, G. B. SAR images segmentation using mixture of Gamma distribution. In: Vision Interface’99. **Proceedings...** Trois-Rivres, Canada, 1999. p. 125–130. 19-21. [38](#)

Zhang, Y. J. A survey on evaluation methods for image segmentation. **Pattern Recognition**, v. 29, n. 8, p. pp.1335–1345, Aug. 1996. [45](#)

APÊNDICE A

ALGUMAS DISTRIBUIÇÕES ESTATÍSTICAS E SUAS PROPRIEDADES

A.1 Distribuição Normal

Uma variável aleatória X é dita ser normalmente distribuída com média $\mu \in \mathbb{R}$ e variância $\sigma^2 \in \mathbb{R}_+$, se a sua densidade for dada, para todo $x \in \mathbb{R}$

$$f_X(x; \mu, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}. \quad (\text{A.1})$$

Este caso é denotado por $X \sim N(\mu, \sigma^2)$. Segue que se $X \sim N(\mu, \sigma^2)$ então $X' = \frac{X-\mu}{\sigma} \sim N(0, 1)$, a qual é denominada distribuição normal padrão. Tem-se, portanto, que se $X \sim N(\mu, \sigma^2)$, então a média e variância de X são dadas por:

$$\begin{aligned} E(X) &= \mu \\ \text{Var}(X) &= \sigma^2 \end{aligned}$$

A.2 Distribuição Constante

A variável aleatória X é dita degenerada em $k \in \mathbb{R}$, ou possuir uma distribuição Constante igual a k , denotada por $X \sim \mathcal{C}(k)$, se X possuir para todo $x \in \mathbb{R}$ a sua função de distribuição acumulada dada por:

$$F_X(x) = 1_{[k, \infty)}(x), \quad (\text{A.2})$$

onde $1_A(x)$ é a função indicadora de um conjunto A , denotada por $1I : A \rightarrow \{0, 1\}$ e definida como:

$$1_A(x) = \begin{cases} 1, & \text{se } x \in A. \\ 0, & \text{se } x \notin A. \end{cases} \quad (\text{A.3})$$

A.3 Distribuição Exponencial Padrão

Uma *v.a.* X é dita possuir uma distribuição exponencial padrão com média unitária se sua densidade, para todo $x \in \mathbb{R}$, for dada por

$$f_X(x) = e^{-x} 1_{\mathbb{R}_+}(x) \quad (\text{A.4})$$

Este caso é denotado por $X \sim \mathcal{E}(1)$.

A.4 Distribuição Exponencial

Seja $X' \sim \mathcal{E}(1)$ e $\beta \in \mathbb{R}_+$. A variável aleatória $X = \beta^{-1}X'$ é dita possuir uma distribuição exponencial com parâmetro β . Sua densidade, para todo $x \in \mathbb{R}$ é dada por:

$$f_X(x; \beta) = \beta e^{-\beta x} 1_{\mathbb{R}_+}(x) \quad (\text{A.5})$$

Este caso é denotado por $X \sim \mathcal{E}(\beta)$, e seus momentos de ordem r são dados por:

$$E(X^r) = \beta^{-1} \Gamma(r+1), \quad (\text{A.6})$$

onde a função $\Gamma(\beta)$ é a função Gama que é definida por:

$$\Gamma(\beta) = \int_0^\infty x^{\beta-1} e^{-x} dx \quad (\text{A.7})$$

Para valores inteiros de n , o cálculo da $\Gamma(n)$ é facilmente obtido por:

$$\Gamma(n) = (n-1)! \quad n = 1, 2, \dots$$

A média e variância de uma v.a. $X \sim \mathcal{E}(\beta)$ são dadas por:

$$E(X) = 1/\beta \quad (\text{A.8})$$

$$Var(X) = 1/\beta^2 \quad (\text{A.9})$$

A.5 Distribuição Gama Padrão

Seja $n \in \mathbb{N}$ um número inteiro positivo e seja $(X_i)_{1 \leq i \leq n}$ uma coleção de variáveis aleatórias independentes e identicamente distribuídas, tal que $X_i \sim \mathcal{E}(1)$. Então a variável aleatória definida pela soma $X = \sum_{i=1}^n X_i$ é dita possuir uma distribuição Gama Padrão com parâmetro n , e neste caso é denotada por $X \sim \Gamma(n, 1)$. Sua densidade é dada, para

todo $x \in \mathbb{R}$, por

$$f_X(x; n, 1) = \frac{x^{n-1}}{\Gamma(n)} e^{-x} 1_{\mathbb{R}_+}(x). \quad (\text{A.10})$$

A.6 Distribuição Gama

Seja $X' \sim \Gamma(n, 1)$ e $\beta \in \mathbb{R}_+(x)$. A variável aleatória $X = \beta^{-1}X'$ é dita possuir uma distribuição Gama com parâmetros n e β e sua densidade, para todo $x \in \mathbb{R}$, é dada por

$$f(x; n, \beta) = \frac{\beta^n}{\Gamma(n)} x^{n-1} e^{-\beta x} 1_{\mathbb{R}_+}(x). \quad (\text{A.11})$$

Este caso é denotado por $X \sim \Gamma(n, \beta)$, e seus momentos de ordem r são dados por:

$$E(X^r) = \frac{\Gamma(n+r)}{\beta^r \Gamma(n)}. \quad (\text{A.12})$$

Portanto, se $X \sim \Gamma(n, \beta)$, X possui média e variância dadas por:

$$E(X) = \frac{n}{\beta} \quad (\text{A.13})$$

$$Var(X) = \frac{n}{\beta^2} \quad (\text{A.14})$$

Pode-se verificar que o quadrado do coeficiente de variação de $X \sim \Gamma(n, \beta)$ será:

$$CV^2(X) = \frac{1}{n} \quad (\text{A.15})$$

APÊNDICE B

VALORES CRÍTICOS DE COEFICIENTE DE VARIAÇÃO DA DISTRIBUIÇÃO GAMA

TABELA B.1 – VALORES CRÍTICOS DE CV A 0,1% OBTIDOS POR SIMULAÇÃO DE
MONTE CARLO.

nel	Tamanho da amostra												
	10	20	30	40	50	...	100	...	500	...	1000	...	9000
1	1,945	1,734	1,777	1,606	1,582		1,330		1,149		1,114		1,035
2	1,327	1,212	1,126	1,054	0,998		0,940		0,797		0,778		0,725
3	1,069	0,919	0,903	0,852	0,820		0,742		0,646		0,623		0,592
4	0,953	0,806	0,743	0,733	0,697		0,638		0,552		0,538		0,513
5	0,822	0,718	0,667	0,656	0,618		0,565		0,495		0,481		0,457
6	0,774	0,653	0,629	0,571	0,547		0,507		0,450		0,438		0,417
7	0,686	0,611	0,555	0,532	0,526		0,470		0,420		0,406		0,387
8	0,652	0,566	0,508	0,498	0,468		0,439		0,394		0,381		0,362
9	0,604	0,503	0,493	0,462	0,449		0,416		0,367		0,358		0,341
10	0,576	0,490	0,458	0,431	0,426		0,393		0,348		0,337		0,323
11	0,554	0,460	0,436	0,422	0,399		0,377		0,334		0,322		0,308
12	0,527	0,459	0,421	0,407	0,390		0,353		0,321		0,309		0,296
13	0,501	0,433	0,403	0,379	0,365		0,338		0,306		0,297		0,284
14	0,493	0,410	0,389	0,368	0,355		0,329		0,293		0,287		0,274
15	0,458	0,400	0,381	0,359	0,343		0,318		0,284		0,277		0,264
16	0,457	0,385	0,362	0,344	0,332		0,312		0,274		0,268		0,256
17	0,428	0,381	0,347	0,329	0,326		0,301		0,267		0,260		0,248
18	0,440	0,365	0,345	0,320	0,320		0,293		0,261		0,253		0,241
19	0,415	0,365	0,329	0,316	0,304		0,280		0,253		0,246		0,234
20	0,414	0,350	0,316	0,309	0,295		0,274		0,247		0,239		0,229
21	0,384	0,336	0,310	0,296	0,288		0,269		0,240		0,233		0,223
22	0,380	0,331	0,311	0,293	0,284		0,262		0,233		0,228		0,218
23	0,373	0,319	0,296	0,282	0,280		0,258		0,229		0,224		0,213
24	0,377	0,315	0,297	0,276	0,270		0,251		0,226		0,219		0,208
25	0,353	0,313	0,289	0,275	0,266		0,243		0,220		0,213		0,204
26	0,354	0,304	0,282	0,268	0,267		0,241		0,216		0,210		0,200
27	0,339	0,300	0,276	0,262	0,259		0,235		0,212		0,206		0,196
28	0,336	0,284	0,263	0,261	0,258		0,232		0,207		0,203		0,193
29	0,325	0,280	0,266	0,254	0,243		0,231		0,205		0,200		0,190
30	0,328	0,283	0,259	0,247	0,241		0,228		0,201		0,195		0,187
⋮													
50	0,244	0,217	0,197	0,193	0,190		0,172		0,156		0,151		0,144
⋮													
100	0,177	0,156	0,142	0,135	0,134		0,123		0,111		0,108		0,102
⋮													
200	0,127	0,107	0,100	0,096	0,092		0,087		0,077		0,076		0,072
⋮													
250	0,109	0,096	0,088	0,085	0,082		0,077		0,070		0,068		0,065

TABELA B.2 – VALORES CRÍTICOS DE CV A 0,5% OBTIDOS POR SIMULAÇÃO DE *MONTE CARLO*.

nel	Tamanho da amostra												
	10	20	30	40	50	...	100	...	500	...	1000	...	9000
1	1,752	1,574	1,496	1,468	1,426		1,290		1,131		1,092		1,026
2	1,181	1,067	1,020	1,001	0,949		0,881		0,783		0,759		0,723
3	0,961	0,852	0,809	0,787	0,761		0,705		0,637		0,618		0,590
4	0,850	0,755	0,689	0,678	0,650		0,608		0,546		0,534		0,510
5	0,732	0,654	0,618	0,603	0,577		0,541		0,487		0,476		0,456
6	0,673	0,596	0,561	0,543	0,530		0,493		0,444		0,434		0,416
7	0,622	0,558	0,526	0,499	0,488		0,453		0,412		0,402		0,385
8	0,591	0,525	0,484	0,472	0,455		0,425		0,387		0,376		0,360
9	0,547	0,478	0,460	0,446	0,429		0,402		0,362		0,354		0,340
10	0,531	0,463	0,433	0,411	0,409		0,381		0,345		0,334		0,322
11	0,502	0,434	0,409	0,398	0,385		0,360		0,327		0,319		0,307
12	0,477	0,419	0,401	0,379	0,372		0,345		0,315		0,306		0,294
13	0,456	0,407	0,386	0,361	0,352		0,331		0,301		0,294		0,283
14	0,453	0,386	0,362	0,346	0,337		0,321		0,290		0,284		0,272
15	0,417	0,376	0,356	0,338	0,332		0,310		0,281		0,274		0,263
16	0,415	0,359	0,339	0,329	0,319		0,302		0,270		0,264		0,255
17	0,398	0,352	0,326	0,318	0,309		0,287		0,263		0,256		0,247
18	0,387	0,336	0,323	0,307	0,302		0,282		0,257		0,250		0,240
19	0,374	0,338	0,313	0,302	0,292		0,272		0,249		0,243		0,234
20	0,370	0,322	0,299	0,293	0,282		0,267		0,243		0,237		0,228
21	0,353	0,315	0,295	0,285	0,277		0,261		0,236		0,231		0,222
22	0,355	0,312	0,289	0,278	0,273		0,256		0,231		0,226		0,217
23	0,340	0,301	0,280	0,271	0,264		0,249		0,226		0,221		0,213
24	0,335	0,298	0,278	0,264	0,259		0,244		0,221		0,216		0,208
25	0,327	0,292	0,270	0,261	0,252		0,238		0,217		0,212		0,204
26	0,320	0,287	0,267	0,254	0,248		0,232		0,213		0,208		0,200
27	0,313	0,275	0,258	0,250	0,246		0,228		0,208		0,204		0,196
28	0,309	0,269	0,253	0,247	0,238		0,222		0,204		0,200		0,192
29	0,301	0,265	0,251	0,243	0,234		0,222		0,201		0,196		0,189
30	0,301	0,262	0,245	0,237	0,231		0,219		0,198		0,193		0,186
⋮													
50	0,226	0,201	0,190	0,184	0,180		0,168		0,153		0,150		0,144
...													
100	0,160	0,143	0,135	0,128	0,127		0,119		0,108		0,106		0,102
⋮													
200	0,118	0,101	0,094	0,092	0,089		0,083		0,076		0,075		0,072
⋮													
250	0,101	0,090	0,084	0,082	0,079		0,075		0,069		0,067		0,064

TABELA B.3 – VALORES CRÍTICOS DE CV A 1% OBTIDOS POR SIMULAÇÃO DE *MONTE CARLO*.

nel	Tamanho da amostra												
	10	20	30	40	50	...	100	...	500	...	1000	...	9000
1	1,644	1,508	1,429	1,387	1,362		1,247		1,112		1,080		1,023
2	1,136	1,015	0,969	0,956	0,925		0,860		0,775		0,753		0,721
3	0,923	0,822	0,790	0,764	0,741		0,690		0,631		0,613		0,589
4	0,802	0,719	0,668	0,650	0,636		0,600		0,543		0,530		0,509
5	0,702	0,638	0,590	0,578	0,565		0,533		0,484		0,472		0,455
6	0,639	0,580	0,543	0,525	0,517		0,486		0,441		0,432		0,416
7	0,591	0,534	0,503	0,484	0,477		0,445		0,408		0,400		0,385
8	0,557	0,507	0,469	0,455	0,442		0,418		0,384		0,373		0,360
9	0,525	0,460	0,445	0,432	0,420		0,395		0,360		0,352		0,339
10	0,505	0,444	0,414	0,401	0,400		0,374		0,340		0,333		0,322
11	0,475	0,416	0,397	0,391	0,374		0,354		0,325		0,317		0,307
12	0,455	0,403	0,386	0,369	0,363		0,338		0,312		0,304		0,294
13	0,435	0,393	0,369	0,353	0,344		0,326		0,299		0,292		0,282
14	0,420	0,373	0,354	0,339	0,332		0,315		0,288		0,282		0,272
15	0,404	0,364	0,342	0,330	0,325		0,303		0,278		0,272		0,263
16	0,393	0,347	0,331	0,318	0,311		0,296		0,269		0,263		0,254
17	0,387	0,339	0,318	0,309	0,303		0,284		0,260		0,255		0,247
18	0,374	0,327	0,309	0,302	0,293		0,276		0,254		0,249		0,240
19	0,358	0,321	0,302	0,294	0,286		0,268		0,247		0,242		0,233
20	0,354	0,310	0,293	0,286	0,277		0,263		0,240		0,236		0,227
21	0,341	0,307	0,287	0,280	0,272		0,256		0,234		0,230		0,222
22	0,335	0,300	0,277	0,270	0,266		0,252		0,229		0,225		0,217
23	0,323	0,289	0,272	0,264	0,257		0,245		0,224		0,220		0,212
24	0,321	0,285	0,268	0,257	0,254		0,240		0,219		0,215		0,208
25	0,313	0,281	0,265	0,255	0,249		0,234		0,215		0,211		0,203
26	0,307	0,273	0,260	0,249	0,241		0,229		0,211		0,207		0,199
27	0,300	0,269	0,252	0,245	0,239		0,224		0,207		0,203		0,196
28	0,297	0,262	0,247	0,242	0,234		0,219		0,203		0,199		0,192
29	0,289	0,259	0,245	0,235	0,230		0,218		0,199		0,195		0,189
30	0,285	0,253	0,239	0,232	0,226		0,214		0,196		0,192		0,186
⋮													
50	0,216	0,195	0,185	0,180	0,176		0,165		0,152		0,149		0,144
⋮													
100	0,155	0,138	0,132	0,125	0,124		0,117		0,108		0,105		0,102
⋮													
200	0,110	0,097	0,092	0,090	0,087		0,082		0,076		0,075		0,072
⋮													
250	0,098	0,087	0,083	0,079	0,078		0,074		0,068		0,067		0,064

TABELA B.4 – VALORES CRÍTICOS DE CV A 5% OBTIDOS POR SIMULAÇÃO DE *MONTE CARLO*.

nel	Tamanho da amostra												
	10	20	30	40	50	...	100	...	500	...	1000	...	9000
1	1,358	1,296	1,255	1,231	1,213		1,155		1,073		1,053		1,017
2	0,960	0,909	0,875	0,859	0,846		0,809		0,754		0,740		0,717
3	0,795	0,741	0,713	0,697	0,684		0,652		0,613		0,602		0,585
4	0,684	0,637	0,613	0,600	0,589		0,567		0,530		0,521		0,506
5	0,616	0,568	0,545	0,535	0,525		0,504		0,472		0,465		0,453
6	0,557	0,519	0,501	0,489	0,480		0,460		0,431		0,424		0,413
7	0,519	0,480	0,459	0,448	0,443		0,424		0,398		0,393		0,383
8	0,484	0,452	0,431	0,419	0,415		0,398		0,373		0,367		0,358
9	0,454	0,420	0,408	0,394	0,388		0,374		0,351		0,346		0,337
10	0,433	0,401	0,383	0,375	0,369		0,356		0,333		0,328		0,320
11	0,417	0,377	0,367	0,362	0,352		0,336		0,318		0,313		0,305
12	0,397	0,364	0,352	0,343	0,338		0,323		0,305		0,300		0,292
13	0,382	0,352	0,337	0,329	0,324		0,311		0,292		0,288		0,281
14	0,367	0,340	0,326	0,317	0,312		0,299		0,281		0,277		0,270
15	0,353	0,328	0,316	0,306	0,302		0,290		0,272		0,268		0,261
16	0,343	0,317	0,305	0,297	0,292		0,281		0,263		0,259		0,253
17	0,334	0,305	0,293	0,288	0,283		0,270		0,255		0,252		0,245
18	0,327	0,298	0,288	0,281	0,274		0,263		0,248		0,245		0,238
19	0,314	0,291	0,280	0,273	0,268		0,257		0,242		0,238		0,232
20	0,308	0,282	0,272	0,266	0,260		0,251		0,236		0,232		0,226
21	0,301	0,277	0,263	0,259	0,255		0,244		0,230		0,226		0,221
22	0,291	0,270	0,258	0,253	0,249		0,240		0,225		0,221		0,216
23	0,285	0,265	0,252	0,246	0,242		0,233		0,219		0,216		0,211
24	0,282	0,259	0,248	0,242	0,238		0,229		0,215		0,212		0,207
25	0,274	0,252	0,244	0,237	0,234		0,224		0,211		0,208		0,202
26	0,268	0,247	0,239	0,233	0,228		0,219		0,206		0,203		0,198
27	0,266	0,243	0,234	0,229	0,225		0,215		0,203		0,200		0,195
28	0,260	0,239	0,230	0,225	0,220		0,210		0,199		0,196		0,191
29	0,253	0,235	0,225	0,220	0,216		0,208		0,196		0,192		0,188
30	0,250	0,231	0,221	0,216	0,213		0,204		0,192		0,189		0,185
⋮													
50	0,192	0,177	0,171	0,169	0,164		0,158		0,149		0,147		0,143
⋮													
100	0,138	0,126	0,121	0,118	0,116		0,112		0,105		0,104		0,101
⋮													
200	0,097	0,089	0,086	0,084	0,082		0,079		0,074		0,073		0,072
⋮													
250	0,087	0,080	0,077	0,075	0,074		0,071		0,067		0,066		0,064

TABELA B.5 – VALORES CRÍTICOS DE CV A 10% OBTIDOS POR SIMULAÇÃO DE *MONTE CARLO*.

nel	Tamanho da amostra												
	10	20	30	40	50	...	100	...	500	...	1000	...	9000
1	1,230	1,207	1,178	1,156	1,144		1,111		1,055		1,040		1,013
2	0,885	0,850	0,824	0,818	0,808		0,781		0,742		0,731		0,715
3	0,729	0,695	0,676	0,664	0,656		0,634		0,604		0,596		0,584
4	0,633	0,603	0,582	0,573	0,567		0,549		0,523		0,516		0,505
5	0,564	0,534	0,519	0,513	0,504		0,491		0,466		0,461		0,452
6	0,516	0,490	0,475	0,467	0,463		0,447		0,426		0,421		0,412
7	0,483	0,452	0,440	0,430	0,427		0,412		0,394		0,389		0,382
8	0,450	0,425	0,410	0,404	0,399		0,387		0,368		0,364		0,357
9	0,424	0,399	0,389	0,380	0,376		0,364		0,348		0,343		0,336
10	0,400	0,378	0,368	0,361	0,357		0,347		0,329		0,325		0,319
11	0,387	0,359	0,350	0,346	0,340		0,328		0,314		0,310		0,304
12	0,365	0,345	0,337	0,329	0,326		0,315		0,301		0,297		0,291
13	0,356	0,333	0,323	0,317	0,313		0,302		0,289		0,286		0,280
14	0,340	0,321	0,311	0,305	0,301		0,291		0,278		0,275		0,270
15	0,329	0,311	0,301	0,295	0,292		0,282		0,269		0,266		0,261
16	0,318	0,300	0,292	0,286	0,283		0,274		0,260		0,257		0,252
17	0,309	0,289	0,280	0,277	0,274		0,264		0,252		0,250		0,245
18	0,302	0,281	0,275	0,270	0,266		0,257		0,245		0,243		0,238
19	0,292	0,275	0,267	0,262	0,259		0,250		0,239		0,236		0,232
20	0,286	0,269	0,260	0,256	0,251		0,244		0,233		0,230		0,226
21	0,280	0,261	0,252	0,250	0,246		0,238		0,227		0,225		0,220
22	0,271	0,255	0,247	0,243	0,240		0,233		0,222		0,219		0,215
23	0,266	0,251	0,241	0,238	0,235		0,228		0,217		0,215		0,211
24	0,263	0,245	0,237	0,233	0,230		0,223		0,212		0,210		0,206
25	0,254	0,238	0,233	0,229	0,226		0,219		0,208		0,206		0,202
26	0,250	0,234	0,229	0,224	0,221		0,213		0,204		0,202		0,198
27	0,248	0,230	0,224	0,220	0,217		0,209		0,200		0,198		0,194
28	0,242	0,227	0,221	0,216	0,212		0,206		0,196		0,194		0,191
29	0,236	0,222	0,216	0,211	0,210		0,203		0,193		0,191		0,187
30	0,232	0,219	0,212	0,208	0,206		0,199		0,190		0,188		0,184
⋮													
50	0,179	0,169	0,164	0,162	0,159		0,153		0,147		0,145		0,143
⋮													
100	0,128	0,120	0,116	0,114	0,112		0,109		0,104		0,103		0,101
⋮													
200	0,090	0,085	0,082	0,081	0,079		0,077		0,074		0,073		0,071
⋮													
250	0,081	0,076	0,074	0,072	0,071		0,069		0,066		0,065		0,064

TABELA B.6 – VALORES CRÍTICOS DE CV A 15% OBTIDOS POR SIMULAÇÃO DE *MONTE CARLO*.

nel	Tamanho da amostra												
	10	20	30	40	50	...	100	...	500	...	1000	...	9000
1	1,162	1,147	1,125	1,116	1,106		1,086		1,043		1,031		1,011
2	0,832	0,813	0,797	0,790	0,784		0,764		0,735		0,726		0,713
3	0,689	0,667	0,652	0,644	0,638		0,622		0,599		0,593		0,582
4	0,600	0,578	0,562	0,558	0,552		0,539		0,518		0,513		0,504
5	0,537	0,513	0,502	0,498	0,491		0,480		0,462		0,458		0,451
6	0,489	0,474	0,460	0,455	0,451		0,439		0,422		0,418		0,412
7	0,458	0,433	0,425	0,418	0,417		0,405		0,391		0,387		0,381
8	0,427	0,408	0,397	0,394	0,389		0,380		0,365		0,362		0,356
9	0,402	0,385	0,376	0,370	0,367		0,358		0,345		0,341		0,336
10	0,381	0,365	0,356	0,351	0,348		0,340		0,326		0,324		0,319
11	0,366	0,347	0,339	0,337	0,332		0,323		0,312		0,309		0,304
12	0,347	0,332	0,327	0,320	0,318		0,310		0,299		0,295		0,291
13	0,339	0,320	0,312	0,308	0,306		0,297		0,287		0,284		0,279
14	0,322	0,310	0,301	0,297	0,294		0,287		0,276		0,274		0,269
15	0,313	0,299	0,292	0,287	0,285		0,277		0,267		0,264		0,260
16	0,302	0,289	0,283	0,278	0,276		0,269		0,258		0,256		0,252
17	0,295	0,279	0,272	0,269	0,267		0,259		0,250		0,248		0,244
18	0,286	0,271	0,266	0,263	0,259		0,252		0,243		0,241		0,237
19	0,277	0,265	0,258	0,254	0,253		0,246		0,237		0,235		0,231
20	0,271	0,259	0,252	0,249	0,245		0,241		0,231		0,229		0,225
21	0,265	0,252	0,245	0,243	0,240		0,234		0,225		0,223		0,220
22	0,257	0,246	0,240	0,237	0,235		0,229		0,220		0,218		0,215
23	0,253	0,242	0,234	0,232	0,230		0,224		0,215		0,214		0,210
24	0,249	0,236	0,230	0,228	0,225		0,219		0,211		0,209		0,206
25	0,242	0,230	0,226	0,222	0,221		0,215		0,207		0,205		0,201
26	0,239	0,227	0,222	0,218	0,216		0,210		0,202		0,201		0,198
27	0,234	0,222	0,217	0,213	0,212		0,206		0,199		0,197		0,194
28	0,230	0,218	0,214	0,210	0,207		0,202		0,195		0,193		0,190
29	0,224	0,214	0,210	0,206	0,205		0,199		0,192		0,190		0,187
30	0,220	0,211	0,205	0,203	0,201		0,196		0,189		0,187		0,184
⋮													
50	0,171	0,163	0,159	0,158	0,155		0,151		0,146		0,145		0,142
⋮													
100	0,122	0,116	0,113	0,111	0,110		0,107		0,103		0,102		0,101
⋮													
200	0,086	0,082	0,080	0,078	0,078		0,076		0,073		0,072		0,071
⋮													
250	0,077	0,073	0,071	0,070	0,070		0,068		0,065		0,065		0,064

TABELA B.7 – VALORES CRÍTICOS DE CV A 20% OBTIDOS POR SIMULAÇÃO DE *MONTE CARLO*.

nel	Tamanho da amostra												
	10	20	30	40	50	...	100	...	500	...	1000	...	9000
1	1,109	1,101	1,092	1,087	1,079		1,066		1,034		1,025		1,009
2	0,797	0,784	0,775	0,769	0,764		0,752		0,729		0,723		0,712
3	0,657	0,645	0,634	0,629	0,625		0,612		0,594		0,590		0,581
4	0,572	0,561	0,547	0,546	0,541		0,530		0,515		0,510		0,503
5	0,515	0,497	0,490	0,487	0,481		0,474		0,459		0,456		0,450
6	0,468	0,459	0,450	0,445	0,441		0,432		0,420		0,416		0,411
7	0,438	0,421	0,415	0,410	0,409		0,400		0,388		0,386		0,380
8	0,410	0,396	0,388	0,384	0,382		0,375		0,363		0,361		0,356
9	0,385	0,374	0,366	0,362	0,360		0,353		0,342		0,340		0,335
10	0,366	0,354	0,347	0,343	0,340		0,335		0,324		0,322		0,318
11	0,351	0,338	0,331	0,329	0,326		0,318		0,310		0,307		0,303
12	0,334	0,323	0,318	0,313	0,311		0,306		0,297		0,294		0,290
13	0,325	0,310	0,304	0,301	0,300		0,293		0,285		0,283		0,279
14	0,310	0,300	0,294	0,292	0,288		0,282		0,274		0,272		0,269
15	0,300	0,291	0,285	0,282	0,280		0,273		0,265		0,263		0,260
16	0,290	0,280	0,276	0,272	0,271		0,265		0,257		0,255		0,252
17	0,282	0,271	0,266	0,264	0,262		0,256		0,249		0,247		0,244
18	0,274	0,263	0,260	0,257	0,254		0,249		0,242		0,240		0,237
19	0,265	0,257	0,252	0,249	0,249		0,243		0,236		0,234		0,231
20	0,260	0,252	0,246	0,243	0,241		0,237		0,230		0,228		0,225
21	0,255	0,243	0,239	0,237	0,235		0,231		0,224		0,222		0,220
22	0,246	0,238	0,234	0,232	0,230		0,226		0,219		0,217		0,214
23	0,242	0,234	0,229	0,226	0,225		0,221		0,214		0,213		0,210
24	0,239	0,229	0,224	0,222	0,221		0,216		0,210		0,208		0,205
25	0,233	0,223	0,221	0,218	0,216		0,212		0,205		0,204		0,201
26	0,228	0,220	0,216	0,213	0,212		0,207		0,201		0,200		0,197
27	0,225	0,217	0,211	0,209	0,208		0,204		0,198		0,196		0,194
28	0,221	0,212	0,209	0,206	0,203		0,200		0,194		0,193		0,190
29	0,216	0,208	0,205	0,202	0,200		0,196		0,190		0,189		0,187
30	0,212	0,205	0,201	0,198	0,197		0,193		0,187		0,186		0,184
⋮													
50	0,165	0,158	0,156	0,154	0,153		0,149		0,145		0,144		0,142
⋮													
100	0,117	0,112	0,110	0,108	0,108		0,106		0,103		0,102		0,101
⋮													
200	0,082	0,079	0,078	0,077	0,076		0,075		0,073		0,072		0,071
⋮													
250	0,074	0,071	0,070	0,069	0,069		0,067		0,065		0,064		0,064

PUBLICAÇÕES TÉCNICO-CIENTÍFICAS EDITADAS PELO INPE

Teses e Dissertações (TDI)

Teses e Dissertações apresentadas nos Cursos de Pós-Graduação do INPE.

Manuais Técnicos (MAN)

São publicações de caráter técnico que incluem normas, procedimentos, instruções e orientações.

Notas Técnico-Científicas (NTC)

Incluem resultados preliminares de pesquisa, descrição de equipamentos, descrição e ou documentação de programa de computador, descrição de sistemas e experimentos, apresentação de testes, dados, atlas, e documentação de projetos de engenharia.

Relatórios de Pesquisa (RPQ)

Reportam resultados ou progressos de pesquisas tanto de natureza técnica quanto científica, cujo nível seja compatível com o de uma publicação em periódico nacional ou internacional.

Propostas e Relatórios de Projetos (PRP)

São propostas de projetos técnico-científicos e relatórios de acompanhamento de projetos, atividades e convênios.

Publicações Didáticas (PUD)

Incluem apostilas, notas de aula e manuais didáticos.

Publicações Seriadas

São os seriados técnico-científicos: boletins, periódicos, anuários e anais de eventos (simpósios e congressos). Constam destas publicações o Internacional Standard Serial Number (ISSN), que é um código único e definitivo para identificação de títulos de seriados.

Programas de Computador (PDC)

São a seqüência de instruções ou códigos, expressos em uma linguagem de programação compilada ou interpretada, a ser executada por um computador para alcançar um determinado objetivo. São aceitos tanto programas fonte quanto executáveis.

Pré-publicações (PRE)

Todos os artigos publicados em periódicos, anais e como capítulos de livros.