

MINISTÉRIO DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

INPE-7507-TDI/721

**AVALIAÇÃO E COMPARAÇÃO DE ALGORITMOS DE
SEGMENTAÇÃO DE IMAGENS DE RADAR DE ABERTURA
SINTÉTICA**

Eduardo Viegas Dalle Lucca

Dissertação de Mestrado em Sensoriamento Remoto, orientada pela Dra. Corina da Costa Freitas e pelo Dr. Alejandro Cesar Frery Orgambide, aprovada em 18 de dezembro de 1998.

INPE
São José dos Campos
1999

528. 711. 7

LUCCA, E. V. D.

Avaliação e comparação de algoritmos de segmentação de imagens de radar de abertura sintética / E. V. D. Lucca. – São José dos Campos: INPE, 1998.

207p. – (INPE-7507-TDI/721).

1.Sensoriamento remoto. 2.Radar de Abertura Sintética (SAR). 3.Processamento de imagens. 4.Detecção de borda. 5.Análise de imagens. 6.Segmentação. I.Título.

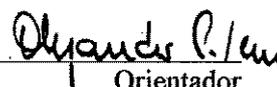
Aprovado pela Banca Examinadora
em cumprimento a requisito exigido
para a obtenção do Título de Mestre
em **Sensoriamento Remoto**.

Dr^a Corina da Costa Freitas



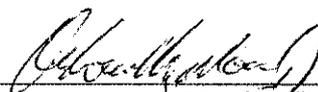
Presidente/Orientadora

Dr. Alejandro César Frery Orgambide



Orientador

Dr. Antonio Miguel Vieira Monteiro



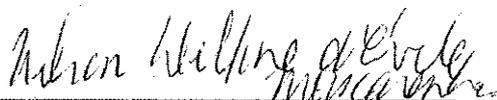
Membro da Banca

Dr. Luciano Vieira Dutra



Membro da Banca

Dr. Nelson Delfino D'Ávila Mascarenhas



Membro da Banca

Convidado

Candidato (a) : Eduardo Viegas Dalle Lucca

São José dos Campos, 18 de dezembro de 1998.

À minha esposa Alyne e à minha filha Renata.

AGRADECIMENTOS

À doutora Corina da Costa Freitas e ao doutor Alejandro Cesar Frery Orgambide, exemplos de profissionalismo, competência e dedicação, pela orientação segura, incentivo, confiança e amizade demonstrada no transcorrer destes anos.

À minha esposa Alyne por seu permanente carinho, dedicação, incentivo, acompanhamento e participação em todos os momentos.

À minha filha Renata que, com sua presença, alegria e encanto proporcionou o incentivo necessário nos momentos mais difíceis.

Ao meu amigo Sidnei pelo auxílio na elaboração de todos os programas necessários e imprescindíveis à execução deste trabalho.

Aos integrantes da Senzala, pela colaboração e paciência nos momentos necessários.

Aos professores do INPE, mestres, doutores e funcionários pela sua contribuição e apoio.

À Etel pelo apoio e incentivo durante todos estes anos de convívio.

Ao Instituto Nacional de Pesquisas Espaciais (INPE), em particular, aos amigos do SERE e a todos os meus amigos, companheiros de incontáveis momentos, que acreditaram e contribuíram para a consecução deste trabalho.

À minha família, pela confiança, colaboração e constante incentivo.

Aos que embora não citados, contribuíram de alguma forma para a realização deste trabalho.

Ao CTA/IEAv pela confiança, incentivo e apoio.

RESUMO

Este trabalho tem como objetivo avaliar e comparar o desempenho de dois algoritmos de segmentação de imagens de radar de abertura sintética (SAR), o *Merge Using Moments* (MUM) e o RWSEG, os quais estão implementados no *software* CAESAR versão 2.1 (NASoftware, 1994). A avaliação tem como base a aplicação desses algoritmos em estudos de uso e ocupação do solo e é feita através de análise qualitativa e quantitativa das segmentações de imagens testes produzidas pelos mesmos. O conjunto de imagens teste é composto por imagens real e sintéticas, contendo regiões com diferentes graus de homogeneidade (homogêneas, heterogêneas e extremamente heterogêneas), processadas com diferentes números de *looks* e tipo de detecção linear. O processo de obtenção das imagens sintéticas compreende basicamente três etapas. A primeira consiste na criação de um imagem idealizada que resume as principais características geométricas e topológicas da ocupação do solo. A segunda na classificação das regiões criadas em função do grau de homogeneidade. A terceira na modelagem estatística das observações provindas dessas classes através de distribuições particulares associadas aos graus de homogeneidade e derivadas do modelo multiplicativo adotado para representar os dados SAR monoespectrais em amplitude. As avaliações qualitativa e quantitativa são baseadas na comparação da segmentação de uma imagem produzida pelos algoritmos com a segmentação da mesma imagem obtida manualmente, a qual é suposta como verdadeira e empregada como referência. O resultado qualitativo é obtido através da comparação puramente visual enquanto que o quantitativo é obtido a partir da aplicação de método empírico de discrepância, no qual as diferenças entre as segmentações comparadas são quantificadas empregando-se medidas de discrepância. Para tanto são definidas medidas quantitativas para avaliar a qualidade de uma segmentação do ponto de vista da correção de posição, tamanho, forma e intensidade média dos seus segmentos. A avaliação quantitativa das imagens simuladas conta ainda com uma experiência Monte Carlo, realizada com objetivo de amenizar a influência de uma imagem particular nos resultados obtidos. A avaliação e a comparação relativa entre os algoritmos são feitas do ponto de vista da adequação para o tipo de aplicação definido, do desempenho qualitativo e quantitativo das segmentações produzidas de cada imagem de entrada, da capacidade de segmentar regiões com diferentes graus de homogeneidade, do custo computacional e da simplicidade.

EVALUATION AND COMPARISON OF SAR IMAGE SEGMENTATION ALGORITHMS

ABSTRACT

This work aims at evaluating and comparing the performance of two synthetic aperture radar image segmentation algorithms, the Merge Using Moments (MUM) and the RWSEG, which are implemented in software Caesar version 2.1 (NASoftware, 1994). The evaluation is based on land use application studies and is done from qualitative and quantitative analysis of the test image segmentations obtained from these algorithms. The test image set is composed of real and simulated images, containing regions with different homogeneity degrees (homogeneous, heterogeneous and extremely heterogeneous), processed with different numbers of looks and with linear detection. The process for obtaining simulated images is made up basically of three phases. The first consists of creating an idealized image which summarizes the main land use geometric and topologic characteristics. The second of classifying the obtained regions in relation to their homogeneity degrees. The third from statistical modelling of observing each class through particular distributions associated with homogeneity degrees and derived from multiplicative model used to represent amplitude SAR data. The qualitative and quantitative evaluations are based on comparing an image segmentation obtained from algorithms with the one obtained manually from the same image, which is considered true and used as reference. The qualitative result is obtained from simple visual comparison whereas the quantitative one is obtained from the application of empirical discrepancy methods, in which the difference between the compared segmentations is quantified from discrepancy measures. In order to do so, quantitative measures are defined to evaluate the quality of segmentation from the view point of position, size, shape and mean intensity correction of its segments. The simulated images quantitative evaluation also uses a Monte Carlo experiment, performed to reduce the influence of particular images on the performance assessment. The evaluation and relative comparison between the algorithms are done from the following points of view: adequacy for the defined application type, qualitative and quantitative performance of the segmentation obtained from each input image, ability to segment regions having different degrees of homogeneity, computational cost as well as simplicity.

SUMÁRIO

	Pág.
LISTA DE FIGURAS	
LISTA DE TABELAS	
CAPÍTULO 1 - INTRODUÇÃO	21
CAPÍTULO 2 - PRINCIPAIS DISTRIBUIÇÕES APLICADAS AOS DADOS SAR	27
2.1 - Notações e definições.....	27
2.1.1 - Variáveis aleatórias	27
2.1.2 - Esperança	28
2.1.3 - Variância	28
2.1.4 - Momento	28
2.2 - Distribuições aplicáveis aos dados SAR.....	29
2.2.1 - Distribuição constante.....	29
2.2.2 - Distribuição gama	29
2.2.3 - Distribuição raiz de gama	30
2.2.4 - Distribuição recíproca da raiz de gama	31
2.2.5 - Distribuição raiz de gaussiana inversa generalizada.....	31
2.2.6 - Distribuição K-amplitude	32
2.2.7 - Distribuição G-amplitude	33
2.2.8 - Distribuição G-amplitude zero.....	33
CAPÍTULO 3 - MODELAGEM DOS DADOS SAR	35
3.1 - Modelo multiplicativo	36
CAPÍTULO 4 - SEGMENTAÇÃO DE IMAGENS SAR	41

CAPÍTULO 5 - DESCRIÇÃO DOS ALGORITMOS DE SEGMENTAÇÃO DE IMAGENS SAR MUM E RWSEG.....	47
5.1 - O algoritmo MUM.....	48
5.2 - O algoritmo RWSEG.....	51
CAPÍTULO 6 - MEDIDAS DE QUALIDADE DE UMA SEGMENTAÇÃO.	61
6.1 - Métodos de avaliação de algoritmos de segmentação	62
6.2 - Alguns aspectos da modelagem matemática de uma imagem e de uma segmentação	64
6.3 - Medidas de qualidade.....	67
CAPÍTULO 7 - METODOLOGIA	79
7.1 - Definição do tipo de aplicação	82
7.2 - Proposta e obtenção do conjunto de imagens teste.....	82
7.2.1 - Imagem real.....	84
7.2.2 - Obtenção das imagens sintéticas.....	87
7.2.2.1 - Obtenção do <i>phantom</i>	88
7.2.2.2 - Modelagem das classes contidas no <i>phantom</i>	91
7.3 - Obtenção e avaliação das segmentações das imagens testes pelo MUM e pelo RWSEG.....	104
CAPÍTULO 8 - RESULTADOS E DISCUSSÃO	107
8.1 - Resultados obtidos a partir da imagem simulada de 3 <i>looks</i>	109
8.1.1 - Resultados obtidos pelo MUM.....	109
8.1.1.1 - Avaliação qualitativa	109
8.1.1.2 - Avaliação quantitativa	112
8.1.2 - Resultados obtidos pelo RWSEG.....	114
8.1.2.1 - Avaliação qualitativa	114

8.1.2.2. - Avaliação quantitativa.....	121
8.1.3 - Experimento Monte Carlo.....	126
8.2 - Resultados obtidos a partir da imagem simulada de 8 <i>looks</i>	142
8.2.1 - Resultados obtidos pelo MUM.....	142
8.2.1.1 - Avaliação qualitativa	142
8.2.1.2 - Avaliação quantitativa	146
8.2.2 - Resultados obtidos pelo RWSEG.....	148
8.2.2.1 - Avaliação qualitativa	148
8.2.2.2. - Avaliação quantitativa.....	155
8.2.3 - Experimento Monte Carlo.....	160
8.3 - Resultados obtidos a partir da imagem real.....	175
8.3.1 - Resultados obtidos pelo MUM.....	175
8.3.1.1 - Avaliação qualitativa	175
8.3.1.2 - Avaliação quantitativa.....	179
8.3.2 - Resultados obtidos pelo RWSEG.....	181
8.3.2.1 - Avaliação qualitativa	181
8.3.2.2. - Avaliação quantitativa.....	188
8.3.3 - Comparação dos resultados obtidos pelo MUM e pelo RWSEG.....	193
CAPÍTULO 9 - CONCLUSÕES	199
REFERÊNCIAS BIBLIOGRÁFICAS	207

LISTA DE FIGURAS

	Pág.
3.1 - Exemplo das distribuições Raiz de Gama, K-amplitude e G-amplitude zero	39
5.1 - Representação da saída dos algoritmos através do mapa de médias e do mapa de bordas	48
5.2 - Ilustração do cálculo da variância em cada sub-janela	55
6.1 - Representação da segmentação de referência g_1 e seus segmentos.....	72
6.2 - Representação da segmentação g_2 e seus segmentos.	73
6.3 - Projeção da subregião 1 (sombreada) de g_1 sobre g_2	74
7.1 - Diagrama esquemático da metodologia.....	81
7.2 - Localização da área de estudo.....	84
7.3 - Imagem SAR real da região de Ariquemes.....	85
7.4 - Processo de obtenção da segmentação manual.....	86
7.5 - Resultado da segmentação manual da imagem real	86
7.6 - Imagem SAR real da região de Castanhal	88
7.7 - Segmentação manual da imagem real.....	89
7.8 - Imagem idealizada de classes (<i>phantom</i>).....	91
7.9 - Influência do parâmetro α nas distribuições $KA(\alpha, \lambda, n)$ e $G_A^0(\alpha, \gamma, n)$	94
7.10 - Densidades das distribuições $\Gamma^{\frac{1}{2}}(3, 0.000563)$, $\Gamma^{\frac{1}{2}}(3, 0.000431)$, $\Gamma^{\frac{1}{2}}(3, 0.000123)$ usadas para modelar as regiões homogêneas 1, 2 e 3, respectivamente.....	97
7.11 - Densidades das distribuições $KA(2, 10000, 3)$, $KA(5, 33000, 3)$, $KA(3, 20000, 3)$ usadas para modelar as regiões heterogêneas 1, 2 e 3, respectivamente.	98

7.12 - Densidades das distribuições $G_A^0(-7, 328930, 3)$ e $G_A^0(-4, 90670, 3)$ usadas para modelar as regiões extremamente heterogêneas 1 e 2, respectivamente.	99
7.13 - Densidades das distribuições $\Gamma^{\frac{1}{2}}(8, 0.001653)$, $\Gamma^{\frac{1}{2}}(8, 0.001266)$, $\Gamma^{\frac{1}{2}}(8, 0.000360)$ usadas para modelar as regiões homogêneas 1, 2 e 3, respectivamente	100
7.14 - Densidades das distribuições $KA(2, 9400, 8)$, $KA(5, 31400, 8)$, $KA(3, 18900, 8)$ usadas para modelar as regiões heterogêneas 1, 2 e 3, respectivamente.	101
7.15 - Densidades das distribuições $G_A^0(-7, 312300, 8)$ e $G_A^0(-4, 86000, 8)$ usadas para modelar as regiões extremamente heterogêneas 1 e 2, respectivamente.	102
7.16 - Imagens simuladas de 3 <i>looks</i> e em Amplitude	103
7.17 - Imagens simuladas de 8 <i>looks</i> e em Amplitude	103
8.1 - Segmentação manual e segmentações da imagem 3 <i>looks</i> produzidas pelo MUM com $p=1$, $p=6$, $p=10$, $p=13$ e $p=17$	110
8.2 - Segmentação manual e segmentações da imagem 3 <i>looks</i> produzidas pelo MUM com $p=4$, $p=5$, $p=7$, $p=8$ e $p=9$	111
8.3 - Média geral das segmentações da imagem de 3 <i>looks</i> produzidas pelo MUM	112
8.4 - Segmentação manual e segmentações da imagem 3 <i>looks</i> produzidas pelo RWSEG com $j=0$ e $e=1,65$, $e=2,58$, $e=3,29$, $e=4,06$ e $e=4,91$	116
8.5 - Segmentação manual e segmentações da imagem 3 <i>looks</i> produzidas pelo RWSEG com $j=8$ e $e=1,65$, $e=2,58$, $e=3,29$, $e=4,06$ e $e=4,91$	117
8.6 - Segmentação manual e segmentações da imagem 3 <i>looks</i> produzidas pelo RWSEG com $j=2$ e $e=2,33$, $e=2,58$, $e=2,81$, $e=3,09$ e $e=3,29$	118
8.7 - Segmentação manual e segmentações da imagem 3 <i>looks</i> produzidas pelo RWSEG com com $j=4$ e $e=2,33$, $e=2,58$, $e=2,81$, $e=3,09$ e $e=3,29$	119

8.8 - Média geral das segmentações da imagem de 3 <i>looks</i> produzidas pelo RWSEG.....	121
8.9 - Valores do ajuste de posição obtidos em cada segmentação produzida pelo MUM e pelo RWSEG no experimento Monte Carlo.	127
8.10 - Valores do ajuste de intensidade média obtidos em cada segmentação produzida pelo MUM e pelo RWSEG no experimento Monte Carlo.	128
8.11 - Valores do ajuste de tamanho obtidos em cada segmentação produzida pelo MUM e pelo RWSEG no experimento Monte Carlo.	128
8.12 - Valores do ajuste de forma obtidos em cada segmentação produzida pelo MUM e pelo RWSEG no experimento Monte Carlo.	129
8.13 - Valores da média geral obtida em cada segmentação produzida pelo MUM e pelo RWSEG no experimento Monte Carlo.	129
8.14 - Comparação das médias amostrais do ajuste de posição obtidas pelo MUM e pelo RWSEG no experimento Monte Carlo..	131
8.15 - Comparação das médias amostrais do ajuste de intensidade obtidas pelo MUM e pelo RWSEG no experimento Monte Carlo..	131
8.16 - Comparação das médias amostrais do ajuste de tamanho obtidas pelo MUM e pelo RWSEG no experimento Monte Carlo..	132
8.17 - Comparação das médias amostrais do ajuste de forma obtidas pelo MUM e pelo RWSEG no experimento Monte Carlo..	132
8.18 - Comparação das médias amostrais da média geral obtidas pelo MUM e pelo RWSEG no experimento Monte Carlo..	133
8.19 - Comparação das médias amostrais das medidas de ajuste obtidas pelo MUM em função do tipo de região..	135
8.20 - Comparação das médias amostrais das medidas de ajuste obtidas pelo RWSEG em função do tipo de região.....	136
8.21 - Comparação das médias amostrais das medidas de ajuste e média geral obtidas pelo MUM e pelo RWSEG para regiões homogêneas.....	138

8.22 - Comparação das médias amostrais das medidas de ajuste e média geral obtidas pelo MUM e pelo RWSEG para regiões heterogêneas.....	138
8.23 - Comparação das médias amostrais das medidas de ajuste e média geral obtidas pelo MUM e pelo RWSEG para regiões extremamente heterogêneas.....	139
8.24 - Segmentação manual, <i>phantom</i> e segmentações da imagem 3 <i>looks</i> produzidas pelo MUM com $p=5$ e RWSEG com $e=2,58$ e $j=2$	141
8.25 - Segmentação manual e segmentações da imagem 8 <i>looks</i> produzidas pelo MUM com $p=3$, $p=6$, $p=10$, $p=13$ e $p=17$	144
8.26 - Segmentação manual e segmentações da imagem 8 <i>looks</i> produzidas pelo MUM com $p=7$, $p=8$, $p=9$, $p=11$ e $p=12$	145
8.27 - Média geral das segmentações da imagem de 8 <i>looks</i> produzidas pelo MUM.....	146
8.28 - Segmentação manual e segmentações da imagem 8 <i>looks</i> produzidas pelo RWSEG com $j=0$ e $e=1,65$, $e=2,58$, $e=3,29$, $e=4,06$ e $e=4,91$	151
8.29 - Segmentação manual e segmentações da imagem 8 <i>looks</i> produzidas pelo RWSEG com $j=8$ e $e=1,65$, $e=2,58$, $e=3,29$, $e=4,06$ e $e=4,91$	152
8.30 - Segmentação manual e segmentações da imagem 8 <i>looks</i> produzidas pelo RWSEG com $j=2$ e $e=2,33$, $e=2,58$, $e=2,81$, $e=3,09$ e $e=3,29$	153
8.31 - Segmentação manual e segmentações da imagem 8 <i>looks</i> produzidas pelo RWSEG com $j=4$ e $e=2,33$, $e=2,58$, $e=2,81$, $e=3,09$ e $e=3,29$	154
8.32 - Média geral das segmentações da imagem de 8 <i>looks</i> produzidas pelo RWSEG.....	155
8.33 - Valores do ajuste de posição obtidos em cada segmentação produzida pelo MUM e pelo RWSEG no experimento Monte Carlo.	161
8.34 - Valores do ajuste de intensidade média obtidos em cada segmentação produzida pelo MUM e pelo RWSEG no experimento Monte Carlo.	161
8.35 - Valores do ajuste de tamanho obtidos em cada segmentação produzida pelo MUM e pelo RWSEG no experimento Monte Carlo.	162

8.36 - Valores do ajuste de forma obtidos em cada segmentação produzida pelo MUM e pelo RWSEG no experimento Monte Carlo.	162
8.37 - Valores da média geral obtida em cada segmentação produzida pelo MUM e pelo RWSEG no experimento Monte Carlo.	163
8.38 - Comparação das médias amostrais do ajuste de posição obtidas pelo MUM e pelo RWSEG no experimento Monte Carlo..	164
8.39 - Comparação das médias amostrais do ajuste de intensidade obtidas pelo MUM e pelo RWSEG no experimento Monte Carlo..	165
8.40 - Comparação das médias amostrais do ajuste de tamanho obtidas pelo MUM e pelo RWSEG no experimento Monte Carlo..	165
8.41 - Comparação das médias amostrais do ajuste de forma obtidas pelo MUM e pelo RWSEG no experimento Monte Carlo..	166
8.42 - Comparação das médias amostrais da média geral obtidas pelo MUM e pelo RWSEG no experimento Monte Carlo..	166
8.43 - Comparação das médias amostrais das medidas de ajuste obtidas pelo MUM em função do tipo de região..	169
8.44 - Comparação das médias amostrais das medidas de ajuste obtidas pelo RWSEG em função do tipo de região.....	170
8.45 - Comparação das médias amostrais das medidas de ajuste e média geral obtidas pelo MUM e pelo RWSEG para regiões homogêneas.....	171
8.46 - Comparação das médias amostrais das medidas de ajuste e média geral obtidas pelo MUM e pelo RWSEG para regiões heterogêneas.....	171
8.47 - Comparação das médias amostrais das medidas de ajuste e média geral obtidas pelo MUM e pelo RWSEG para regiões extremamente heterogêneas.....	172
8.48 - Segmentação manual, <i>phantom</i> e segmentações da imagem <i>8 looks</i> produzidas pelo MUM com $p=10$ e RWSEG com $e=3,29$ e $j=2$	174
8.49 - Segmentação manual e segmentações da imagem real produzidas pelo MUM com $p=1, p=6, p=10, p=13$ e $p=17$	177

8.50 - Segmentação manual - e segmentações da imagem real produzidas pelo MUM com $p=11, p=12, p=14, p=15$ e $p=16$	178
8.51 - Média geral das segmentações da imagem real produzidas pelo MUM	179
8.52 - Segmentação manual e segmentações da imagem real produzidas pelo RWSEG com $j=2$ e $e=1,65, e=2,58, e=3,29, e=4,06$ e $e=4,91$	184
8.53 - Segmentação manual e segmentações da imagem real produzidas pelo RWSEG com $j=8$ e $e=1,65, e=2,58, e=3,29, e=4,06$ e $e=4,91$	185
8.54 - Segmentação manual e segmentações da imagem real produzidas pelo RWSEG com $j=8$ e $e=4,27, e=4,42, e=4,57, e=4,91$ e com $j=10 e=4,91$	186
8.55 - Segmentação manual e segmentações da imagem real produzidas pelo RWSEG com $j=10$ e $e=4,57, e=4,77, e=4,91$ e com $j=6$ e $e=4,77$ e $e=4,57$	187
8.56 - Média geral das segmentações da imagem real produzidas pelo RWSEG.....	188
8.57 - Segmentação manual, mapa de classes e segmentações da imagem real produzidas pelo MUM com $p=14$ e RWSEG com $e=4,57$ e $j=8$	194

LISTA DE TABELAS

	Pág.
3.1 - Distribuições no modelo multiplicativo para os diferentes graus de homogeneidade	38
6.1 - Valores relativos à segmentação de referência	72
6.2 - Valores relativos à segmentação.....	73
6.3 - Cômputo das medidas de qualidade de ajuste para cada par de regiões ajustadas	76
6.4 - Valores da média e variância gerais e de cada uma das medidas de qualidade.....	76
7.1 - Número de segmentos por grau de homogeneidade	90
7.2 - Distribuições e parâmetros adotados para modelar a imagem simulada de 3 <i>looks</i>	95
7.3 - Distribuições e parâmetros adotados para modelar a imagem simulada de 8 <i>looks</i>	95
8.1 - Tempo de processamento e número de classes e de segmentos obtidos.....	113
8.2 - Classificação qualitativa das segmentações	120
8.3 - Tempo de processamento e número de classes e de segmentos obtidos com $j=0$	122
8.4 - Tempo de processamento e número de classes e de segmentos obtidos com $j=2$	123
8.5 - Tempo de processamento e número de classes e de segmentos obtidos com $j=4$	123
8.6 - Tempo de processamento e número de classes e de segmentos obtidos com $j=6$	124
8.7 - Tempo de processamento e número de classes e de segmentos obtidos com $j=8$	124

8.8 - Tempo de processamento e número de classes e de segmentos obtidos com $j=10$	125
8.9 - Média e variância amostrais das medidas de ajuste obtidas no experimento Monte Carlo.....	130
8.10 – Média e variância amostrais das medidas de ajuste obtidas pelo MUM em função do tipo de região.....	133
8.11 - Média e variância amostrais das medidas de ajuste obtidas pelo RWSEG em função do tipo de região.....	134
8.12 - Tempo de processamento e número de classes e de segmentos obtidos.....	147
8.13 - Classificação qualitativa das segmentações	150
8.14 - Tempo de processamento e número de classes e de segmentos obtidos com $j=0$	156
8.15 - Tempo de processamento e número de classes e de segmentos obtidos com $j=2$	157
8.16 - Tempo de processamento e número de classes e de segmentos obtidos com $j=4$	157
8.17 - Tempo de processamento e número de classes e de segmentos obtidos com $j=6$	158
8.18 - Tempo de processamento e número de classes e de segmentos obtidos com $j=8$	158
8.19 - Tempo de processamento e número de classes e de segmentos obtidos com $j=10$	159
8.20 - Média e variância amostrais das medidas de ajuste obtidas no experimento Monte Carlo.....	163
8.21 - Média e variância amostrais das medidas de ajuste obtidas pelo MUM em função do tipo de região.....	167
8.22 - Média e variância amostrais das medidas de ajuste obtidas pelo RWSEG função do tipo de região	168
8.23 - Tempo de processamento e número de classes e de segmentos obtidos.....	180
8.24 - Classificação qualitativa das segmentações	183

8.25 - Tempo de processamento e número de classes e de segmentos	
obtidos com $j=0$	189
8.26 - Tempo de processamento e número de classes e de segmentos	
obtidos com $j=2$	190
8.27 - Tempo de processamento e número de classes e de segmentos	
obtidos com $j=4$	190
8.28 - Tempo de processamento e número de classes e de segmentos	
obtidos com $j=6$	191
8.29 - Tempo de processamento e número de classes e de segmentos	
obtidos com $j=8$	191
8.30 - Tempo de processamento e número de classes e de segmentos	
obtidos com $j=10$	192
8.31 - Valores individuais e média e variância gerais das medidas de ajuste.....	195
8.32 - Tempo de processamento e número de classes e segmentos	197

CAPÍTULO 1

INTRODUÇÃO

Nos últimos anos tem havido um crescente interesse nos dados obtidos através de radares de abertura sintética (SAR) e em suas aplicações em atividades de sensoriamento remoto. A importância destes sistemas deriva da sua capacidade de gerar imagens de alta resolução sem depender da iluminação solar ou das condições meteorológicas, sendo desta forma um valioso instrumento para aplicações civis e militares.

A crescente procura e disponibilidade atual e futura dos dados SAR geram uma profunda necessidade de desenvolvimento de técnicas automáticas de processamento e análise. Essas técnicas automáticas são essenciais para tornar operacional o emprego destas imagens por uma grande comunidade de usuários de dados de sensoriamento remoto.

Entretanto, a proposta e a implementação destas técnicas são tarefas relativamente complexas, uma vez que os sistemas SAR fazem uso de radiação coerente e os dados gerados por tais dispositivos são corrompidos com um ruído multiplicativo denominado *speckle*. Este ruído causa grandes variações nos valores de intensidade de cada ponto da imagem e dificulta dramaticamente o emprego e implementação de técnicas automáticas para extração de informações destes dados.

Os dados SAR apresentam características predominantemente aleatórias e muitos estudos têm sido conduzidos no sentido da sua modelagem probabilística. As propriedades estatísticas dos dados SAR podem ser diferentes para os diferentes alvos e para diferentes imagens, uma vez que o retroespalhamento é dependente de vários fatores, alguns relacionados ao sensor (comprimento de onda, ângulo de incidência, polarização, etc.), outros do alvo (rugosidade, permissividade, etc.) e outros do tipo de processamento (número de visadas, formato, etc.).

As propriedades estatísticas destes dados são usadas para discriminar tipos de usos dos solos, no desenvolvimento de filtros para redução do ruído *speckle* e no processo de interpretação e análise de dados SAR.

Um dos primeiros passos do processo de interpretação e análise de uma imagem consiste em particioná-la em seus elementos constituintes e representá-la através de um conjunto de regiões contínuas, disjuntas e, segundo algum critério tal como intensidade média, contraste ou textura, uniformes. Tal processo é denominado de segmentação.

A segmentação é uma das tarefas mais críticas no processo de análise de uma imagem, e sua importância tem impulsionado o desenvolvimento de uma grande variedade de algoritmos para esse propósito. O objetivo dos algoritmos de segmentação é prover um modo automático de obter uma decomposição de uma imagem. No caso mais simples, conhecido como *cartoon*, a imagem é decomposta em uma coleção de regiões nas quais a intensidade é constante (Cook et al., 1994).

A implementação e emprego de segmentadores de imagens SAR deve considerar suas características particulares e os fatores que intervêm na sua aquisição. Neste sentido, um aspecto relevante e complicador é que a hipótese de que os dados provindos destes dados serem normalmente distribuídos não é adequada. Por outro lado, a implementação pode ser feita utilizando-se diferentes tipos de técnicas. Deste modo, a avaliação do desempenho e comparação de algoritmos constitui-se em um importante objeto de estudo da segmentação.

Diversos métodos têm sido propostos para avaliar e comparar o desempenho de algoritmos de segmentação. Alguns exemplos encontrados na literatura a esse respeito são (Caves et al., 1996; Delves et al., 1992; Zhang, 1996, Quegan et al., 1988). Esses métodos visam indicar suas limitações, vantagens e aplicabilidade, e podem ser divididos em duas categorias: métodos analíticos e métodos empíricos. Os primeiros examinam e verificam os algoritmos através da análise de seus princípios e propriedades, enquanto os segundos os julgam indiretamente através de resultados. Esses resultados podem ser

obtidos usando-se imagens testes e medidas de qualidade da segmentação resultante (Zhang, 1996).

O objetivo deste trabalho é avaliar e comparar dois algoritmos de segmentação presentes no *software* CAESAR, o *Merge Using Moments* (Cook et al., 1994) e o RWSEG (White, 1986), desenvolvidos especificamente para dados SAR.

Uma vez que a segmentação depende do tipo de aplicação requerido pelo usuário, a avaliação e comparação dos algoritmos é realizada visando aplicações de uso e ocupação do solo, onde os principais alvos (regiões) de interesse são áreas de cultura agrícola, pastagens, solo exposto, florestas e áreas urbanas. Estas regiões podem ser descritas em função do grau de homogeneidade que possuem e podem ser classificadas como homogêneas, heterogêneas e extremamente heterogêneas, para um dado sistema de aquisição.

A metodologia proposta para avaliar o desempenho dos algoritmos utiliza uma abordagem empírica que consiste basicamente em segmentar imagens testes (real e simuladas) com os dois algoritmos e qualificar as segmentações produzidas a partir de análise qualitativa e quantitativa. Estas análises consistem na comparação das segmentações produzidas pelos algoritmos com uma segmentação de referência suposta como verdadeira. A análise qualitativa baseia-se na comparação visual enquanto que a quantitativa baseia-se na obtenção de medidas que quantificam a qualidade da segmentação produzida. Para amenizar a influência de uma imagem particular sobre as medidas quantitativas, é realizado um experimento Monte Carlo.

As imagens testes empregadas contem regiões com diferentes graus de homogeneidade. O processo de obtenção das imagens simuladas consiste na criação de um *phantom* (imagem idealizada de classes, onde cada classe representa um certo grau de homogeneidade) que resuma as principais características geométricas e topológicas da ocupação do solo e na modelagem estatística das observações provindas de cada classe através de uma distribuição particular.

A avaliação e a comparação relativa entre os algoritmos são feitas do ponto de vista da adequação para o tipo de aplicação definido, do desempenho qualitativo e quantitativo das segmentações produzidas de cada imagem de entrada, da capacidade de segmentar regiões com diferentes graus de homogeneidade, do custo computacional e da simplicidade de uso.

Dentre as figuras de mérito envolvidas, a avaliação do comportamento destes algoritmos quando empregados em imagens contendo regiões com diferentes graus de homogeneidade merece destaque. Isto porque estes algoritmos foram desenvolvidos sob hipóteses distribucionais particulares, associadas aos graus de homogeneidade das regiões de uma imagem e derivadas do modelo multiplicativo adotado para representar os dados SAR. É suposto, no caso de imagens processadas em amplitude, que o ruído *speckle* possui uma distribuição Raiz de Gama, $\Gamma^{1/2}(n, n)$, onde n é o número equivalente de *looks*, enquanto que o retroespalhamento possui uma distribuição Constante.

Dentro do contexto do modelo multiplicativo, estas suposições indicam que os dois algoritmos são aplicáveis somente para imagens com regiões homogêneas, uma vez que a modelagem do retroespalhamento das regiões heterogêneas e extremamente heterogêneas parte da hipótese básica que as mesmas possuem distribuições Raiz de Gama e recíproca da Raiz de Gama, respectivamente.

Como na prática os diferentes alvos nas imagens raramente se apresentam todos como homogêneos, este trabalho visa também a análise do comportamento dos algoritmos em regiões heterogêneas e extremamente heterogêneas, isto é, em regiões onde as suposições em que os algoritmos se baseiam não são necessariamente válidas.

Para apresentar os fundamentos teóricos, as formulações conhecidas e implementadas e os resultados obtidos, esta dissertação possui a capitulação abaixo descrita:

- ◆ No Capítulo 2 são apresentadas as notações e definições básicas a serem utilizadas no decorrer da dissertação, as formulações das principais distribuições aplicáveis aos

dados SAR empregadas, incluindo as funções densidade de probabilidade, média e variância;

- ◆ No Capítulo 3 é apresentada a modelagem utilizada para os dados SAR, onde são abordadas as distribuições decorrentes do modelo multiplicativo para as imagens em amplitude;
- ◆ No Capítulo 4 é apresentada a fundamentação teórica da segmentação, suas particularidades para dados SAR, bem como as técnicas usualmente empregadas para sua realização;
- ◆ No Capítulo 5 é apresentada a descrição dos algoritmos de segmentação MUM e RWSEG, incluindo seus princípios, suposições, técnicas empregadas e descrição dos parâmetros selecionáveis;
- ◆ No Capítulo 6 descreve-se o método e as medidas empregadas para quantificar a qualidade das segmentações obtidas pelos algoritmos;
- ◆ No Capítulo 7 é apresentada a metodologia aplicada neste trabalho para a obtenção dos resultados que permitirão a avaliação e comparação dos algoritmos, incluindo a proposta e obtenção das imagens utilizadas, os passos executados para obtenção das segmentações destas imagens pelos dois algoritmos, o processo de avaliação qualitativa e quantitativa das segmentações produzidas, o experimento Monte Carlo e os critérios empregados para comparar os algoritmos;
- ◆ No Capítulo 8 são apresentados, discutidos e comparados os resultados qualitativos e quantitativos das segmentações obtidas por cada algoritmo para cada dado de entrada, obtidos a partir da metodologia proposta;
- ◆ No Capítulo 9 são apresentadas as conclusões e sugestões resultantes deste trabalho.

CAPÍTULO 2

PRINCIPAIS DISTRIBUIÇÕES APLICADAS AOS DADOS SAR

A seguir serão apresentadas algumas notações, definições e as distribuições aplicáveis aos dados SAR que serão abordadas nesta dissertação.

2.1 - NOTAÇÕES E DEFINIÇÕES

As variáveis aleatórias serão denotadas com letras maiúsculas e suas ocorrências em letras minúsculas.

Os vetores e matrizes serão denotados em negrito e maiúsculos.

O conjunto dos números reais, $(-\infty, +\infty)$, será denotado por \mathfrak{R} .

O conjunto dos números reais positivos, $(0, +\infty)$, será denotado por \mathfrak{R}_+ .

O conjunto amostral será denotado por Ω .

A probabilidade será denotada por Pr .

2.1.1 - VARIÁVEIS ALEATÓRIAS

Seja Ω um espaço amostral genérico, B uma classe sobre a qual está definida a variável aleatória, Pr uma medida. A função real X que associa um valor $X(\omega)$ em B para cada resultado ω de Ω , sendo $X : \Omega \rightarrow \mathfrak{R}$, é uma variável aleatória real.

A função $F_X(x)$, definida por:

$$F_X(x) = Pr(X \leq x) ; x \in \mathfrak{R} ,$$

onde \mathfrak{R} é o conjunto dos números reais, é denominada *função distribuição* da variável aleatória X , e é comumente chamada de *função de distribuição acumulada* de X .

A função densidade de probabilidade $f(x)$, se existir, se relaciona com a função de distribuição acumulada através da relação (James, 1991):

$$F_X(x) = \int_{-\infty}^x f(x) dx,$$

e vale que $f(x) \geq 0, \forall x$ e que $\int_{-\infty}^{+\infty} f(x) dx = 1$.

2.1.2 - ESPERANÇA

A esperança de uma variável aleatória contínua X cuja densidade é $f(x)$, é denotada por $E[X]$ e definida por (James, 1991):

$$E[X] = \int_{-\infty}^{\infty} xf(x) dx,$$

desde que a integral acima exista. Algumas propriedades da esperança podem ser encontradas em DeGroot (1975).

2.1.3 - VARIÂNCIA

Suponha que X é uma variável aleatória com média $\mu = E[X]$. A variância de X denotada por $VAR[X]$ é definida por (DeGroot, 1975):

$$Var[X] = E[(X - \mu)^2], \text{ ou}$$

$$Var[X] = \int_{-\infty}^{\infty} (x - \mu)^2 f(x) dx,$$

desde que a integral acima exista. Algumas propriedades da variância podem ser encontradas em DeGroot (1975).

2.1.4 - MOMENTO

O momento de ordem r ($r \in \mathfrak{R}$) de uma variável aleatória X , caso exista, é definido por (DeGroot, 1975):

$$E(X^r) = \int_{\mathfrak{R}} x^r f(x) dx$$

e, segundo Yanasse et al. (1995), o coeficiente de variação é dado por:

$$C_v = \frac{Var^{1/2}(X)}{E(X)}.$$

2.2 - DISTRIBUIÇÕES APLICÁVEIS AOS DADOS SAR

Nesta seção serão apresentadas as distribuições aplicáveis aos dados SAR que serão abordadas nesta dissertação, incluindo suas respectivas funções de densidade de probabilidade, esperança e variância.

2.2.1 - DISTRIBUIÇÃO CONSTANTE

Diz-se que uma variável aleatória X possui distribuição Constante igual ao valor k , denotada por $X \sim C(k)$, se a sua função de distribuição acumulada é dada, para todo $x \in \mathfrak{R}$, por (Yanasse et al., 1995):

$$F_X(x) = \Pi_{[k, \infty)}(x),$$

onde $\Pi_A(x)$ é a função indicadora de um conjunto A , denotada por $\Pi: A \rightarrow \{0,1\}$ e dada por (James, 1991):

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

2.2.2 - DISTRIBUIÇÃO GAMA

Diz-se que a variável aleatória X possui uma distribuição Gama com parâmetros α e $\lambda \in \mathfrak{R}_+$, denotada por $X \sim \Gamma(\alpha, \lambda)$, se sua densidade, para todo $x \in \mathfrak{R}$, é dada por (Frery, 1993; Sant'Anna, 1995; Yanasse et al., 1993; Yanasse et al., 1995):

$$f_x(x; \alpha, \lambda) = \frac{\lambda^\alpha}{\Gamma(\alpha)} x^{\alpha-1} \exp(-\lambda x).$$

Tem-se que $E[X] = \alpha\lambda^{-1}$ e $Var[X] = \alpha\lambda^{-2}$. Considerando uma distribuição Gama com $E[X] = 1$, ou seja, $\alpha = \lambda$, a sua densidade será dada por:

$$f_x(x; \alpha, \alpha) = \frac{(\alpha x)^{\alpha-1}}{\alpha^{-1}\Gamma(\alpha)} \exp(-\alpha x).$$

2.2.3 - DISTRIBUIÇÃO RAIZ DE GAMA

A variável aleatória X possui uma distribuição Raiz de Gama com parâmetros α e $\lambda \in \mathfrak{R}_+$, denotada por $X \sim \Gamma^{\frac{1}{2}}(\alpha, \lambda)$, se sua densidade, para todo $x \in \mathfrak{R}_+$, é dada por (Frery, 1993; Yanasse et al., 1993; Yanasse et al., 1995):

$$f_x(x; \alpha, \lambda) = \frac{2\lambda^\alpha}{\Gamma(\alpha)} x^{2\alpha-1} \exp(-\lambda x^2).$$

A média é dada por:

$$E[X] = \frac{\Gamma(\alpha + 0,5)}{\lambda^{\frac{1}{2}}\Gamma(\alpha)} \quad (2.1).$$

A variância é dada por:

$$VAR[X] = \frac{1}{\lambda} \left[\alpha - \left(\frac{\Gamma(\alpha + 0,5)}{\Gamma(\alpha)} \right)^2 \right].$$

Pode-se demonstrar (Yanasse et al., 1995) que a variável aleatória formada pelo produto de duas variáveis aleatórias independentes com distribuições $C(\sqrt{\beta})$ e $\Gamma^{\frac{1}{2}}(n, n)$ respectivamente, possui uma distribuição $\Gamma^{\frac{1}{2}}(n, n\beta^{-1})$.

2.2.4 - DISTRIBUIÇÃO RECÍPROCA DA RAIZ DE GAMA

A variável aleatória X possui uma distribuição Recíproca da Raiz de Gama com parâmetros $-\alpha$ e $\lambda \in \mathfrak{R}_+$, denotada por $X \sim \Gamma^{-1/2}(\alpha, \lambda)$, se sua densidade, para todo $x \in \mathfrak{R}_+$, é dada por (Frery, 1997):

$$f_X(x; \alpha, \lambda) = \frac{2}{\lambda^\alpha \Gamma(-\alpha)} x^{2\alpha-1} \exp\left(-\frac{\lambda}{x^2}\right).$$

2.2.5 - DISTRIBUIÇÃO RAIZ DE GAUSSIANA INVERSA GENERALIZADA

Diz-se que a variável aleatória X possui uma distribuição Raiz de Gaussiana Inversa Generalizada, com parâmetros α, γ e λ , denotada por $X \sim N^{-1/2}(\alpha, \gamma, \lambda)$, se a sua densidade, para todo $x \in \mathfrak{R}_+$, for dada por (Frery et al., 1995a):

$$f_X(x; \alpha, \gamma, \lambda) = \frac{(\lambda/\gamma)^{\alpha/2}}{K_\alpha(2\sqrt{\lambda\gamma})} x^{2\alpha-1} \exp\left(-\frac{\gamma}{x^2} - \lambda x^2\right),$$

Onde K_α denota a função modificada de Bessel de terceiro tipo e ordem α , e o domínio dos parâmetros é dado por (Frery et al., 1995a):

$$\begin{cases} \gamma > 0, \lambda \geq 0, \text{ se } \alpha < 0 \\ \gamma > 0, \lambda > 0, \text{ se } \alpha = 0 \\ \gamma \geq 0, \lambda > 0, \text{ se } \alpha > 0 \end{cases} \quad (2.2).$$

O momento de ordem $r \in \mathfrak{R}$ é dado por (Frery et al., 1995a):

$$E(X^r) = \frac{K_{\alpha+r/2}(2\sqrt{\gamma\lambda})}{K_\alpha(2\sqrt{\gamma\lambda})} \left(\frac{\gamma}{\lambda}\right)^{r/4}.$$

As distribuições Raiz de Gama e Recíproca da Raiz de Gama são casos particulares da distribuição Raiz de Gaussiana Inversa Generalizada. O esquema abaixo mostra a relação entre estas distribuições.

$$N^{-1/2}(\alpha, \gamma, \lambda) \left\{ \begin{array}{l} \xrightarrow{D} \Gamma^{1/2}(\alpha, \lambda) \xrightarrow{\text{Pr}} C(\beta_1^{1/2}) \\ \gamma \rightarrow 0 \quad \alpha, \lambda \rightarrow \infty \\ \alpha, \lambda > 0 \quad \alpha/\lambda \rightarrow \beta_1 \\ \\ \xrightarrow{D} \Gamma^{-1/2}(\alpha, \gamma) \xrightarrow{\text{Pr}} C(\beta_2^{-1/2}) \\ \lambda \rightarrow 0 \quad -\alpha, \gamma \rightarrow \infty \\ -\alpha, \gamma > 0 \quad -\alpha/\gamma \rightarrow \beta_2 \end{array} \right. ,$$

onde “ \xrightarrow{D} ” e “ $\xrightarrow{\text{Pr}}$ ” denotam as convergências em distribuição e probabilidade, respectivamente, das seqüências de variáveis aleatórias associadas.

2.2.6 - DISTRIBUIÇÃO K-AMPLITUDE

Diz-se que a variável aleatória X possui distribuição K-Amplitude (KA) com parâmetros $\alpha, \lambda, n \in \mathfrak{R}_+$, denotada por $X \sim KA(\alpha, \lambda, n)$, se sua densidade, para cada $x \in \mathfrak{R}$, é dada por (Frery, 1993; Yanasse et al., 1993):

$$f_X(x; \alpha, \lambda, n) = \frac{4\alpha n x}{\lambda \Gamma(\alpha) \Gamma(n)} \sqrt{\left(\frac{\alpha n x^2}{\lambda}\right)^{(\alpha+n-2)}} K_{\alpha-n} \left(2x \sqrt{\frac{\alpha n}{\lambda}}\right).$$

O momento de ordem $r \in \mathfrak{R}$ é dado por (Frery, 1993; Yanasse et al., 1993):

$$E(X^r) = \sqrt{\left(\frac{\lambda}{\alpha n}\right)^r} \frac{\Gamma(r/2 + \alpha) \Gamma(r/2 + n)}{\Gamma(\alpha) \Gamma(n)}.$$

A média é dada por:

$$E[X] = \sqrt{\frac{\lambda}{\alpha n}} \frac{\Gamma(1/2 + \alpha) \Gamma(1/2 + n)}{\Gamma(\alpha) \Gamma(n)}. \quad (2.3).$$

Pode-se demonstrar (Yanasse et al., 1995) que a variável aleatória formada pelo produto de duas variáveis aleatórias independentes com distribuições $\Gamma^{1/2}(\alpha, \beta)$ e $\Gamma^{1/2}(n, n)$ respectivamente, possui uma distribuição $KA(\alpha, \lambda, n)$, onde $\lambda = \alpha\beta^{-1}$.

2.2.7 - DISTRIBUIÇÃO G-AMPLITUDE

A variável aleatória X possui uma distribuição G-Amplitude (GA), com parâmetros α , γ , λ e n , denotada por $X \sim GA(\alpha, \gamma, \lambda, n)$ se sua densidade, para todo $x \in \mathfrak{R}$, é dada por (Frery et al., 1995):

$$f_x(x; \alpha, \gamma, \lambda, n) = \frac{2n^n \left(\frac{\lambda}{\gamma}\right)^{\alpha/2}}{\Gamma(n) K_\alpha(2\sqrt{\lambda\gamma})} x^{2n-1} \left(\frac{\gamma + nx^2}{\lambda}\right)^{(\alpha-n)/2} K_{\alpha-n}\left(2\sqrt{\lambda(\gamma + nx^2)}\right),$$

e o domínio dos parâmetros dado em (2.2).

O momento de ordem $r \in \mathfrak{R}$ é dado por (Frery et al., 1995):

$$E(X^r) = \frac{K_{\alpha+r/2}(2\sqrt{\gamma\lambda})\Gamma(n+r/2)}{K_\alpha(2\sqrt{\gamma\lambda})\Gamma(n)} \left(\frac{\gamma}{n^2\lambda}\right)^{r/4}.$$

2.2.8 - DISTRIBUIÇÃO G-AMPLITUDE ZERO

Diz-se que a variável aleatória X possui uma distribuição G-Amplitude Zero, com parâmetros α, γ , e n , denotada por $X \sim G_A^0(\alpha, \gamma, n)$, supondo-se $\alpha < 0$ e $\gamma, n > 0$, se a sua densidade, para todo $x \in \mathfrak{R}$, for dada por (Frery et al., 1995b):

$$f_x(x; \alpha, \gamma, n) = \frac{2n^n \Gamma(n - \alpha) x^{2n-1}}{\gamma^\alpha \Gamma(n) \Gamma(-\alpha) (\gamma + nx^2)^{n-\alpha}}.$$

O momento de ordem $r \in \mathfrak{R}$ é dado por (Frery et al., 1995b):

$$E(X^r) = \begin{cases} \frac{\Gamma(-\alpha - r/2)\Gamma(n + r/2)}{\Gamma(-\alpha)\Gamma(n)} \left(\frac{\gamma}{n}\right)^{r/2}, & \text{se } r < -2\alpha \\ \infty, & \text{em caso contrário} \end{cases}.$$

A média é dada por:

$$E[X] = \frac{\Gamma(-\alpha - 1/2)\Gamma(n + 1/2)}{\Gamma(-\alpha)\Gamma(n)} \left(\frac{\gamma}{n}\right)^{1/2} \quad (2.4).$$

Pode-se demonstrar (Frery et al., 1997) que a variável aleatória formada pelo produto de duas variáveis aleatórias independentes com distribuições $\Gamma^{-1/2}(\alpha, \gamma)$ e $\Gamma^{1/2}(n, n)$ respectivamente, possui uma distribuição $G_A^0(\alpha, \gamma, n)$.

As distribuições $\Gamma^{1/2}$, KA e G_A^0 são casos particulares da distribuição GA . O esquema abaixo mostra a relação entre estas distribuições.

$$GA(\alpha, \gamma, \lambda, n) \left\{ \begin{array}{l} \xrightarrow{D} KA(\alpha, \lambda, n) \quad \xrightarrow{Pr} \Gamma^{1/2}(n, n/\beta_1) \\ \gamma \rightarrow 0 \quad \alpha, \lambda \rightarrow \infty \\ \alpha, \lambda > 0 \quad \alpha/\lambda \rightarrow \beta_1 \\ \xrightarrow{D} G_A^0(\alpha, \gamma, n) \quad \xrightarrow{Pr} \Gamma^{1/2}(n, n\beta_2) \\ \lambda \rightarrow 0 \quad -\alpha, \gamma \rightarrow \infty \\ -\alpha, \gamma > 0 \quad -\alpha/\gamma \rightarrow \beta_2 \end{array} \right. ,$$

onde “ \xrightarrow{D} ” e “ \xrightarrow{Pr} ” denotam as convergências em distribuição e probabilidade, respectivamente, das seqüências de variáveis aleatórias associadas.

CAPÍTULO 3

MODELAGEM DOS DADOS SAR

O imageamento por radar consiste da emissão de pulsos de microondas a intervalos regulares sobre uma região de interesse e da recepção dos ecos provenientes da interação entre os pulsos e a região imageada. O processamento do sinal de retorno SAR pode ser em range (direção perpendicular ao deslocamento do sensor) ou em azimuth (direção do deslocamento do sensor) e tem como objetivo recuperar o valor do coeficiente de retroespalhamento da seção transversal por unidade de área de um alvo (σ^0). Este coeficiente é função dos parâmetros do sensor (comprimento de onda, ângulo de incidência e polarização) e das características geométricas e dielétricas do alvo.

O tipo de detecção do sinal de retorno pode ser linear ou quadrático. Deste modo, a imagem do terreno pode ser formada tanto em amplitude (detecção linear) quanto em intensidade (detecção quadrática). Entretanto, devido à natureza coerente da radiação emitida pelos radares imageadores (faixa espectral das microondas), as imagens SAR são corrompidas por um ruído dependente do sinal denominado *speckle*. Este ruído tem caráter multiplicativo, ou seja, é mais intenso onde o sinal de retorno é maior e dá uma aparência granular às imagens.

Para reduzir o nível de ruído *speckle* nas imagens SAR pode-se realizar um outro tipo de processamento denominado *multilook*. Entretanto, este tipo de processamento reduz a resolução espacial proporcionalmente ao número de *looks*.

Os dados SAR apresentam características predominantemente aleatórias e muitos estudos têm sido conduzidos no sentido de modelá-los probabilisticamente. As propriedades estatísticas destes dados são usadas para discriminar tipos de usos dos solos, no desenvolvimento de filtros para redução do ruído *speckle*, na obtenção de imagens simuladas e em processo de interpretação e análise de dados SAR (Dutra et al., 1993). Além disto, o método a ser empregado por um certo segmentador pode estar baseado em considerações distribucionais para os dados de entrada.

Como observado em Frery et al. (1997), a maioria dos dados provindos de sistemas SAR não obedecem a distribuição Gaussiana devido à natureza coerente da radiação empregada para formar as imagens, na qual aparecem fenômenos de interferência construtiva e destrutiva do sinal de retorno. Deste modo, o modelo empregado para representar estes dados deve ser capaz de separar o ruído do que seria efetivamente a resposta do alvo.

3.1 - MODELO MULTIPLICATIVO

O comportamento estatístico e modelagem dos dados SAR é geralmente explicado com base no modelo multiplicativo e dele advêm as distribuições utilizadas para modelar tanto o sinal de retorno quanto o ruído speckle (Vieira, 1996; Frery, 1993; Yanasse, 1991; Yanasse et al., 1995).

No modelo multiplicativo é suposto que o valor observado em cada coordenada da imagem é a ocorrência de uma variável aleatória $Z = XY$, sendo X e Y variáveis aleatórias independentes, onde X representa a variável aleatória que modela o retroespalhamento do pulso incidente na superfície terrestre (*backscatter*) e Y representa a variável aleatória que modela o ruído associado à radiação coerente que incide sobre a cena (*speckle*) (Yanasse et al., 1995).

As distribuições associadas a X e Y variam em função do tipo de detecção (linear ou quadrática) e dos diferentes tipos de regiões (homogêneas, heterogêneas e extremamente heterogêneas), produzindo diferentes distribuições para cada dado observado Z (Ulaby e Dobson, 1989; Frery et al., 1997).

A obtenção de imagens sintéticas necessárias para este trabalho envolve a modelagem dos diferentes tipos de regiões e considera apenas o tipo de detecção linear (imagem amplitude).

Quanto aos tipos de regiões, serão abordadas as homogêneas (por exemplo, para um certo sistema, áreas de cultura agrícola, pastagens, solo exposto, etc.), as heterogêneas (floresta primária, por exemplo) e as extremamente heterogêneas (áreas urbanas, por

exemplo). Cabe salientar que a definição do grau de homogeneidade de um determinado tipo de região é função da configuração (banda, resolução, etc.) do sistema empregado para aquisição da imagem.

O *backscatter* das imagens em amplitude pode ser modelado por diferentes distribuições, dependendo do grau de homogeneidade do alvo.

A modelagem para regiões homogêneas parte da hipótese básica de que o *backscatter* possui um valor constante, porém desconhecido. Assim, supõe-se que pode ser modelado por uma distribuição constante (Yanasse et al., 1995), isto é:

$$X \sim C(\sqrt{\beta}).$$

A modelagem das regiões heterogêneas parte da hipótese básica que o *backscatter* não possui um valor constante, mas pode ser modelado por uma distribuição Raiz de Gamma (Frery et al., 1995; Yanasse et al., 1995), isto é:

$$X \sim \Gamma^{1/2}(\alpha, \lambda).$$

A modelagem das regiões extremamente heterogêneas parte da hipótese básica que o *backscatter* pode ser modelado por uma distribuição Recíproca da Raiz de Gama (Frery et al., 1997), isto é:

$$X \sim \Gamma^{-1/2}(\alpha, \lambda).$$

Em (Frery et al., 1997) é proposto um modelo geral considerando que o *backscatter* possui uma distribuição Raiz de Gaussiana Inversa Generalizada. Esta distribuição possui como casos especiais mais simples as distribuições descritas acima para modelar os diferentes tipos de regiões. A modelagem simplificada possui vantagem de tornar mais fácil a estimação dos parâmetros destas distribuições.

O ruído *speckle*, sob certas condições, pode ser modelado por uma distribuição Raiz de Gama com ambos os parâmetros iguais ao número equivalente de *looks* da imagem (Ulaby et al.,1986), isto é:

$$Y \sim \Gamma^{\frac{1}{2}}(n, n).$$

O número equivalente de *looks* (n) equivale ao número de pixels que devem ser somados no processamento *multilook*, de modo a se obter a mesma informação quantitativa que a soma dos pixels da imagem original, que apresentam informação redundante. Este parâmetro é, em geral, conhecido ou estimado para toda a imagem.

Considerando as modelagens supostas para o *backscatter* e para o *speckle*, as possíveis distribuições para o retorno Z , para o caso de n *looks*, podem ser resumidas conforme indicado na Tabela 3.1.

TABELA 3.1 - DISTRIBUIÇÕES NO MODELO MULTIPLICATIVO PARA OS DIFERENTES GRAUS DE HOMOGENEIDADE

Grau de homogeneidade	<i>Backscatter</i>	<i>Speckle</i>	Retorno
	X	Y	$Z = XY$
Caso Geral	$N^{-1/2}(\alpha, \gamma, \lambda)$	$\Gamma^{\frac{1}{2}}(n, n)$	$GA(\alpha, \gamma, \lambda, n)$
Homogêneas	$C(\sqrt{\beta})$	$\Gamma^{\frac{1}{2}}(n, n)$	$\Gamma^{\frac{1}{2}}(n, n\beta^{-1})$
Heterogêneas	$\Gamma^{\frac{1}{2}}(\alpha, \lambda)$	$\Gamma^{\frac{1}{2}}(n, n)$	$KA(\alpha, \lambda, n)$
Extremamente Heterogêneas	$\Gamma^{-\frac{1}{2}}(\alpha, \gamma)$	$\Gamma^{\frac{1}{2}}(n, n)$	$G_A^0(\alpha, \gamma, n)$

FONTE: Vieira (1996, p.36).

Na Tabela 3.1 nota-se que para regiões homogêneas o retorno é modelado por uma distribuição Raiz de Gama, para regiões heterogêneas por uma distribuição K -Amplitude e para regiões extremamente heterogêneas por uma distribuição G -Amplitude Zero.

O parâmetro α das distribuições K -Amplitude e G -Amplitude Zero está relacionado com o grau de homogeneidade (rugosidade) dos dados. Uma vez conhecidos os valores de α

e n (número de *looks*), pode-se determinar os parâmetros (de escala) λ e γ das distribuições K -Amplitude e G -Amplitude Zero, respectivamente.

A Figura 3.1 apresenta um exemplo comparativo entre as distribuições Raiz de Gama, K -Amplitude e G -Amplitude Zero.

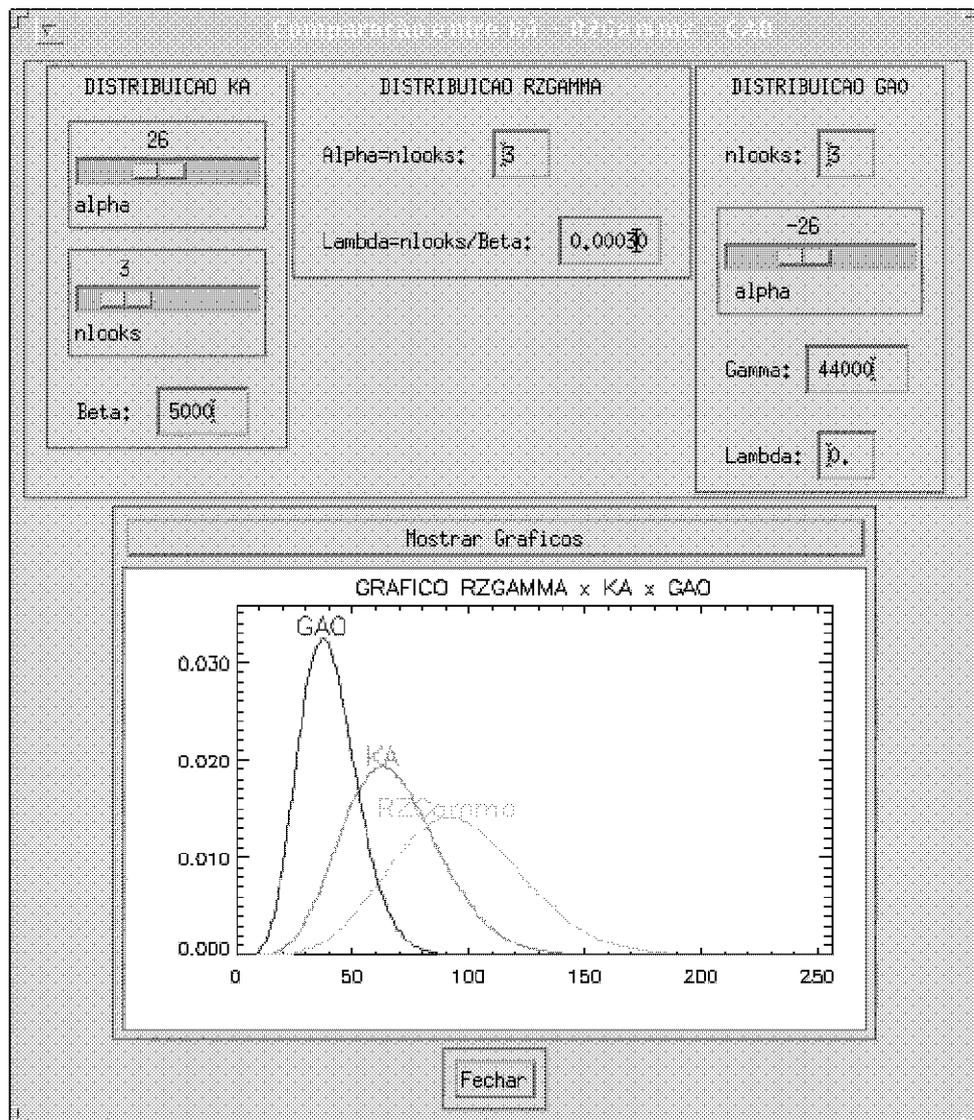


Fig. 3.1 – Exemplos das distribuições Raiz de Gama, K -amplitude e G -amplitude zero.

CAPÍTULO 4

SEGMENTAÇÃO DE IMAGENS SAR

Segundo Gonzales e Wintz (1987), um dos primeiros passos do processo de análise de uma imagem digital consiste em particioná-la em seus elementos constituintes. O processo de agrupar pixels de uma imagem em partições é baseado em alguma propriedade intrínseca da imagem tal como intensidade média, contraste ou textura (Le Moigne e Tilton, 1995). Tal processo é denominado de segmentação e representa o menor nível descritivo no qual o entendimento de uma imagem possa ser baseado (Caves et al., 1996). A segmentação pode resumir todos os objetos (alvos) distintos que compõem uma imagem, e esta possibilidade a torna muito valiosa para extração de informações.

Além de subsídio para análise, a segmentação de uma imagem também pode ser empregada como parte do processo de gerenciamento e compressão de dados. Muitos tipos distintos de aplicação requerem ou se beneficiam deste tipo de informação, sendo o estudo do uso e ocupação do solo um deles. Muito embora a segmentação permita representar objetos da imagem como entidades únicas, ela não é a priori uma classificação e sim um reconhecimento da estrutura desta imagem. Entretanto, estes dois processos estão intimamente ligados, uma vez que os segmentos podem ser classificados a partir da característica comum de todos os pixels que os constituem. A segmentação pode, por exemplo, servir como primeiro passo para algoritmos de classificação contextual, uma vez que seu resultado contém descrições da estrutura da imagem, tais como adjacência, área, posição e forma das regiões constituintes.

A segmentação depende do tipo de aplicação e também do tipo de sensor empregado para aquisição dos dados, uma vez que duas imagens de uma mesma cena tomadas com diferentes resoluções, ou diferentes bandas espectrais, produzirão segmentações diferentes (Tailor et al., 1988).

O modelo mais geral associado à operação de segmentação é aquele no qual a cena consiste de regiões que obedecem a um certo critério de similaridade. Regiões adjacentes distintas são separadas através de bordas que correspondem a mudanças em alguma propriedade estatística local, tal como intensidade média ou textura. Neste trabalho serão consideradas somente as segmentações produzidas através dos valores radiométricos (intensidade) de cada pixel da imagem de entrada. Cabe notar que variações na intensidade podem não ser um bom indicador das variações físicas da cena, assim como variações físicas nem sempre originam variações na intensidade.

Para dados SAR, o modelo de estrutura mais simples para uma imagem é aquele em que o *backscatter* é constante dentro dos segmentos, com bordas indicando uma mudança dessa grandeza. Na literatura este modelo é conhecido como *cartoon* e, segundo Caves et al. (1996), as técnicas de segmentação de imagens SAR baseadas neste modelo podem ser aplicadas com sucesso à segmentação de regiões limitadas por bordas abruptas, porém não são capazes de representar mudanças graduais de intensidade nem feições lineares.

A segmentação de uma imagem pode ser obtida manualmente ou automaticamente. A segmentação manual tem como principal vantagem a possibilidade de contar com outros dados (percepção humana, cartas, mapas, pesquisa de campo, etc.) além dos contidos na imagem. A segmentação manual de uma imagem não é única. Diferentes intérpretes podem gerar diferentes resultados e um mesmo intérprete pode gerar resultados diferentes em tempos diferentes.

A segmentação feita automaticamente (a partir de algoritmos desenvolvidos para este propósito) baseia-se primariamente em técnicas de reconhecimento de similaridade ou de diferenças mensuráveis entre regiões adjacentes.

Muita pesquisa tem sido conduzida para desenvolver algoritmos para segmentação automática de uma imagem. Entretanto, a maioria só são aplicáveis para imagens obtidas por sensores ópticos, uma vez que não são adaptadas para as características particulares das imagens obtidas por radares imageadores de abertura sintética (SAR). O ruído

multiplicativo presente nestas imagens causa grandes variações nos valores de intensidade de cada ponto da imagem e dificulta dramaticamente o seu processamento através de técnicas de reconhecimento de padrões.

As técnicas empregadas pelos algoritmos de segmentação são geralmente baseadas em duas propriedades básicas dos valores de níveis de cinza: descontinuidade e similaridade. Na primeira categoria a abordagem é particionar uma imagem tomando por base as mudanças abruptas do nível de cinza. As principais áreas de interesse desta categoria são a detecção de pontos isolados, de linhas e de bordas da imagem.

Na segunda categoria a abordagem é baseada no estabelecimento de um limiar para separar alvos distintos de uma imagem. A limiarização pode ser entendida como uma operação que envolve testes contra uma função da forma $T = T[x, y, p(x, y), f(x, y)]$, onde $f(x, y)$ é o nível de cinza no ponto (x, y) e $p(x, y)$ denota alguma propriedade local deste ponto, por exemplo, a média dos níveis de cinza de uma vizinhança centrada no ponto (x, y) . Deste modo, uma imagem limiarizada $g(x, y)$ pode ser definida, por exemplo, como:

$$g(x, y) = \begin{cases} 1 & \text{se } f(x, y) > T \\ 0 & \text{se } f(x, y) \leq T \end{cases}$$

Deste modo, pixels rotulados como 1 correspondem a alvos enquanto que rotulados com zero correspondem ao fundo (*background*). A segmentação é então conduzida analisando a imagem pixel por pixel e rotulando cada um como alvo ou fundo em função do limiar selecionado (Gonzales e Wintz, 1987).

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

Segmentações produzidas por algoritmos que empregam técnicas de ajuste de regiões são realizadas através de tentativas de ajustar um padrão para cada porção da imagem de

entrada. Uma das mais simples implementações desta abordagem é a técnica de divisão e agrupamento de regiões (*split and merge*). Neste caso, a segmentação é realizada juntando-se regiões adjacentes se as mesmas forem similares ou dividindo uma região se a mesma não é homogênea (White, 1986). Segundo Gonzales e Wintz (1987), uma abordagem para segmentar uma imagem através desta técnica consiste em subdividir a imagem de entrada sucessivamente em quadrantes que satisfaçam certa propriedade. Desta forma, para cada quadrante, verifica-se se a propriedade é válida ou não e se um dado quadrante não satisfazer tal propriedade, ele é subdividido em subquadrantes e assim por diante. O próximo passo é agrupar regiões adjacentes que são similares, isto é, satisfazem a propriedade definida. O processo termina quando não for mais possível nenhuma divisão ou agrupamento.

Entretanto, existem algumas limitações no emprego desta técnica. Uma delas é que, uma vez que a segmentação é feita a partir da produção de divisões quadradas da imagem original, a segmentação final tende a ter regiões com formas quadradas. Outro aspecto é que as regiões produzidas são dependentes do ponto de partida e regiões homogêneas podem ser segmentadas dependendo da sua posição espacial com respeito a matriz quadrada definida. Finalmente, esta abordagem tende a perder pequenas regiões dentro de grandes áreas uniformes.

Segundo White (1986), esta técnica pode ser empregada para imagens SAR. Neste caso, a janela (quadrante) precisa ser suficientemente grande para possibilitar a detecção de discontinuidades na presença de ruído. Por outro lado, a janela não pode ser muito grande, pois os resultados são confusos quando regiões pequenas são encontradas. Deste modo, a maior limitação desta técnica para dados SAR é a necessidade de se empregar janelas de tamanho fixo. Um exemplo de aplicação desta técnica em algoritmos de segmentação de imagens SAR pode ser encontrado em Gerbrands e Backer (1984).

Segmentações produzidas por algoritmos que empregam técnicas de crescimento de regiões baseiam-se na procura direta de regiões, onde o procedimento consiste em agrupar pixels ou sub-regiões em regiões maiores. Nesta técnica, a segmentação se inicia

com partições pequenas, distintas e homogêneas da imagem para depois agrupar essas partições empregando-se critérios de similaridade de uma certa propriedade (nível médio de cinza, por exemplo) entre partições vizinhas. A seleção do critério de similaridade depende da aplicação considerada e do tipo de dado disponível.

Alguns problemas desta técnica são a seleção das partições iniciais, a seleção de propriedades convenientes para crescer (ou agrupar) essas partições e a formulação de uma regra de término para o processo. Outro problema é que toda vez que um novo pixel é juntado a um segmento, a característica deste segmento é redefinida. A adição de um pixel a um segmento é dependente do limiar de similaridade automático ou manual adotado. Pixels situados em zonas de fronteira entre duas regiões distintas podem ter características impuras, ou seja, seus valores radiométricos podem ser uma combinação das radiometrias que definem essas regiões. Deste modo, se o limiar estabelecido é muito alto, o crescimento de regiões vai deixar muitos desses pixels como segmentos diminutos. Entretanto, se o limiar é baixo, segmentos que representam classes distintas serão agrupados.

Com respeito ao emprego para imagens SAR, esta técnica permite o crescimento de qualquer segmento para qualquer tamanho e forma de janelas desejado. Entretanto, a necessidade de seleção de parâmetros de similaridade dificulta sua aplicação, devido à dificuldade de se encontrar parâmetros fixos que possam ser empregados para diferentes imagens. Exemplos de algoritmos de segmentação de imagens SAR que empregam esta técnica podem ser encontrados em Cook et al. (1994) e Oddy e Rye (1983).

Segmentações produzidas por algoritmos que empregam técnicas de detecção de bordas baseiam-se em encontrar limites entre regiões homogêneas de diferentes propriedades (White, 1996), e necessitam de operadores específicos que realcem as bordas antes da segmentação (Bénié et al., 1989). Uma borda é o limite entre duas regiões com propriedades de níveis de cinza relativamente distintas e sua detecção pode ser feita automaticamente por operadores de derivadas locais denominados de gradiente, os quais são implementados usando-se janelas (máscaras) de variados tamanhos.

Técnicas de detecção de bordas têm sido largamente empregadas para segmentar imagens ópticas. Alguns exemplos de operadores de bordas usados em tais imagens são os gradientes de Robert, Prewitt e Sobel (Gonzales e Wintz, 1987), os quais utilizam máscaras de tamanhos 2×2 , 3×3 ou 5×5 . Entretanto, os mesmos são pouco eficientes para imagens SAR, basicamente devido ao pequeno tamanho das máscaras empregadas. Todavia, para estas imagens, o gradiente de Sobel é o mais apropriado devido ao efeito de suavização que causa na imagem. Por outro lado, o emprego de máscaras maiores, 9×9 por exemplo, pode facilmente introduzir problemas na orientação das bordas (Frost et al., 1982).

Exemplos de algoritmos de segmentação de imagens SAR que empregam esta técnica podem ser encontrados em (White, 1986), (Frost et al., 1982), (Don e Fu, 1985), (Rosenfeld e Thurston, 1971), (Rosenfeld et al., 1972) e (Touzi et al., 1988).

Como pode ser observado, não existem técnicas plenamente satisfatórias para a segmentação de imagens SAR. Esta deficiência é consequência direta do ruído multiplicativo. O processo de segmentação destas imagens a partir das técnicas apresentadas exige que áreas com grande quantidade de pixels sejam amostradas para se obter médias de retroespalhamento mais precisas, acarretando perda de resolução, de desempenho ou excessivo custo computacional.

CAPÍTULO 5

DESCRIÇÃO DOS ALGORITMOS DE SEGMENTAÇÃO DE IMAGENS SAR MUM E RWSEG

Os algoritmos MUM (Cook et al., 1994) e RWSEG (White, 1986) utilizados neste trabalho estão implementados no *software* CAESAR versão 2.1 (NASoftware, 1994). Este *software* contém um conjunto de ferramentas desenvolvidas para auxiliar no processo de interpretação de imagens de radar de abertura sintética. Além dos algoritmos de segmentação, estão disponíveis também algoritmos para redução do ruído *speckle*, detecção de bordas, detecção de objetos pontuais e algumas ferramentas para obtenção de estatísticas e compressão de imagens SAR. Para rodar o CAESAR versão 2.1 é necessário uma *workstation* com sistema operacional *Solaris* 1.x ou 2.x.

Durante a execução deste trabalho foi disponibilizada a versão 3.1, a qual permite executar o software também a partir de PC com sistema operacional Windows 95/98. Esta nova versão também incluiu algumas modificações nos algoritmos de segmentação MUM e RWSEG. Entretanto, esta nova versão não foi utilizada neste trabalho uma vez que os dados necessários já haviam sido gerados na versão anterior.

Os dois algoritmos de segmentação foram desenvolvidos especificamente para dados SAR e produzem segmentações baseadas nos valores de intensidade dos *pixels* e representadas através do modelo *cartoon*, isto é, a imagem é decomposta em uma coleção de regiões nas quais a intensidade é constante (representada pela média dos valores de intensidade dos *pixels* que formam a região). Além disto, eles se baseiam na modelagem dos dados como sendo provindos do modelo multiplicativo e na consideração de que não existe correlação espacial entre os valores radiométricos dos *pixels*.

No tocante à modelagem dos dados em amplitude, é suposto que o ruído *speckle* possui uma distribuição $\Gamma^{\frac{1}{2}}(n,n)$, onde n é o número equivalente de *looks*, enquanto que o retroespalhamento possui uma distribuição Constante. Dentro do contexto do modelo

multiplicativo, as suposições indicam que os dois algoritmos são aplicáveis somente para imagens com regiões homogêneas, uma vez que a modelagem do retroespalhamento das regiões heterogêneas e extremamente heterogêneas parte da hipótese básica que as mesmas possuem distribuições Raiz de Gama e recíproca da Raiz de Gama, respectivamente.

O dado de saída destes algoritmos pode ser apresentado através de um mapa de médias (*cartoon*) ou através de um mapa binário de bordas. A Figura 5.1 apresenta um exemplo da representação destes dois tipos de mapas.

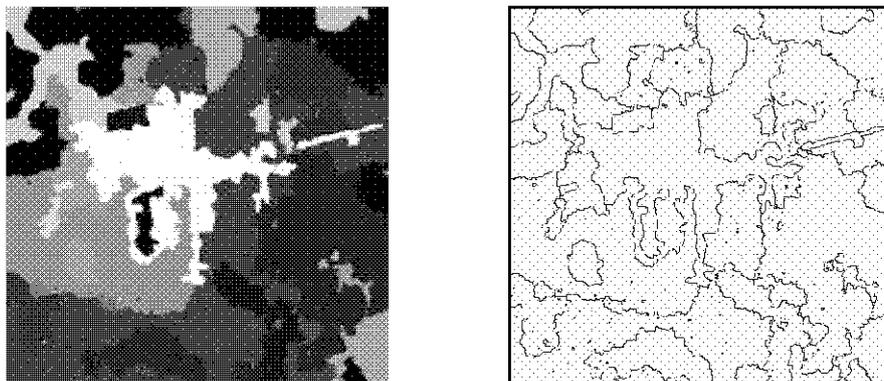


Fig. 5.1 - Representação da saída dos algoritmos através do mapa de médias (esquerda) e do mapa de bordas (direita).

Cabe salientar que o mapa de bordas é o resultado mais próximo da definição da segmentação de uma imagem. O mapa de médias inclui uma informação adicional, no caso o nível de cinza médio de cada segmento.

5.1 - ALGORITMO MUM

O algoritmo MUM (Merge Using Moments) segmenta uma imagem empregando uma técnica de segmentação baseada no crescimento de regiões. Num primeiro estágio a imagem de entrada é inicialmente subdividida em um grande número de regiões (cada

pixel pode, em princípio, ser tratado como um segmento). O refinamento dessa segmentação inicial é feito agrupando (*merging*) pares de regiões adjacentes similares. A similaridade é verificada a partir do exame de propriedades estatísticas (momentos) dos dados contidos nas regiões. Este refinamento é controlado através de um limiar selecionado pelo usuário.

Existem três parâmetros que devem ser selecionados pelo usuário para poder executar o algoritmo (NASoftware, 1994): i , p e l . O parâmetro i permite especificar o formato das imagens de entrada (amplitude ou intensidade). O parâmetro l permite especificar o número de *looks* da imagem de entrada. Entretanto, o principal parâmetro de controle do algoritmo é o p , que seleciona o valor de corte (probabilidade) de agrupamento de regiões vizinhas. Este parâmetro controla o crescimento da região e pode ser escolhido dentro da faixa de valores inteiros compreendida entre 1 e 17. ($0 < p < 18$).

Para decidir se duas regiões adjacentes, A e B , serão agrupadas ou não, o algoritmo aplica um teste de hipótese às observações nelas contidas afim de verificar, a um certo nível de significância, se as duas regiões são amostras provenientes de um mesmo retroespalhamento (*backscatter*). Isto é feito através de um teste estatístico denominado *t*-Student, o qual permite determinar se dois valores médios são significativamente diferentes quando a média e o desvio padrão da distribuição dos dados são desconhecidos e quando é válida a hipótese de normalidade para estes dados.

Para tal, considere as regiões A e B , e sejam N_i , μ_i e σ_i , $i = (A,B)$, o número de *pixels*, a média e o desvio padrão amostrais dos valores de intensidade na região i , respectivamente. Sob a hipótese das médias e variâncias serem iguais, a variância conjunta dos dados das duas regiões pode ser calculada através da relação:

$$\sigma_{AB}^2 = \frac{N_A \sigma_A^2 + N_B \sigma_B^2}{N_A + N_B - 2} \left(\frac{1}{N_A} + \frac{1}{N_B} \right) \quad (1)$$

Seja a estatística t obtida através da relação:

$$t = \frac{|\mu_A - \mu_B|}{\sigma_{A,B}} \quad (2)$$

A significância deste valor é então verificada utilizando-se uma distribuição t -Student com $v = N_A + N_B - 2$ graus de liberdade contra a probabilidade p_o selecionada pelo usuário através do parâmetro p . Deste modo, seja a probabilidade de que uma variável aleatória P com distribuição t -Student e com v graus de liberdade seja maior que t . Então $1 - P(t|v)$ é o nível de significância no qual a hipótese de que as médias são iguais é rejeitada (Cook et al., 1994). Logo, a hipótese é rejeitada se:

$$1 - P(t|v) < p_o,$$

onde p_o é a probabilidade selecionada pelo usuário através do parâmetro p , sendo que $p_o = 10^{-p}$.

Durante o processo de segmentação, o algoritmo calcula os valores das equações (1) e (2) para cada par de regiões vizinhas, agrupando aquelas nos quais o valor de $1 - P(t|v)$ excede o valor de 10^{-p} . Este processo é repetido até que não haja mais pares de regiões vizinhas possíveis de serem agrupadas, quando então a segmentação está terminada.

É importante notar que a decisão de unir duas regiões ou parar a segmentação depende somente das duas regiões consideradas na comparação. O MUM usa informação local para agrupar as regiões, não havendo nenhum parâmetro global para o agrupamento. Deste modo, a segmentação produzida pelo MUM é capaz de conservar detalhes de alvos pequenos e pontuais, bem como crescer e formar regiões extensas.

Todas as propriedades (tamanho, média e desvio padrão) necessárias de uma nova região formada podem ser deduzidas das regiões que foram agrupadas para criá-la. Assim, não é necessário recalculá-las para a nova região a cada estágio de agrupamento (Cook et al., 1994). Cada região pode ser caracterizada através de sua relação com outras regiões, sua forma, seu tamanho, sua média e seu desvio padrão.

A relação com outras regiões descreve a estrutura topológica da segmentação, isto é, a relação de adjacência entre as regiões. O algoritmo não faz uso da informação da forma da região, armazenando-a apenas como uma lista de *pixels* ligados. O tamanho, média e desvio padrão das observações contidas na região são calculados da maneira usual:

$$\text{Tamanho} = N .$$

$$\text{Média} = \frac{1}{N} \sum_{i=1}^N x_i .$$

$$\text{Variância} = \frac{1}{N-1} \left[\sum_{i=1}^N x_i^2 - \frac{1}{N} \left(\sum_{i=1}^N x_i \right)^2 \right] .$$

Isto significa que após o agrupamento das regiões é necessário somente atualizar a topologia da nova região formada. A geometria da nova região é derivada da união das duas listas de *pixels* e sua estatística pode ser calculada diretamente através das seguintes relações:

$$N_{AB} = N_A + N_B .$$

$$\sum x_{AB} = \sum x_A + \sum x_B .$$

$$\sum x_{AB}^2 = \sum x_A^2 + \sum x_B^2 .$$

Desta forma, o custo computacional do agrupamento é relativamente pequeno.

5.2 - O ALGORITMO RWSEG

O RWSEG segmenta uma imagem basicamente em duas etapas: a primeira e principal consiste em um processo iterativo envolvendo estágios de detecção de bordas e crescimento de regiões e a segunda consiste em um estágio de agrupamento de regiões. Durante o processo iterativo de detecção de bordas e crescimento de regiões, as bordas detectadas são empregadas para limitar o crescimento de regiões, resultando em uma

segmentação intermediária que é então usada, num próximo estágio, para gerar uma detecção de bordas mais precisa e assim melhorar a segmentação. Após cada iteração, o contraste médio dos segmentos obtidos é medido e a iteração continua enquanto o valor do contraste médio diminui. Na etapa final verifica-se se os segmentos adjacentes são estatisticamente distintos e, agrupa-se aqueles que não são.

Os parâmetros que devem ser seleccionados pelo usuário para executar o algoritmo são: i , e e j (NASoftware, 1994). O parâmetro i permite especificar o formato do dado de entrada (amplitude ou intensidade). O parâmetro e permite especificar a probabilidade para detecção de bordas, a qual está relacionada à probabilidade de falso alarme, ou seja, detectar uma borda inexistente (valor padrão é 2,33, que corresponde a uma probabilidade de falso alarme de aproximadamente 0,02). O parâmetro j permite especificar a probabilidade de agrupamento de regiões (valor padrão é zero).

A detecção de bordas é a ferramenta fundamental deste algoritmo. As bordas são detectadas através de operadores gradientes usando janelas de diferentes tamanhos e com limiares adaptados para o tamanho da janela e o desvio padrão local. O detetor de bordas implementado nesta versão do algoritmo possui quatro características principais:

- capacidade de operar a partir de uma segmentação prévia;
- possibilidade de gerar uma razão de falso alarme constante;
- possibilidade de seleção de uma dada probabilidade de falso alarme desejada;
- possibilidade de detectar bordas de baixo e alto contraste.

A capacidade de operar a partir de uma segmentação prévia se justifica porque no estágio de detecção de bordas e crescimento de regiões é gerada uma segmentação provisória, a qual pode ser usada como dado de entrada para uma nova iteração deste primeiro estágio ou para o segundo estágio do algoritmo.

Alvos pontuais podem facilmente influenciar as estimativas de médias locais, causando a detecção de bordas falsas. Um alvo pontual formado por um único *pixel* pode gerar uma assinatura de borda igual ao tamanho da janela de detecção, levando a incorreções na representação do alvo e obscurecendo detalhes estruturais da vizinhança próxima. Desta forma, a detecção de alvos pontuais antes da detecção de bordas é de grande interesse. Para que um alvo pontual seja detectado na presença do *speckle*, ele precisa ser significativamente mais brilhante que seus vizinhos imediatos. Uma abordagem usada neste processo é a detecção de alvos pontuais com razão constante de falso alarme, CFAR, descrita em (Caves, 1993) e relacionada com o uso de razões de intensidade para detecção de bordas apresentadas em (Touzi et al., 1988).

Segundo (Caves, 1993), a probabilidade que um pixel com intensidade I_0 seja r vezes mais intenso que todos seus oito vizinhos com intensidade I_1, \dots, I_8 é dada por:

$$\Pr(r) = \text{prob}\left(\frac{I_0}{I_i} > r : i = 1, \dots, 8\right) = \int_0^\infty f_I(I) \left[p_I\left(\frac{I}{r}\right) \right]^8 dI,$$

onde $f_I(I)$ e $p_I(I)$ são, respectivamente, a função densidade de probabilidade e função de densidade acumulada da intensidade. Para r igual a um, esta probabilidade é equivalente à probabilidade que o pixel seja um máximo local e decresce rapidamente a medida que r aumenta.

Usando-se esta probabilidade, um limiar r_0 pode ser selecionado para dar uma dada (conhecida) probabilidade de que um pico de *speckle* seja r_0 vezes mais brilhante que todos os seus vizinhos. A razão de intensidade de todos os pares de *pixels* 8-conectados na imagem é calculada e normalizada para ser maior que um. *Pixels* vizinhos são definidos como conectados se suas razões normalizadas é menor que r . Os *pixels* que são vizinhos mas não conectados devem ter razão normalizada maior que o limiar definido. Se a probabilidade de falso alarme é baixa o suficiente (0,01 é geralmente suficiente), a maioria da imagem é detectada como uma principal região conectada e as demais como

regiões diminutas. Aquelas que são mais brilhantes que a região principal são consideradas alvos pontuais.

Este método proporciona a detecção de alvos pontuais com razão constante de falso alarme, uma vez que a probabilidade que um *pixel* seja r vezes mais intenso que todos seus oito vizinhos depende mais das razões do que dos valores absolutos.

Em cada *pixel* da imagem, o dado de saída do operador gradiente sobre uma janela retangular centrada neste *pixel* pode ser obtido dividindo-se a janela em duas partes (A, B) iguais, cada uma contendo, a princípio, N *pixels*. Em seguida o valor médio e a variância de cada sub-janela são estimados a partir dos valores dos *pixels* contidos em cada uma. O resultado de saída desta versão do gradiente tem média amostral dada por $\mu_g = \mu_a - \mu_b$ e desvio padrão amostral dado por:

$$\sigma_g = \sqrt{\frac{\sigma_a^2 + \sigma_b^2}{N}},$$

onde μ_A, σ_A^2 são a média e a variância da sub-janela A , e μ_B, σ_B^2 são os correspondentes à outra.

A fim de produzir uma razão de falso alarme constante sobre regiões homogêneas, a média amostral obtida pelo operador gradiente precisa ser normalizada pelo seu desvio padrão amostral. Da equação acima, isto requer uma estimativa da variância em cada sub-janela, a qual pode ser calculada a partir de uma segmentação prévia, tomando-se o valor da variância média dos segmentos sobrepostos pelas sub-janelas ponderado pela proporção da sub-janela ocupada por cada segmento. Para ilustrar o processo de estimação da variância em cada sub-janela, considere a Figura 5.2.

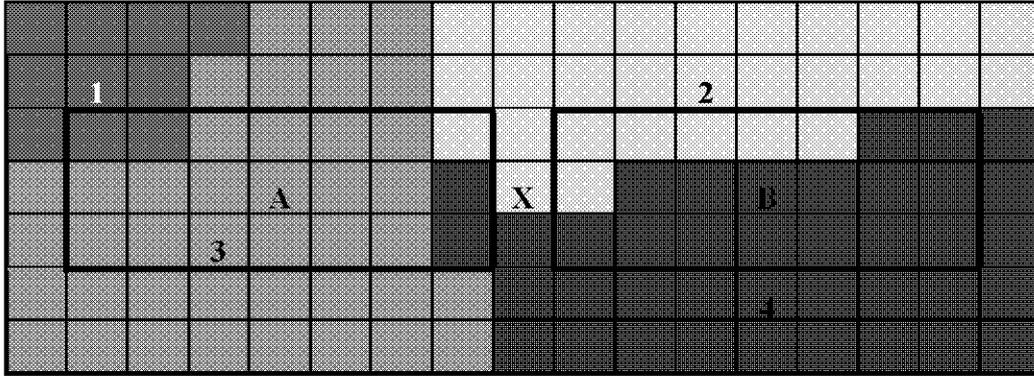


Fig. 5.2 - Ilustração do cálculo da variância em cada sub-janela.

Na Figura 5.2 estão representadas quatro regiões detectadas numa segmentação obtida de uma iteração prévia. Estas regiões estão rotuladas 1, 2, 3, e 4, e suas respectivas variâncias amostrais são denotadas por σ_1^2 , σ_2^2 , σ_3^2 , e σ_4^2 . O operador gradiente empregando uma janela retangular de dimensão 3×15 é aplicado sobre o *pixel* assinalado com X. A variância em cada uma das duas sub-janelas de dimensão 3×7 , A e B, é dada respectivamente por:

$$\sigma_A^2 = \frac{2\sigma_1^2 + 1\sigma_2^2 + 16\sigma_3^2 + 2\sigma_4^2}{21} \text{ e } \sigma_B^2 = \frac{6\sigma_2^2 + 15\sigma_4^2}{21}.$$

Deste modo, tanto a imagem de entrada quanto a segmentação obtida em uma iteração prévia são empregadas em cada iteração. Na primeira iteração, como não existe ainda uma segmentação prévia, a imagem inteira é considerada como um segmento único.

O valor de saída do operador gradiente no referido *pixel*, denominado gradiente normalizado e denotado por G_N , é dado por:

$$G_N = \frac{\mu_g}{\sigma_g} = \frac{\mu_A - \mu_B}{\sqrt{\frac{\sigma_A^2 + \sigma_B^2}{N}}}.$$

Para janelas muito grandes, o teorema central do limite indica que as ocorrências de falsos alarmes, isto é, detecção de bordas inexistentes, terão distribuição Gaussiana com média zero e desvio padrão unitário. Um limiar pode então ser selecionado para garantir uma certa probabilidade de falso alarme p_e . O mesmo limiar pode ser aplicado para janelas menores, porém a suposição da distribuição Gaussiana será menos válida.

Segundo (White, 1986), simulações com imagens processadas com 5 *looks* mostraram que o gradiente normalizado calculado usando-se janelas de 3×3 até 16×16 possui distribuição Gaussiana. Um limiar L para o valor absoluto do gradiente normalizado aplicável para operadores gradientes com sub-janelas de N *pixels* pode ser da forma $L = k\sqrt{N}$, onde k é um número de desvios padrões tomados da distribuição das ocorrências de falsos alarmes e que representa uma dada probabilidade de falso alarme.

Para determinar se um *pixel* é uma borda, o algoritmo calcula a probabilidade das duas áreas de cada lado deste *pixel* terem médias diferentes. Um *pixel* é definido como sendo uma borda se:

$$\frac{|\mu_A - \mu_B|}{\sqrt{\sigma_A^2 + \sigma_B^2}} \geq e,$$

onde μ_A , σ_A^2 são a média e a variância da área subtendida pela sub-janela A , e μ_B , σ_B^2 são as correspondentes à outra e e é o valor do limiar L (expresso como um número de desvios padrões) selecionado pelo usuário através do parâmetro e , supondo que os valores médios tem distribuição Gaussiana.

Para detectar bordas de diferentes intensidades, o algoritmo utiliza sete janelas retangulares de tamanhos 3×3 , 3×7 , 3×15 , 5×19 , 7×27 , 9×45 e 13×57 *pixels*, aplicadas em ordem crescente de tamanho, com intenção de detectar primeiramente bordas de alto contraste e em seguida as de baixo contraste. Inicialmente um operador gradiente de Sobel usando uma janela de 3×3 é aplicado sobre a imagem para gerar um mapa de bordas consistindo de zeros (*background*) e uns (bordas). Se a quantidade de

uns é baixa, a máscara de 3×7 é então aplicada. Assim, mais bordas (uns) são geradas e juntadas às demais. As máscaras subsequentes são então aplicadas.

Os diferentes tamanhos de janela também visam contornar o efeito do *speckle* em operações com janelas pequenas, as quais tendem a encontrar um grande número de bordas falsas. Para detectar bordas em diferentes orientações, as janelas são aplicadas vertical e horizontalmente usando janelas longas e estreitas que excluem a necessidade de aplicação na orientação diagonal (White,1986).

Usando o mapa de bordas obtido no estágio de detecção de bordas numa dada iteração, as regiões são encontradas no estágio de crescimento de regiões ajustando-se discos de diferentes diâmetros dentro das áreas onde nenhuma borda foi detectada. Discos de diâmetros 64, 32, 16, 8, 4, 2 e 1 *pixels* são ajustados em ordem decrescente de tamanho. Os discos que apresentam sobreposição são agrupados para formar uma única região se suas médias forem consideradas iguais (NASoftware, 1994).

Cada estágio do crescimento das regiões é seguido pelo cálculo do contraste médio dado por:

$$\text{Contraste médio} = \sum_{k=1}^m \frac{n_k}{n} [C_v(k)]^2,$$

onde $C_v(k)$ é o coeficiente de variação dentro da região k , n_k é número de *pixels* da região k , n é o número de *pixels* da imagem e m é o número total de regiões.

O contraste médio tende a decrescer para um valor limite na medida em que a segmentação melhora. O processo iterativo termina quando há um aumento no valor do contraste médio de uma iteração para outra, sendo que a segmentação prévia será o resultado final.

A segmentação resultante dos estágios de detecção de bordas e crescimento de regiões pode conter muitas regiões pequenas como, por exemplo, um campo dividido em muitas partes. Na etapa final realizada pelo algoritmo, que consiste em um estágio de

agrupamento de regiões, é verificado se regiões adjacentes representam feições estatisticamente distintas. Para realizar esta tarefa, a probabilidade p_{AB} de cada par de regiões adjacentes A e B terem a mesma intensidade média é calculada. Isto equivale a encontrar a probabilidade de suas bordas de separação serem originadas simplesmente do *speckle*. Pares de regiões para os quais p_{AB} excede a probabilidade de falso alarme usada na detecção de bordas, p_e , são consideradas como sendo estatisticamente iguais e então agrupadas.

Conforme descrito em (NASoftware, 1994), este estágio consiste em remover bordas definidas como de baixa intensidade entre regiões adjacentes. A intensidade de uma borda é medida comparando-se as regiões de cada lado da borda. Uma borda de baixa intensidade é removida se:

$$\frac{|\mu_A - \mu_B|}{\sqrt{\sigma_A^2 + \sigma_B^2}} \leq j,$$

onde μ_A , σ_A^2 são a média e a variância da região A , e μ_B , σ_B^2 são as correspondentes à outra e j é o valor do limiar de agrupamento de regiões (expresso como um número de desvios padrões) selecionado pelo usuário através do parâmetro j .

Entretanto, a simples remoção de todas as bordas para as quais a probabilidade p_{jk} é maior que a probabilidade de falso alarme não leva a bons resultados e esta remoção de bordas é feita dinamicamente. As probabilidades de cada borda da imagem terem se originado puramente do *speckle* são ordenadas da mais para a menos provável. Se a probabilidade da primeira borda nesta lista exceder a probabilidade de falso alarme, a borda é removida. Esta remoção modifica algumas das probabilidades das bordas e leva então a um novo ordenamento. Desta forma, as bordas são removidas com reordenamento a cada passo, até que a primeira borda da lista não exceda o limiar.

O processo continua até que a intensidade de todas as bordas presentes na segmentação excedam o valor do limiar de agrupamento. No caso deste limiar ser definido como igual a zero, nenhum agrupamento é feito.

O custo computacional aumenta aproximadamente com o quadrado do número de *pixels* da imagem de entrada.

CAPÍTULO 6

MEDIDAS DE QUALIDADE DE UMA SEGMENTAÇÃO

O que é uma boa segmentação de uma imagem? Segundo Haralick e Shapiro (1984), regiões de uma segmentação devem ser uniformes e homogêneas com respeito a alguma característica (níveis de cinza, por exemplo). O interior das regiões deve ser simples e sem muitos segmentos pequenos. Regiões adjacentes precisam ter valores significativamente distintos em relação à característica nos quais eles são uniformes. As bordas das regiões precisam ser simples, não rugosas e espacialmente corretas.

Como medir a qualidade de uma segmentação? Basicamente esta tarefa pode ser feita a partir de avaliação qualitativa e quantitativa. A primeira é baseada na inspeção visual e permite verificar questões relativas ao número de segmentos gerados, preservação de pontos isolados e feições lineares, regularidade das bordas entre regiões, etc. A segunda é feita a partir de grandezas quantitativas. Grandezas quantitativas de uma segmentação são todas aquelas que permitem quantificar em valores numéricos características a seu respeito, tais como número de segmentos, intensidade média das radiometrias dos segmentos, tamanho dos segmentos em *pixels*, número de classes (tipos de alvos) distintas, tempo de processamento, etc.

Quando a característica a ser mensurada diz respeito à qualidade da segmentação, algumas medidas de qualidade devem ser definidas, muitas vezes baseadas na intuição humana acerca das condições que devem ser satisfeitas para uma segmentação ideal (Zhang, 1996).

O objetivo deste capítulo é descrever o processo empregado neste trabalho para avaliar quantitativamente as segmentações produzidas pelos algoritmos MUM e RWSEG. Para tanto, serão definidos alguns métodos de avaliação de algoritmos descritos na literatura, alguns aspectos da modelagem matemática de uma imagem e de uma segmentação e por fim as medidas quantitativas empregadas para propósitos de avaliação da qualidade das segmentações produzidas pelos algoritmos.

6.1 - MÉTODOS DE AVALIAÇÃO DE ALGORITMOS DE SEGMENTAÇÃO

Alguns métodos têm sido propostos para avaliar e comparar o desempenho de algoritmos de segmentação de imagens SAR, dentre os quais podemos destacar os apresentados em (Quegan et al., 1988; Delves et al., 1992; Zhang 1996; Caves et al., 1996). Esses métodos podem ser divididos em duas categorias: analíticos e empíricos.

Os métodos analíticos permitem examinar e avaliar diretamente os algoritmos através da análise de seus princípios, suposições, propriedades, exigências, utilidade, complexidade, etc. Produzem resultados que independem de experimentos e podem ainda ser aplicados sem que o algoritmo esteja completamente implementado (Zhang, 1996). Além do mais, a aplicação destes métodos é independente da natureza ou objetivo da segmentação.

Algumas propriedades dos algoritmos de segmentação que podem ser obtidas através deste método incluem a estratégia, a complexidade e a eficiência do processamento. Desta forma, tal método acaba sendo de grande utilidade na seleção de um algoritmo para uma aplicação particular. É sempre desejável dispor de uma avaliação analítica dos algoritmos empregados, mas isto nem sempre é possível.

Os métodos empíricos permitem examinar e avaliar um algoritmo de forma indireta, através da aplicação de imagens testes e medição da qualidade do resultado da segmentação (Zhang, 1996). Podem ser divididos em dois tipos: de discrepância e de qualidade.

Os métodos empíricos de qualidade permitem examinar e avaliar o desempenho de algoritmos julgando simplesmente a qualidade da segmentação final obtida, sem nenhum conhecimento a priori da segmentação verdadeira (referência). Algumas medidas de qualidade que têm sido propostas incluem as de uniformidade interna das regiões, contraste entre regiões e forma das regiões.

Os métodos empíricos de discrepância permitem examinar e avaliar o desempenho de um algoritmo através da comparação da segmentação de uma imagem produzida pelo mesmo com uma segmentação de referência, sendo que ambas as segmentações são

obtidas a partir do mesmo dado de entrada. No caso em que o dado de entrada é uma imagem real, a segmentação de referência é geralmente obtida através de uma segmentação manual da imagem de entrada baseada na interpretação visual. No caso de imagens sintéticas, a segmentação de referência é obtida diretamente do seu processo de geração.

Os métodos deste grupo levam em conta as diferenças (medidas através de vários parâmetros de discrepância) entre a segmentação obtida pelo algoritmo e a segmentação de referência. Valores elevados de discrepância são devidos a grandes erros da segmentação, que evidenciam um desempenho deficiente do algoritmo. Algumas medidas de discrepância incluem a posição, tamanho, forma e intensidade média dos segmentos gerados.

Para a aplicação efetiva dos métodos empíricos, o conhecimento do objetivo da segmentação é um aspecto relevante. Isto porque nos métodos empíricos de qualidade, a definição das medidas de qualidades desejáveis da segmentação impõe o conhecimento acerca do resultado esperado. Por outro lado, nos de discrepância, a exigência da construção da segmentação de referência implica uma dependência ainda maior do conhecimento deste objetivo, uma vez que o mesmo baliza o resultado da segmentação manual.

Neste trabalho, os algoritmos de segmentação serão avaliados e comparados quantitativamente a partir de método empírico de discrepância. Esta escolha se justifica pelo fato do mesmo permitir a avaliação de algoritmos distintos (uma vez que somente as imagens a serem segmentadas e as segmentações produzidas são necessárias, não importando o tipo de algoritmo) e pela sua capacidade de ser aplicável para estudos de diferentes propriedades da segmentação.

As medidas de discrepância que serão utilizadas para avaliação da qualidade das segmentações obtidas pelo MUM e RWSEG são algumas das descritas em (Delves et al., 1992). Para descrevê-las, será apresentado a seguir uma definição teórica de uma imagem e de sua segmentação.

6.2 - ALGUNS ASPECTOS DA MODELAGEM MATEMÁTICA DE UMA IMAGEM E DE UMA SEGMENTAÇÃO

O termo imagem monocromática ou simplesmente imagem, refere-se a uma função bidimensional $f(x,y)$, onde x e y representam coordenadas espaciais e o valor de f em qualquer ponto (x,y) representa o nível de cinza neste ponto. Uma imagem digital é uma imagem $f(x,y)$ que foi discretizada tanto em coordenadas espaciais quanto em níveis de cinza (Gonzales e Wintz, 1987). Uma imagem digital pode ser considerada uma matriz bidimensional na qual os índices das linhas e colunas identificam um ponto na imagem e o correspondente valor do elemento da matriz identifica o nível de cinza ou cores no referido ponto. Os elementos desta matriz digital são denominados de *pixels* (*picture elements*).

Seja $S = \{1, \dots, l\} \times \{1, \dots, c\}$ o suporte de uma imagem de l linhas e c colunas. Uma imagem multiespectral é uma função $f: S \rightarrow \mathbb{R}^p$, onde p representa o número de bandas, definida sobre a grade suporte S . Quando p é igual a 1, temos uma imagem mono-espectral. Cada *pixel* desta imagem pode 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 referida coordenada. Desta forma 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 sub-região (r_i). Seja $P(r)$ um predicado lógico (propriedade) definido para um conjunto de pontos contínuos da imagem. A segmentação da imagem que tem por suporte a grade S pode ser definida (Zucker, 1976; Schoenmakers et al., 1991; Gonzales e Wintz, 1987) como uma partição de S em um conjunto não vazio de k sub-regiões (segmentos) tais que:

$$(a) \bigcup_{i=1}^k r_i = S,$$

- (b) r_i é uma região conectada, $i = 1, \dots, k$,
- (c) $r_i \cap r_j = \emptyset$ para todo i e j , $i \neq j$,
- (d) $P(r_i) = \text{VERDADEIRO}$ para $i = 1, \dots, k$ e
- (e) $P(r_i \cup r_j) = \text{FALSO}$ para $i \neq j$, com r_i, r_j adjacentes.

A condição (a) indica que a segmentação precisa ser completa, isto é, cada *pixel* precisa estar contido em uma região. A condição (b) indica que os *pixels* em uma região devem estar conectados. A conectividade entre *pixels* é um conceito importante no estabelecimento de bordas de objetos e componentes de regiões em uma imagem. Para se determinar se dois *pixels* p e q são conectados é preciso determinar se eles são adjacentes em algum sentido e se seus níveis de cinza satisfazem um certo critério de similaridade.

Um *pixel* p com coordenadas (x, y) tem quatro vizinhos, sendo dois horizontais $(x+1, y)$, $(x-1, y)$ e dois verticais $(x, y+1)$, $(x, y-1)$. Este conjunto de *pixels*, chamado de 4-*vizinhança* de p , é denotado por $N_4(p)$. Os quatro vizinhos diagonais de p tem coordenadas $(x+1, y+1)$, $(x+1, y-1)$, $(x-1, y+1)$ e $(x-1, y-1)$ e são denotados $N_D(p)$. O conjunto de *pixels* resultante da união dos subconjuntos $N_D(p)$ e $N_4(p)$ é denominado de 8-*vizinhança* de p e denotado por $N_8(p)$. Seja V o conjunto de valores de níveis de cinza usados para definir conectividade. Consideram-se 3 casos (Gonzales e Wintz, 1987):

- (1) 4-*conectados*. Dois *pixels* p e q com valores de V são 4-*conectados* se q pertence ao conjunto $N_4(p)$.
- (2) 8-*conectados*. Dois *pixels* p e q com valores de V são 8-*conectados* se q pertence ao conjunto $N_8(p)$.
- (3) m-*conectados*. Dois *pixels* p e q com valores de V são m-*conectados* se q pertence ao

conjunto $N_4(p)$ ou q pertence ao conjunto $N_D(p)$ e o conjunto $N_4(p) \cap N_4(q)$ é vazio. Dois pixels p e q são adjacentes se eles são conectados.

A condição (c) implica que as regiões devem ser disjuntas. A condição (d) determina a propriedade que deve ser satisfeita pelos *pixels* em uma determinada subregião e, finalmente, a condição (e) indica que as subregiões adjacentes r_i e r_j são distintas em relação à propriedade definida.

Para expressar grandezas de uma subregião r_i de uma segmentação g , tais como número de *pixels*, posição (em coordenadas) dos *pixels* constituintes e intensidade média de seus valores radiométricos, 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 $g^{-1}(r_i)$. Este conjunto contém todas as coordenadas dos *pixels* que constituem esta subregião e fornece diretamente o tamanho em *pixels* da mesma, denotado por $\#g^{-1}(r_i)$, viabilizando o cálculo do centro geomérico e da intensidade média das radiometrias.

O centro geomérico de uma subregião r_i da segmentação g de uma imagem f é dado por:

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

A média das radiometrias ou intensidade média, denotada por $\langle r_i \rangle$, associada a uma dada subregião r_i da segmentação g de uma imagem f é dada por:

$$\langle r_i \rangle = \frac{1}{\#g^{-1}(r_i)} \sum_{s \in g^{-1}(r_i)} f(s).$$

6.3 - MEDIDAS DE QUALIDADE

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 $f : S \rightarrow \mathcal{R}$, com a mesma dimensão de l linhas por c colunas. Suponha g_1 como a segmentação verdadeira de f e empregada como segmentação de referência e g_2 a segmentação de f produzida por um algoritmo de segmentação. Denota-se uma subregião nas segmentações g_1 e g_2 por r e m , respectivamente, e considera-se que k e q são o número de subregiões de g_1 e g_2 , respectivamente. Segundo descrito em (Delves et al., 1992), um primeiro passo no processo de avaliação da qualidade da segmentação obtida pelo algoritmo é comparar suas regiões $\{m_1, m_2, \dots, m_q\}$ com aquelas presentes na segmentação de referência $\{r_1, r_2, \dots, r_k\}$, isto é, comparar pares de elementos (r_i, m_j) .

Este processo de comparação baseia-se no ajuste de regiões (segmentos) das duas segmentações em questão. O ajuste entre regiões de duas segmentações é obtido através da sobreposição das mesmas. Para cada região $\{r_1, r_2, \dots, r_k\}$ de g_1 será escolhida dentre todas as regiões $\{m_1, m_2, \dots, m_q\}$ de g_2 , uma que melhor a represente. Essa região será denominada região ajustada. Muito provavelmente, a segmentação produzida por um algoritmo conterà um número diferente (geralmente maior) de regiões que aquelas presentes na segmentação de referência. Entretanto, o melhor ajuste entre uma região de g_1 e qualquer outra de g_2 pode ser medido através de critérios de posicionamento no plano XY, número de *pixels*, intensidade média e da forma das regiões ajustadas.

Para definir os pares de regiões ajustadas, parte-se da sobreposição das duas segmentações e obtém-se duas matrizes de tamanho kq , denotadas Gf e Fit , as quais são construídas respectivamente com componentes:

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

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

onde:

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

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

$$pd(r_i, m_j) = \frac{\left[\# g_1^{-1}(r_i) - \# g_2^{-1}(m_j) \right]}{\# g_1^{-1}(r_i) + \# g_2^{-1}(m_j)} e$$

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

com $i = 1, \dots, k$ e $j = 1, \dots, q$. As notações $(\bar{g}_\alpha^{-1}(u))_x$, $(\bar{g}_\alpha^{-1}(u))_y$, $\alpha = (1, 2)$, representam, respectivamente, a média das abscissas e a média das ordenadas da subregião u (centro geométrico), enquanto que $\# g_\alpha^{-1}(u)$, $\langle u \rangle$, representam, respectivamente, o número de *pixels* e a intensidade média dos valores radiométricos na região u .

Cada elemento de uma linha da matriz Gf representa a comparação de um par de subregiões (r_i, m_j) , onde r_i representa uma dada subregião da segmentação referência que é comparada com todas as q subregiões m_j da segmentação produzida pelo

algoritmo. Os valores dos elementos da matriz Gf indicam se há ou não sobreposição entre os pares de regiões (r_i, m_j) formados, e para aqueles no qual existe sobreposição, fornece uma medida quantitativa da relação entre o número de *pixels* da intercessão e o número total de *pixels* dessas regiões. Se o resultado for igual a 1 tem-se um ajuste perfeito, indicando que as duas regiões são iguais. O resultado igual a zero indica que a interseção das duas regiões não apresenta *pixels* comuns, isto é, são disjuntas.

Cada elemento da matriz Fit representa, a exemplo da matriz Gf , a comparação de um par de subregiões (r_i, m_j) . Entretanto, o cômputo dos valores dos elementos envolve medidas de posicionamento no plano XY (xd e yd), intensidade média (id) e tamanho (pd) das regiões comparadas.

A parcela xd mede a diferença dos valores das abcissas dos centros geométricos de duas regiões consideradas, ponderada pelo valor da dimensão da imagem no eixo das abcissas. O mesmo ocorre com a parcela yd , ressaltando que aqui a diferença é tomada e ponderada em relação ao eixo das ordenadas. Estas parcelas são um critério de ajuste do tipo posicional obtido em função do posicionamento dos segmentos das duas segmentações em relação ao plano XY que lhe dão suporte e reflete o erro de posicionamento entre os centros geométricos das regiões comparadas.

A parcela pd estabelece uma relação entre os números de *pixels* das regiões comparadas expressando uma idéia do tamanho relativo entre estas regiões, enquanto que a parcela id expressa a diferença relativa entre as intensidades médias das regiões amostradas. Essas parcelas são uma medida do erro de tamanho e intensidade média entre as regiões comparadas.

Os valores em cada uma das linhas da matriz Fit representam uma medida do sucesso de ajuste entre os pares de subregiões (r_i, m_j) formados levando em consideração o tamanho, forma, posição e intensidade destas subregiões. Para cada subregião r_i na

segmentação referência, a sua subregião ajustada correspondente m_j é definida como aquela que possuir o mínimo valor de $Fit(r_i, m_j)$.

Definida a região ajustada para cada região da imagem referência, passa-se a fase de avaliação da qualidade deste ajuste através de medidas de qualidade destes ajustes, as quais permitem avaliar a segmentação como um todo a partir da qualidade individual do ajuste de cada região isoladamente. As quatro medidas de qualidade utilizadas neste trabalho, descritas em (Delves et al., 1992), são:

◆ AJUSTE DE POSIÇÃO (Fit_{xy})

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

◆ AJUSTE DE INTENSIDADE (Fit_i)

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

◆ AJUSTE DE TAMANHO (Fit_n)

$$Fit_n(r_i, m_j) = 1 - \frac{[\# g_1^{-1}(r_i) - \# g_2^{-1}(m_j)]}{\# g_1^{-1}(r_i) + \# g_2^{-1}(m_j)}.$$

◆ AJUSTE DA FORMA (Gf_{forma})

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

Cabe notar que todas as medidas descritas acima estão padronizadas no intervalo $[0,1]$, onde o valor 1 representa o melhor ajuste.

Desta forma, para cada par de regiões, uma da segmentação de referência e a outra sua correspondente região ajustada, teremos um valor de *Fitxy*, *Fiti*, *Fitn* e *Gforma*. Para as k subregiões r_i da segmentação de referência teremos um conjunto de k valores para cada medida. A segmentação testada pode ser expressa em termos das médias de cada uma das medidas *Fitxy*, *Fiti*, *Fitn* e *Gforma* tomada dos valores obtidos nas k regiões. Para quantificar uma segmentação a partir de um único valor toma-se a média dos valores destas medidas, a qual é denominada média geral.

Uma vez que a segmentação foi quantificada, é possível compará-la com outra segmentação produzida por um outro algoritmo e desta forma comparar os algoritmos entre si a partir de seus resultados.

A título de ilustração do processo de obtenção das medidas quantitativas sobre uma segmentação a partir da metodologia descrita acima, considere duas segmentações g_1 e g_2 de uma mesma imagem f . Suponha g_1 (Figura 6.1) como a segmentação verdadeira de f , empregada como segmentação de referência, e g_2 (Figura 6.2) a segmentação de f produzida por um algoritmo de segmentação. A imagem f contém os valores radiométricos de intensidade que serão necessários para computar as intensidades médias das subregiões das segmentações. As duas segmentações são representadas por uma grade regular contendo 20 linhas e 20 colunas e possuem respectivamente 7 e 11 segmentos.

Os valores do número de *pixels*, intensidade média e as coordenadas dos centros geométricos em relação à origem dos eixos cartesianos das subregiões de cada segmentação estão listados nas Tabelas 6.1 e 6.2.

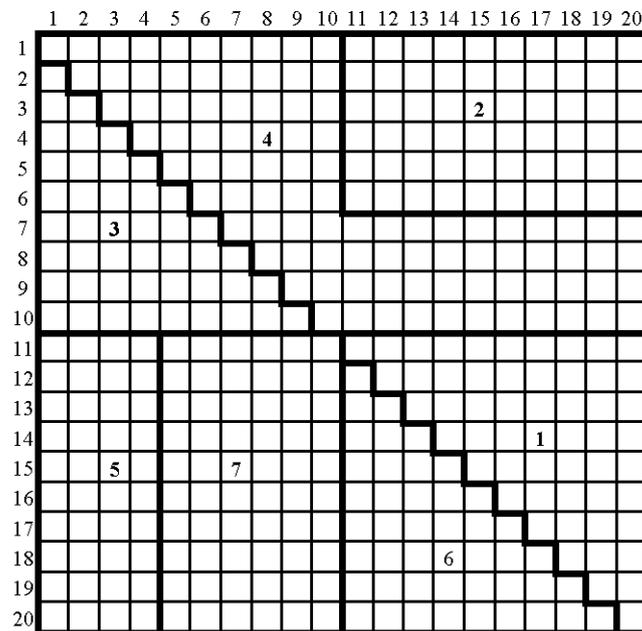


Fig. 6.1 - Representação da segmentação de referência g_1 e seus segmentos.

TABELA 6.1 - VALORES RELATIVOS À SEGMENTAÇÃO DE REFERÊNCIA

Subregião (i)	$\# g^{-1}(r_i)$	$\langle r_i \rangle$	$(\bar{g}_i^{-1}(r_i))_x$	$(\bar{g}_i^{-1}(r_i))_y$
1	55	90	17,0000	14,0000
2	60	30	15,5000	3,5000
3	45	40	3,6666	7,3333
4	95	90	10,5789	5,8947
5	40	60	2,5000	15,5000
6	45	50	13,6666	17,3333
7	60	20	7,5000	15,5000

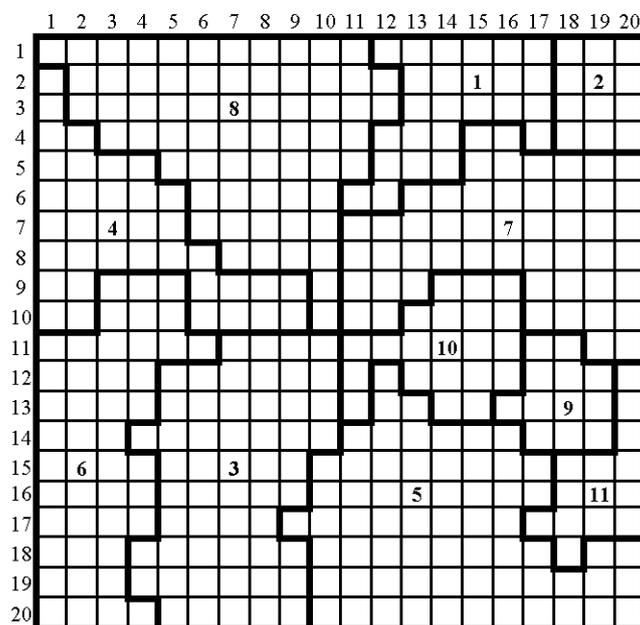


Fig. 6.2 - Representação da segmentação g_2 e seus segmentos.

TABELA 6.2 - VALORES RELATIVOS À SEGMENTAÇÃO

Subregião (j)	$\# g^{-1}(m_j)$	$\langle m_j \rangle$	$(\bar{g}_1^{-1}(m_j))_x$	$(\bar{g}_1^{-1}(m_j))_y$
1	25	30	14,2000	2,9600
2	12	30	19,0000	2,5000
3	54	22,22	7,0740	15,5000
4	36	41,10	3,6940	7,2220
5	65	56	14,0153	17,1538
6	45	55,55	2,7373	14,4000
7	51	58,23	16,1568	7,4700
8	65	72,15	7,2769	3,8923
9	12	90	17,7500	12,6666
10	21	79,52	13,9523	11,0476
11	14	90	19,0000	15,5714

Cabe salientar que os valores contidos nas Tabelas 6.1 e 6.2 podem ser obtidos antes mesmo do processo de ajuste entre as regiões das duas segmentações. Os valores de intensidade média de uma dada região dessas segmentações é calculado a partir dos valores de radiometria contidos na imagem f , sobrepondo-se esta região sobre a imagem e computando a média dos valores radiométricos dos *pixels* delimitados pela região sobreposta.

O primeiro passo para computar as medidas quantitativas de desempenho é construir a matriz Gf de dimensão 7×11 . Para construir a primeira linha completa $Gf(r_1, m_j)$, toma-se a subregião 1 de g_1 e a projeta sobre g_2 , computando-se então os valores de $Gf(r_1, m_j)$ para cada par (r_1, m_j) , ou seja, compara-se a subregião 1 de g_1 com as onze subregiões de g_2 . A Figura 6.3 ilustra o processo de ajuste da subregião 1 (sombreada) de g_1 com as subregiões de g_2 .

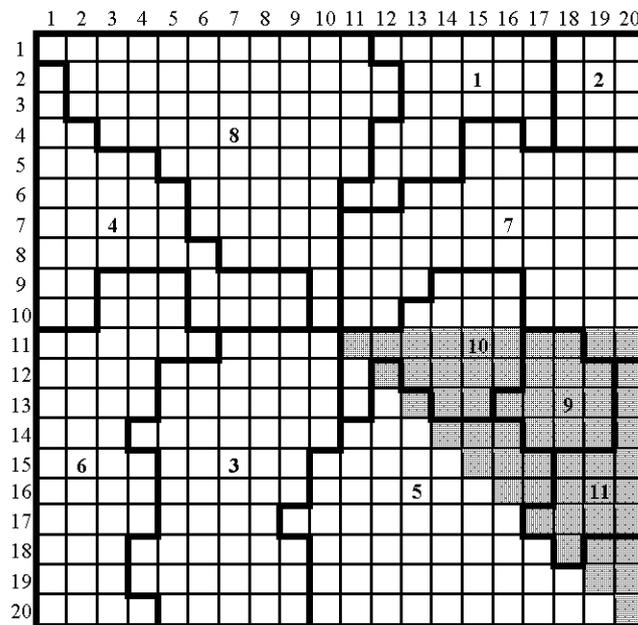


Fig. 6.3 - Projeção da subregião 1 (sombreada) de g_1 sobre g_2 .

Pode-se observar a partir da Figura 6.3 que somente as subregiões 5, 7, 9, 10 e 11 de g_2 apresentam *pixels* comuns com a região 1 de g_1 e, desta forma, são as candidatas para melhor ajuste. Repete-se o procedimento para todas as demais subregiões de g_1 , completando assim todas as linhas da matriz Gf . Para este exemplo a matriz obtida é apresentada abaixo.

$$Gf(r_i, m_j) = \begin{bmatrix} 0 & 0 & 0 & 0 & 0,1429 & 0 & 0,0192 & 0 & 0,2182 & 0,1875 & 0,2545 \\ 0,41 & 0,20 & 0 & 0 & 0 & 0 & 0,1684 & 0,0593 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0,7609 & 0 & 0,0714 & 0 & 0,0377 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0,0077 & 0 & 0 & 0,2920 & 0,5094 & 0 & 0,0642 & 0 \\ 0 & 0 & 0,03 & 0 & 0 & 0,7708 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0,6418 & 0 & 0 & 0 & 0 & 0,0312 & 0 \\ 0 & 0 & 0,80 & 0 & 0,0593 & 0,0194 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}$$

Obtidos os valores da matriz Gf passa-se então a construir a matriz Fit de mesma dimensão. O processo de obtenção desta matriz obedece o mesmo processo seguido para a obtenção da matriz Gf .

$$Fit(r_i, m_j) = \begin{bmatrix} \infty & \infty & \infty & \infty & 3,255 & \infty & 25,721 & \infty & 1,948 & 2,957 & 1,868 \\ 0,714 & 2,791 & \infty & \infty & \infty & \infty & 2,564 & 11,076 & \infty & \infty & \infty \\ \infty & \infty & \infty & 0,0893 & \infty & 6,739 & \infty & 15,550 & \infty & \infty & \infty \\ \infty & \infty & \infty & 102,115 & \infty & \infty & 1,965 & 0,728 & \infty & 11,792 & \infty \\ \infty & \infty & 16,164 & \infty & \infty & 0,149 & \infty & \infty & \infty & \infty & \infty \\ \infty & \infty & \infty & \infty & 0,2267 & \infty & \infty & \infty & \infty & 20,0083 & \infty \\ \infty & \infty & 0,0923 & \infty & 11,2173 & 30,9300 & \infty & \infty & \infty & \infty & \infty \end{bmatrix}$$

Para cada subregião r_i na segmentação referência, a sua região ajustada correspondente m_j é definida como aquela que possuir o mínimo valor na i -ésima linha de $Fit(r_i, m_j)$.

Uma vez selecionados os pares de regiões (r_i, m_j) ajustadas, procede-se ao cálculo das medidas quantitativas de discrepância das regiões ajustadas. A Tabela 6.3 apresenta os resultados dessas medidas para cada par (r_i, m_j) eleito como ajustadas.

**TABELA 6.3 - CÔMPUTO DAS MEDIDAS DE QUALIDADE DE AJUSTE
PARA CADA PAR DE REGIÃO AJUSTADA**

Subregião r_i	Subregião m_j	$Fitxy$	$Fiti$	$Fitn$	$Gforma$
1	11	0,9107	1	0,4058	0,2545
2	1	0,9540	1	0,5882	0,4167
3	4	0,9972	0,9863	0,8889	0,7609
4	8	0,8674	0,9754	0,8125	0,5094
5	6	0,9667	0,9615	0,9412	0,7708
6	5	0,9868	0,9434	0,8182	0,6418
7	3	0,9894	0,9474	0,9474	0,8095

A segmentação pode ser expressa em termos da média e variância de $Fitxy$, $Fiti$, $Fitn$ e $Gforma$ tomada dos valores obtidos para as 7 regiões da segmentação referência. Para quantificar uma segmentação a partir de um único valor toma-se a média dos valores destas medidas, a qual é denominada média geral. Essas médias são expressas na Tabela 6.4.

**TABELA 6.4 - VALORES DA MÉDIA E VARIÂNCIA GERAIS E DE CADA
UMA DAS MEDIDAS DE QUALIDADE**

Medida	Média	Variância
$Fitxy$	0,9532	0,0023
$Fiti$	0,9734	0,0006
$Fitn$	0,7717	0,0408
$Gforma$	0,5948	0,0436
Média Geral	0,8233	0,0055

Assim, dadas uma segmentação de referência e uma outra segmentação qualquer, é possível obter um vetor de medidas quantitativas e expressá-lo através de uma média e variância geral e, desta forma, ter um indicativo numérico acerca da qualidade

segmentação obtida. Além disto, dispondo-se de um conjunto de segmentações obtidas a partir de uma mesma imagem de entrada da qual se conhece a segmentação verdadeira (referência), é possível avaliar essas segmentações entre si.

Para calcular estas medidas para os dados que serão empregados neste trabalho, desenvolveu-se um programa escrito em IDL versão 4.0.

CAPÍTULO 7

METODOLOGIA

Este capítulo tem como objetivo apresentar a metodologia empregada nesta dissertação para obtenção dos resultados finais que permitirão avaliar e comparar os algoritmos de segmentação de imagens SAR, MUM e RWSEG.

A metodologia é baseada numa abordagem empírica, na qual os algoritmos são avaliados indiretamente através do resultado das segmentações obtidas de imagens testes. O conjunto de imagens teste é composto por imagens SAR real e sintéticas, contendo regiões com diferentes graus de homogeneidade (homogêneas, heterogêneas e extremamente heterogêneas), processadas com diferentes números de *looks* e tipo de detecção linear e tem por objetivo avaliar o desempenho dos algoritmos do ponto de vista da adequação para uma aplicação específica, da qualidade das segmentações produzidas, da capacidade de segmentar regiões de diferentes graus de homogeneidade, do custo computacional e da simplicidade.

A avaliação das segmentações é feita de forma qualitativa e quantitativa, ambas baseadas na comparação da segmentação de uma imagem produzida pelos algoritmos com a segmentação da mesma imagem obtida manualmente (tomando por base o tipo de aplicação definido), a qual é suposta como verdadeira e empregada como referência. O resultado qualitativo é obtido através da comparação puramente visual enquanto que o quantitativo é obtido a partir da aplicação de método empírico de discrepância, no qual as diferenças entre as segmentações comparadas são quantificadas empregando-se medidas de discrepância.

No caso das imagens simuladas, a avaliação quantitativa conta ainda com uma experiência Monte Carlo. Esta experiência consiste na obtenção de amostras (replicações) de imagens de uma mesma cena, independentes uma das outras, porém com as mesmas propriedades geométricas e estatísticas. Cada amostra é tratada individualmente e os resultados da experiência se baseiam na análise desses resultados

individuais. O objetivo desta experiência é amenizar a influência de uma imagem particular no resultado da avaliação quantitativa.

A comparação relativa entre os algoritmos é feita do ponto de vista do custo computacional, da simplicidade, da adequação para a aplicação definida e, principalmente da qualidade das segmentações produzidas. Neste caso, a comparação é feita de forma qualitativa e quantitativa. A primeira através da comparação visual entre a melhor segmentação obtida pelo MUM e a melhor obtida pelo RWSEG para cada imagem de entrada com a respectiva segmentação de referência. O critério de seleção destas melhores segmentações é apoiado na avaliação qualitativa e quantitativa de todas segmentações que cada algoritmo pode obter de um mesmo dado de entrada. A segunda através da comparação dos resultados das medidas de discrepância obtidas nas segmentações comparadas e dos resultados do experimento Monte Carlo, no caso das imagens simuladas.

Os passos seguidos nesta metodologia para obtenção dos resultados consistiram na: definição do tipo de aplicação, proposta e obtenção das imagens real e simuladas e de suas respectivas segmentações de referência, segmentação das imagens pelo MUM e pelo RWSEG, avaliação qualitativa e quantitativa das segmentações produzidas, determinação da melhor segmentação de cada imagem de entrada obtida por cada algoritmo, execução do experimento Monte Carlo a partir dos parâmetros de cada algoritmo que produziram as melhores segmentações para cada dado de entrada simulado e a comparação entre os algoritmos.

No diagrama esquemático da Figura 7.1 estão representados os passos seguidos nesta metodologia e será detalhado nas seções subsequentes.

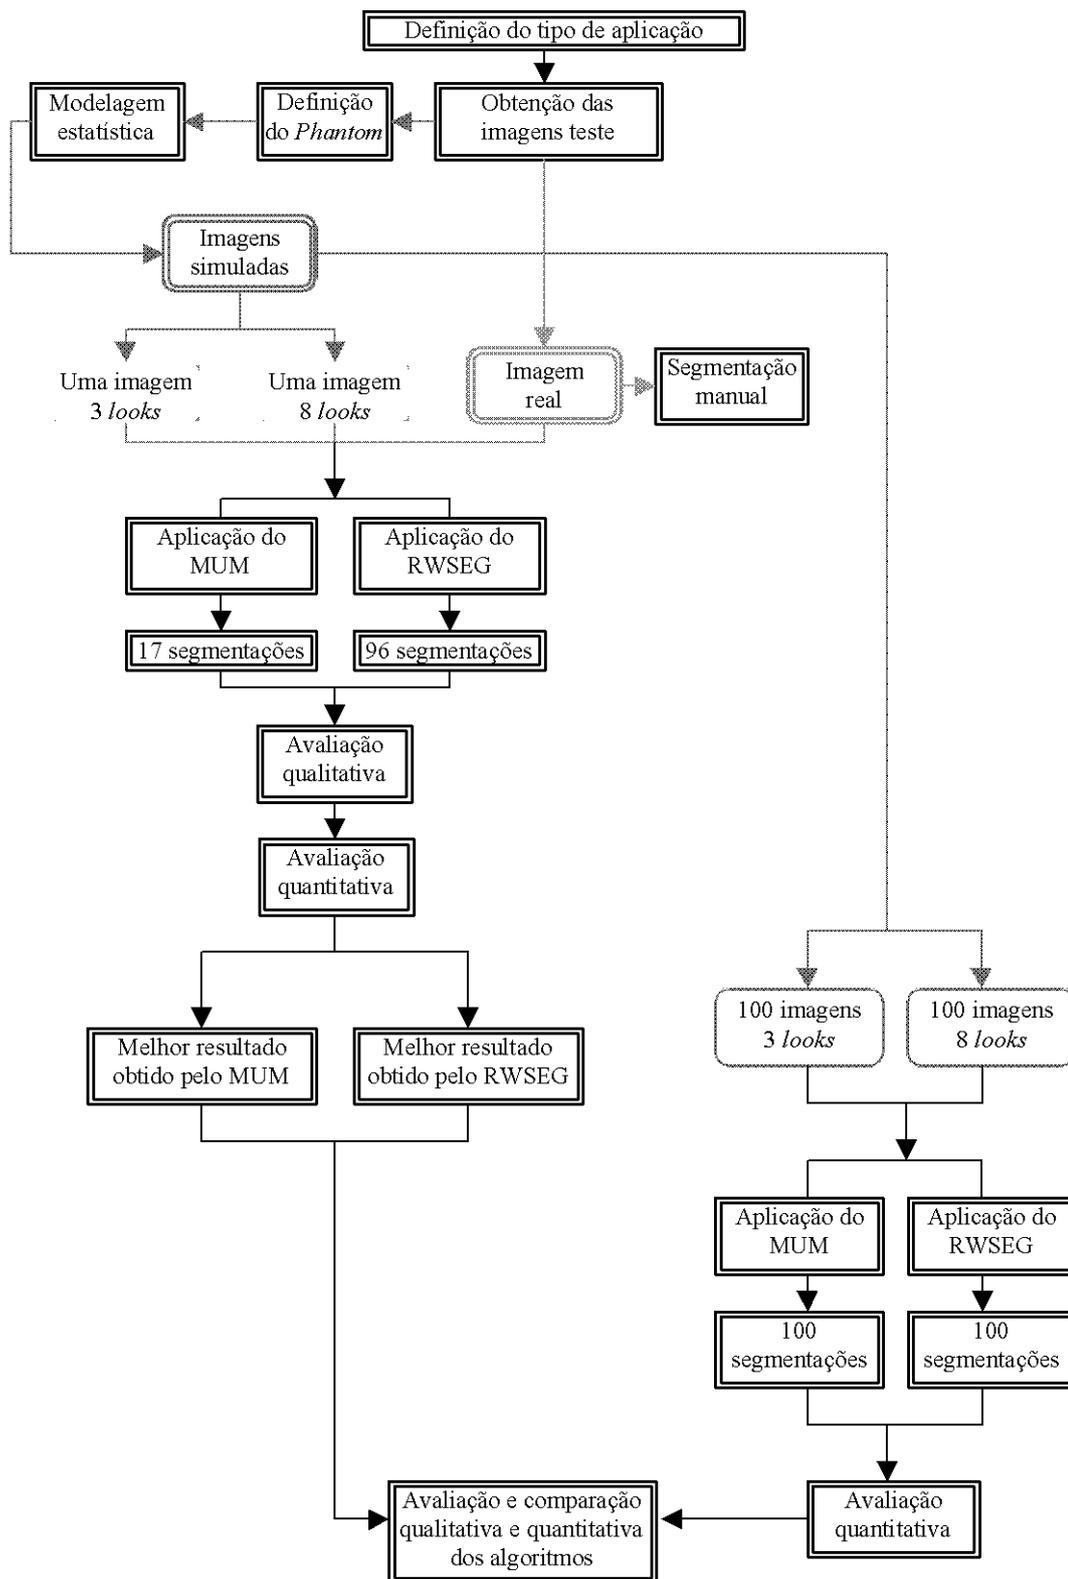


Fig. 7.1 - Diagrama esquemático da metodologia.

7.1 - DEFINIÇÃO DO TIPO DE APLICAÇÃO

O primeiro passo para se estabelecer uma metodologia de comparação entre algoritmos de segmentação consistiu em definir um tipo de aplicação para o qual se desejava segmentar uma imagem. O tipo de aplicação baliza a escolha do conjunto de imagens teste, define certas características (tamanho, forma, etc.) dos alvos a serem identificados e isolados, determina o nível de detalhamento requerido na segmentação e não deve privilegiar um determinado algoritmo. Além disto, serve como figura de mérito no processo de avaliação, na medida que possibilita verificar a adequação dos algoritmos para a aplicação definida. Alguns exemplos de aplicações das imagens SAR em estudos de sensoriamento remoto são o mapeamento de bacias hidrográficas, mapeamento de águas superficiais (lagos, rios), monitoramento de mudanças no uso do solo, mapeamento de camadas de gelo em oceanos, monitoramento de manchas de óleo em oceanos, dentre outras.

O tipo de aplicação definido para avaliar os algoritmos foi o estudo do uso e ocupação do solo. Este tipo de aplicação têm sido largamente conduzido a partir de imagens SAR e pode ser feito a partir de dados de diferentes sensores e em diferentes configurações. As características dos dados SAR é particularmente vantajosa para conduzir este tipo de estudo em regiões tropicais (Amazônia), onde os dados ópticos nem sempre são disponíveis.

Basicamente, tal aplicação consiste em identificar e isolar alvos como áreas urbanas, áreas de cultura agrícola, florestas, áreas de regeneração, solo exposto, pastagens, redes de drenagem, estradas, áreas desmatadas, etc. O fato destes alvos possuírem diferentes graus de homogeneidade e o conhecimento das distribuições usadas para modelá-los constituiu-se numa importante razão da escolha deste tipo de aplicação.

7.2 - PROPOSTA E OBTENÇÃO DO CONJUNTO DE IMAGENS TESTE

O conjunto de imagens teste proposto é composto por 202 imagens SAR sintéticas de uma mesma cena, sendo 101 processadas com 3 *looks* e 101 com 8 *looks*, e uma imagem

SAR real (3,5 *looks*), todas de dimensão 480×480 *pixels*, tipo de detecção linear e constituídas por regiões homogêneas, heterogêneas e extremamente heterogêneas.

Cada uma das imagens simuladas representa uma observação diferente e independente da mesma cena, porém com as mesmas propriedades geométricas e estatísticas.

Uma primeira abordagem acerca das imagens SAR que foram empregadas neste trabalho diz respeito ao fato de serem reais ou simuladas e à aplicabilidade de cada um destes tipos na metodologia proposta.

O emprego de imagens sintéticas foi importante porque elas representam dados de entrada no qual se tem amplo conhecimento a respeito de suas propriedades geométricas (por exemplo, localização e forma de uma borda) e estatísticas, possibilitando desta forma maior controle para quantificar, a partir de método empírico de discrepância, o desempenho das segmentações obtidas pelos algoritmos.

Um fator relevante da aplicabilidade deste tipo de imagem nesta metodologia foi a possibilidade de obtenção de amostras (replicações) de imagens de uma mesma cena, necessárias para o experimento Monte Carlo. Este experimento requer um conjunto relativamente grande de imagens, o que inviabiliza o emprego de imagens reais para tal propósito.

O processo de obtenção das imagens sintéticas permitiu que as mesmas fossem geradas sem levar em conta a correlação espacial dos valores radiométricos entre *pixels* vizinhos, constituindo-se, deste modo, num dado de entrada mais fiel ao suposto pelos algoritmos.

O emprego de uma imagem real teve como objetivo avaliar e comparar os algoritmos do ponto de vista da funcionalidade e adequação dos mesmos em aplicações práticas, e ainda produzir resultados que pudessem servir como base para futuros usuários. Além disto, a imagem real possui características distintas das simuladas no tocante à correlação espacial, servindo como um elemento a mais no processo de avaliação e, principalmente, no de comparação.

7.2.1 - IMAGEM REAL

A imagem SAR real selecionada foi obtida em 04 de Maio de 1996 da região de Ariquemes, no Estado de Rondônia. A Figura 7.2 ilustra a localização da área de estudo.

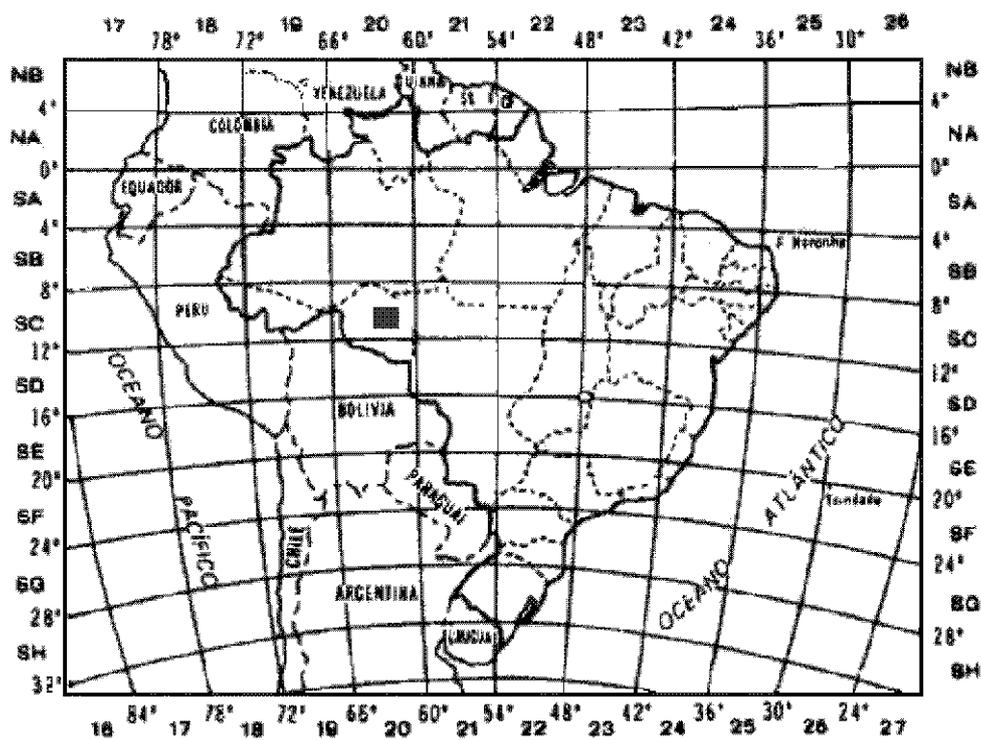


Fig. 7.2 – Localização da área de estudo.

A imagem foi obtida a partir do sistema JERS-1, processada em 3,5 looks e detecção linear (Figura 7.3). Os principais parâmetros deste sistema são a banda L e polarização HH, fornecendo imagens com resolução espacial de 18 metros a partir de um ângulo de visada nominal de 35 graus.

A cena amostrada contém regiões homogêneas, heterogêneas e extremamente heterogêneas com forma, tamanho e orientação variadas. Parte da área urbana do município de Ariquemes pode ser visualizada no quadrante inferior direito da imagem. As florestas primárias de diferentes tipos cobrem boa parte da cena. Algumas áreas de

desflorestamento, vegetação secundária, culturas anuais, solo exposto e um rio que corta toda a extensão da imagem no sentido longitudinal também compõem a cena.



Fig. 7.3 – Imagem SAR real da região de Ariquemes.

A obtenção da segmentação manual desta imagem, necessária para servir de referência no processo de avaliação qualitativa e quantitativa das segmentações produzidas pelos algoritmos, foi feita a partir do *software* Spring e com base no tipo de aplicação definido. Para tanto a imagem real foi importada para um banco de dados onde criou-se um plano de informação de categoria temática com as mesmas dimensões da imagem real. Sobrepondo-se este plano sobre outro que continha a visualização da imagem real, iniciou-se o processo de edição (na tela) de pontos, linhas e polígonos de modo a criar uma partição da imagem. A Figura 7.4 ilustra o processo de obtenção da segmentação manual a partir da sobreposição dos planos de informações e a Figura 7.5 apresenta os segmentos gerados no plano de informação temático. O último passo foi converter este plano de informação para o formato matricial.



Fig. 7.4 – Processo de obtenção da segmentação manual.

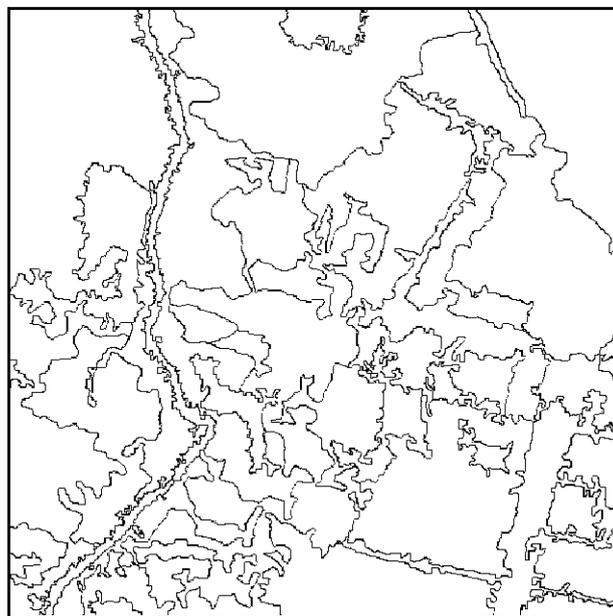


Fig. 7.5 - Resultado da segmentação manual da imagem real.

7.2.2 - OBTENÇÃO DAS IMAGENS SINTÉTICAS

As imagens sintéticas empregadas nesta dissertação possuem tamanho fixo de 480×480 *pixels* e foram simuladas visando o caso de imagens processadas em 3 e 8 *looks* e detecção linear (amplitude). Não foi considerada a correlação espacial entre os valores radiométricos de *pixels* vizinhos.

O processo de obtenção das imagens sintéticas envolveu basicamente três etapas. A primeira consistiu na criação, a partir da observação das regiões de interesse em imagens SAR reais, de um imagem idealizada que resumisse as principais características geométricas e topológicas da ocupação do solo. A segunda na classificação das regiões criadas em função do grau de homogeneidade. Estas classes de homogeneidade de uma região têm sido modeladas estatisticamente em função de observações obtidas dos dados JERS-1 (banda L), RADARSAT (banda C) e ESAR (Frery et al., 1997). A terceira na modelagem estatística das observações provindas dessas classes através de distribuições particulares associadas aos graus de homogeneidade e derivadas do modelo multiplicativo adotado para representar os dados SAR monoespectrais em amplitude. O resultado das duas etapas iniciais denomina-se *phantom* (imagem idealizada de classes de homogeneidades). Este dado foi empregado como segmentação de referência no processo de avaliação qualitativa e quantitativa das segmentações das imagens simuladas produzidas pelos algoritmos.

O modelo proposto para obtenção destas imagens possui três características muito importantes: representatividade, controlabilidade e repetibilidade. A representatividade já foi justificada pela geometria e topologias deduzidas, pelo conhecimento das propriedades estatísticas dos dados SAR e da sua modelagem. Além disto, as imagens simuladas também são representativas do ponto de vista estatístico. Pelo fato de ter-se deduzido um modelo paramétrico ele é controlável, no sentido que diversos valores de parâmetros produzem resultados diferentes, porém previsíveis. Finalmente, pelo fato do modelo ser probabilístico, e dado que dispõe-se de ferramentas de simulação estocástica capazes de gerar observações provindas de todas as distribuições envolvidas no modelo,

foi possível gerar um número arbitrário de observações diferentes, porém com as mesmas propriedades distribucionais desejadas.

7.2.2.1 - OBTENÇÃO DO PHANTOM

Com objetivo de obter representatividade em termos de escala, topologia e distribuição espacial para o *phantom*, partiu-se de uma imagem SAR real (JERS-1) da região de Castanhal no Estado do Pará, adquirida em 04 de Maio de 1996, 3 *looks* e tipo de detecção linear. Selecionou-se uma cena que continha regiões com os diferentes graus de homogeneidade de interesse e com dimensão de 480×480 (Figura 7.6).



Fig. 7.6- Imagem SAR real da região de Castanhal.

A seguir procedeu-se à segmentação manual desta imagem (a partir do mesmo processo empregado anteriormente) com o objetivo de criar um mapa de segmentos com

diferentes tamanhos, orientações e formas para servir de base na construção do *phantom*. O resultado desta operação pode ser visualizado na Figura 7.7.



Fig. 7.7 - Segmentação manual da imagem real.

Para classificar cada um dos segmentos obtidos, definiu-se 8 classes distintas sendo 3 (três) tipos de homogênea, 3 (três) de heterogênea e 2 (dois) de extremamente heterogênea e então cada segmento foi classificado como uma dessas 8 (oito) classes definidas. Vale salientar que a distinção entre as classes do mesmo tipo é obtida através da definição de diferentes parâmetros que caracterizam a distribuição de cada classe. O número de segmentos para cada um dos graus de homogeneidade definido é apresentado na Tabela 7.1.

TABELA 7.1 - NÚMERO DE SEGMENTOS POR GRAU DE HOMOGENEIDADE

GRAU DE HOMOGENEIDADE	SEGMENTOS
Homogênea 1	10
Homogênea 2	7
Homogênea 3	4
Heterogênea 1	4
Heterogênea 2	3
Heterogênea 3	4
Extremamente heterogênea 1	2
Extremamente heterogênea 2	2

O passo seguinte consistiu em classificar cada um dos segmentos obtidos com um dos diferentes graus de homogeneidade definidos. O mapa de segmentos classificados foi convertido para o formato *raster* e assim obteve-se uma imagem temática (*phantom*) com um total de 36 segmentos (Figura 7.8).

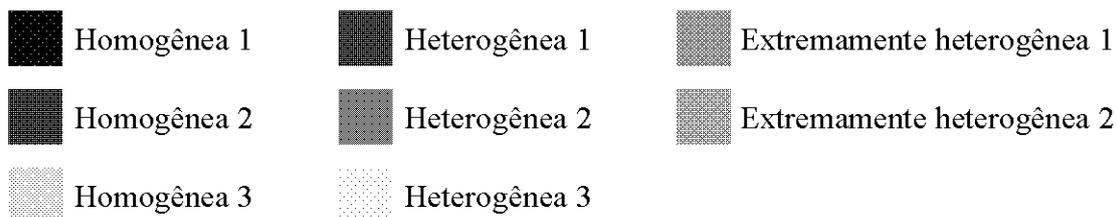
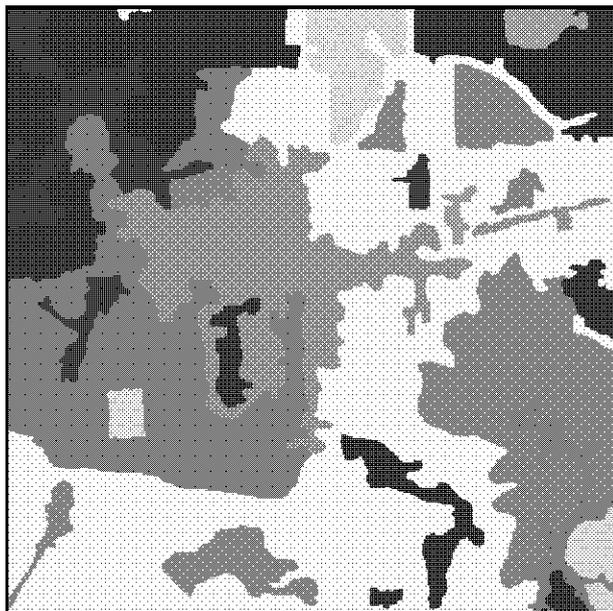


Fig. 7.8 - Imagem idealizada de classes (*Phantom*).

7.2.2.2 - MODELAGEM DAS CLASSES CONTIDAS NO PHANTOM

Para modelar cada classe do *phantom* através de uma certa distribuição particular, é preciso conhecer o processo de simulação estocástica das distribuições que são empregadas para modelar os diferentes graus de homogeneidade das regiões (segmentos) contidas no mesmo.

A simulação estocástica é o processo de gerar amostras de variáveis aleatórias em um ambiente computacional e usar estas amostras para obtenção de um certo resultado. O processo de simulação requer o conhecimento de noções de teoria dos números, de probabilidade, de processos estocásticos, de estatística, de análise numérica e das

particularidades do problema sob consideração. Todas as simulações requeridas para este trabalho dependem criticamente da geração de variáveis aleatórias univariadas Gama, que é um dos problemas que mais tem recebido atenção por parte da comunidade de simulação estocástica. O simulador de Gamas empregado é a implementação em IDL de uma modificação dos algoritmos XB e XG, apresentados em Bustos e Frery (1992), realizado por (Jacobo-Berteles e Mejail, 1998).

O processo de gerar ocorrências de uma variável aleatória que obedece uma certa distribuição pode ser não é trivial. Entretanto, no caso geral de distribuição Gama, o algoritmo de simulação é um caso clássico e conhecido. A partir deste algoritmo é possível também simular as ocorrências de variáveis aleatórias que obedeçam as distribuições Raiz de Gama, K-Amplitude e G-Amplitude Zero, que são de particular interesse para este trabalho.

Dentro do contexto do Modelo Multiplicativo, tal como visto anteriormente no Capítulo 3, seria necessário ter capacidade de gerar ocorrências (independentes, para a modelagem simplificada) provindas da distribuição $GA(\alpha, \gamma, \lambda, n)$, onde n denota o número de *looks*. Contudo, segundo os resultados apresentados em Frery et al. (1997), bastaria simular três casos particulares desta distribuição:

- a distribuição $\Gamma^{\frac{1}{2}}(n, n\beta^{-1})$;
- a distribuição $KA(\alpha, \lambda, n)$;
- a distribuição $G_A^0(\alpha, \gamma, n)$.

Suponha disponível um algoritmo capaz de gerar m ocorrências independentes v_1, \dots, v_m , provindas da variável aleatória V que obedece a distribuição $\Gamma(\alpha, \lambda)$. Esse algoritmo será utilizado para gerar, por simulação, dados observados de regiões de distintos tipos de heterogeneidade, numa imagem em formato de amplitude e de n *looks*.

Quando se deseja simular dados provindos de uma área homogênea com média μ , modelada pela distribuição $\Gamma^{\frac{1}{2}}(n, n\beta^{-1})$, basta informar a média μ da região de interesse e o valor do número de *looks* n e retornar $\sqrt{v_i}$, $i = 1, \dots, m$. O valor de β é obtido a partir da seguinte relação (ver equação 2.1):

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

Se o objetivo é simular as observações associadas a uma área heterogênea com média μ , modelada pela distribuição $KA(\alpha, \lambda, n)$, além do valor do número de *looks* n , da média μ da região, requer-se a especificação da homogeneidade da mesma através do valor do parâmetro α desejado. Definidos estes valores, simulam-se ocorrências independentes v_{i_1} e v_{i_2} , sendo v_{i_1} provinda de uma variável aleatória V_1 que obedece a distribuição $\Gamma(n, n)$ e v_{i_2} provinda de uma variável aleatória V_2 que obedece a distribuição $\Gamma(\alpha, \lambda)$, e retorna-se $\sqrt{v_{i_1} v_{i_2}}$, onde $i = 1, \dots, m$. O valor de λ é obtido a partir da seguinte relação (ver equação 2.2):

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

Analogamente, para simular ocorrências de áreas extremamente heterogêneas com média μ e parâmetro α desejado, modeladas pela distribuição $G_A^0(\alpha, \gamma, n)$, simulam-se ocorrências independentes v_{i_1} e v_{i_2} , sendo v_{i_1} provinda de uma variável aleatória V_1 que obedece a distribuição $\Gamma(n, n)$ e v_{i_2} provinda de uma variável aleatória V_2 que obedece a distribuição $\Gamma(-\alpha, \gamma)$, e retorna-se $\sqrt{v_{i_1}/v_{i_2}}$, onde $i = 1, \dots, m$. O valor de γ é obtido a partir da seguinte relação (ver equação 2.3):

$$\gamma = n \left[\frac{\mu \Gamma(-\alpha) \Gamma(n)}{\Gamma(-\alpha-0,5) \Gamma(n+0,5)} \right]^2.$$

A modelagem das classes definidas no *phantom* seguiu o processo de gerar ocorrências de variáveis aleatórias descrito acima. As observações provindas de cada classe contida no *phantom* foi modelada com as distribuições e parâmetros apresentados nas Tabelas 7.2 e 7.3, considerando-se o modelo multiplicativo para os dados em amplitude e números de *looks* respectivamente iguais a 3 e 8. O valor de μ representa a média (ou esperança) proposta do sinal de retorno. Os valores do parâmetro α das distribuições $KA(\alpha, \lambda, n)$ e $G_A^0(\alpha, \gamma, n)$ usados para modelar as regiões heterogêneas e extremamente heterogêneas, respectivamente, foram selecionados com base na Figura 7.9, a qual ilustra a influência deste parâmetro nestas distribuições.

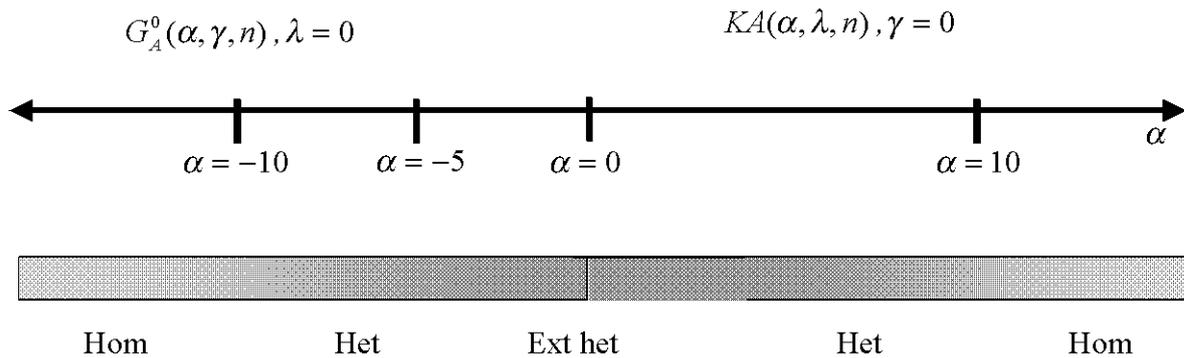


Fig. 7.9 - Influência do parâmetro α nas distribuições $KA(\alpha, \lambda, n)$ e $G_A^0(\alpha, \gamma, n)$.

Para executar a modelagem criou-se um programa escrito em IDL versão 4.0 que, dado uma imagem classificada de entrada, gera uma imagem simulada de saída em amplitude e com o número de *looks* selecionado pelo usuário, onde cada classe da imagem de entrada (*phantom*) é modelada com a distribuição pertinente apresentada nas Tabelas 7.2 e 7.3.

**TABELA 7.2 - DISTRIBUIÇÕES E PARÂMETROS ADOTADOS PARA
 MODELAR A IMAGEM SIMULADA COM 3 LOOKS ($n=3$)**

Regiões	Distrib	μ	α	$\beta \times (10^3)$	$\lambda \times (10^{-4})$	$\gamma \times (10^4)$
Hom 1	$\Gamma^{\frac{1}{2}}(n, n\beta^{-1})$	70	-	5,324	-	-
Hom 2	$\Gamma^{\frac{1}{2}}(n, n\beta^{-1})$	80	-	6,953	-	-
Hom 3	$\Gamma^{\frac{1}{2}}(n, n\beta^{-1})$	150	-	24,446	-	-
Het 1	$KA(\alpha, \lambda, n)$	90	2,0	-	2,000	-
Het 2	$KA(\alpha, \lambda, n)$	170	5,0	-	1,510	-
Het 3	$KA(\alpha, \lambda, n)$	130	3,0	-	1,500	-
Ext Het 1	$G_A^0(\alpha, \gamma, n)$	220	- 7,0	-	-	32,893
Ext Het 2	$G_A^0(\alpha, \gamma, n)$	160	- 4,0	-	-	9,067

**TABELA 7.3 - DISTRIBUIÇÕES E PARÂMETROS ADOTADOS PARA
 MODELAR A IMAGEM SIMULADA COM 8 LOOKS ($n=8$)**

Regiões	Distrib	μ	α	$\beta \times (10^5)$	$\lambda \times (10^{-6})$	$\gamma \times (10^5)$
Hom 1	$\Gamma^{\frac{1}{2}}(n, n\beta^{-1})$	70	-	4,839	-	-
Hom 2	$\Gamma^{\frac{1}{2}}(n, n\beta^{-1})$	80	-	6,321	-	-
Hom 3	$\Gamma^{\frac{1}{2}}(n, n\beta^{-1})$	150	-	22,222	-	-
Het 1	$KA(\alpha, \lambda, n)$	90	2,0	-	211	-
Het 2	$KA(\alpha, \lambda, n)$	170	5,0	-	159	-
Het 3	$KA(\alpha, \lambda, n)$	130	3,0	-	158	-
Ext Het 1	$G_A^0(\alpha, \gamma, n)$	220	- 7,0	-	-	3,123
Ext Het 2	$G_A^0(\alpha, \gamma, n)$	160	- 4,0	-	-	0,860

As Figuras 7.10 a 7.12 apresentam as densidades das distribuições $\Gamma^{\frac{1}{2}}(n, n\beta^{-1})$, $KA(\alpha, \lambda, n)$ e $G_A^0(\alpha, \gamma, n)$ obtidas a partir dos valores dos parâmetros contidos na Tabela 7.2 e usadas para modelar as regiões homogêneas, heterogêneas e extremamente heterogêneas das imagens simuladas de 3 *looks*, respectivamente. As Figuras 7.13 a 7.15 apresentam as densidades das distribuições $\Gamma^{\frac{1}{2}}(n, n\beta^{-1})$, $KA(\alpha, \lambda, n)$ e $G_A^0(\alpha, \gamma, n)$ obtidas a partir dos valores dos parâmetros contidos na Tabela 7.3 e usadas para modelar as regiões homogêneas, heterogêneas e extremamente heterogêneas das imagens simuladas de 8 *looks*, respectivamente.

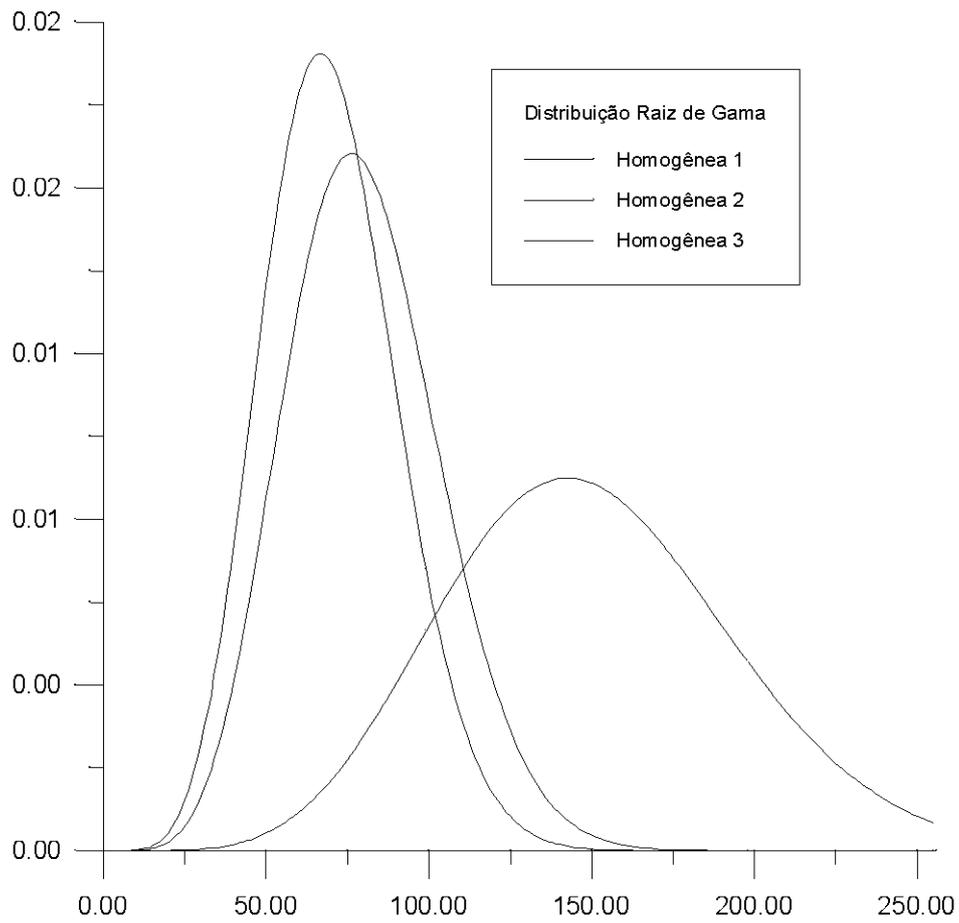


Fig. 7.10 – Densidades das distribuições $\Gamma^{\frac{1}{2}}(3, 0.000563)$, $\Gamma^{\frac{1}{2}}(3, 0.000431)$, $\Gamma^{\frac{1}{2}}(3, 0.000123)$ usadas para modelar as regiões homogêneas 1, 2 e 3, respectivamente.

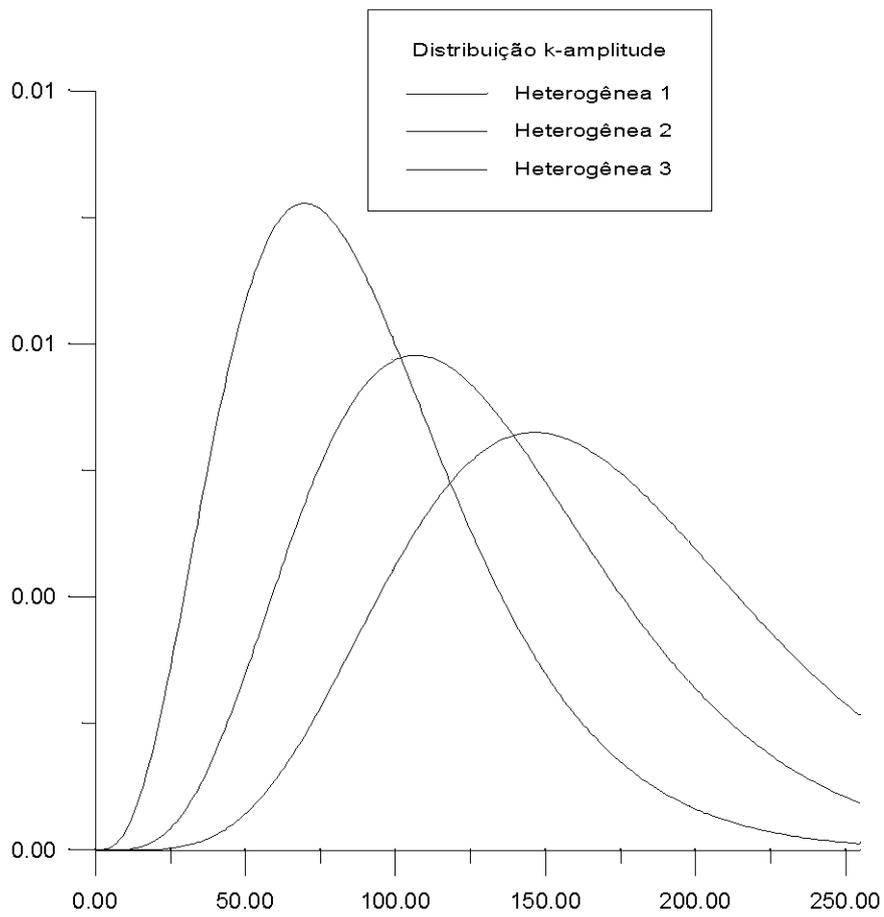


Fig. 7.11 – Densidades das distribuições $KA(2,10000,3)$, $KA(5,33000,3)$, $KA(3,20000,3)$ usadas para modelar as regiões heterogêneas 1, 2 e 3, respectivamente.

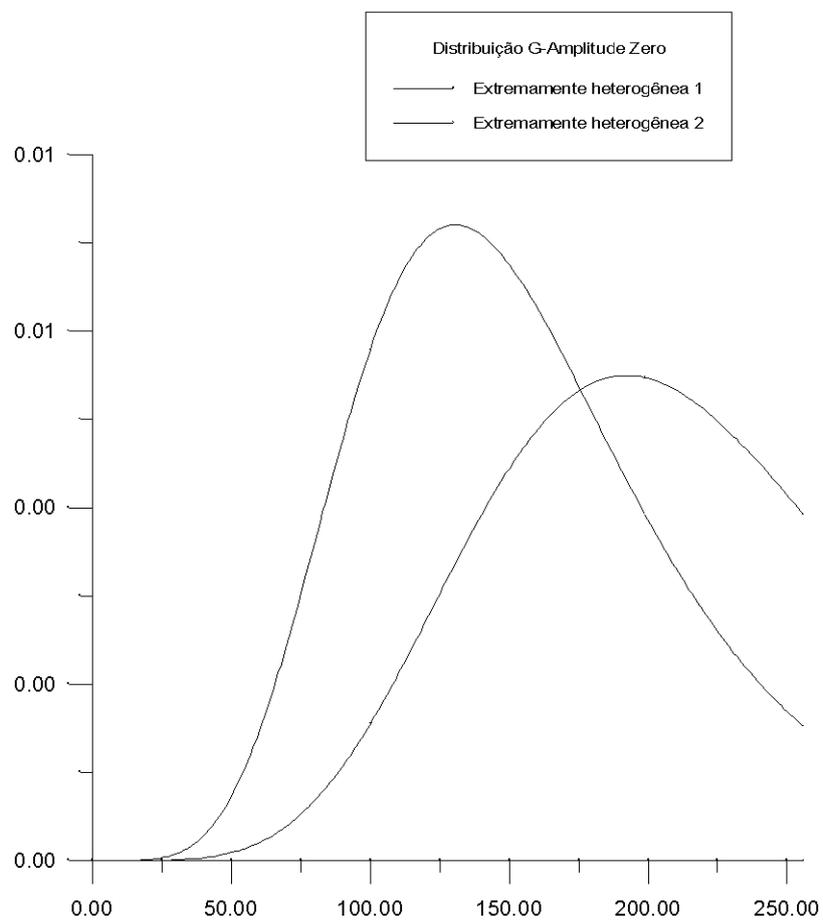


Fig. 7.12 – Densidades das distribuições $G_A^0(-7, 328930, 3)$ e $G_A^0(-4, 90670, 3)$ usadas para modelar as regiões extremamente heterogêneas 1 e 2, respectivamente.

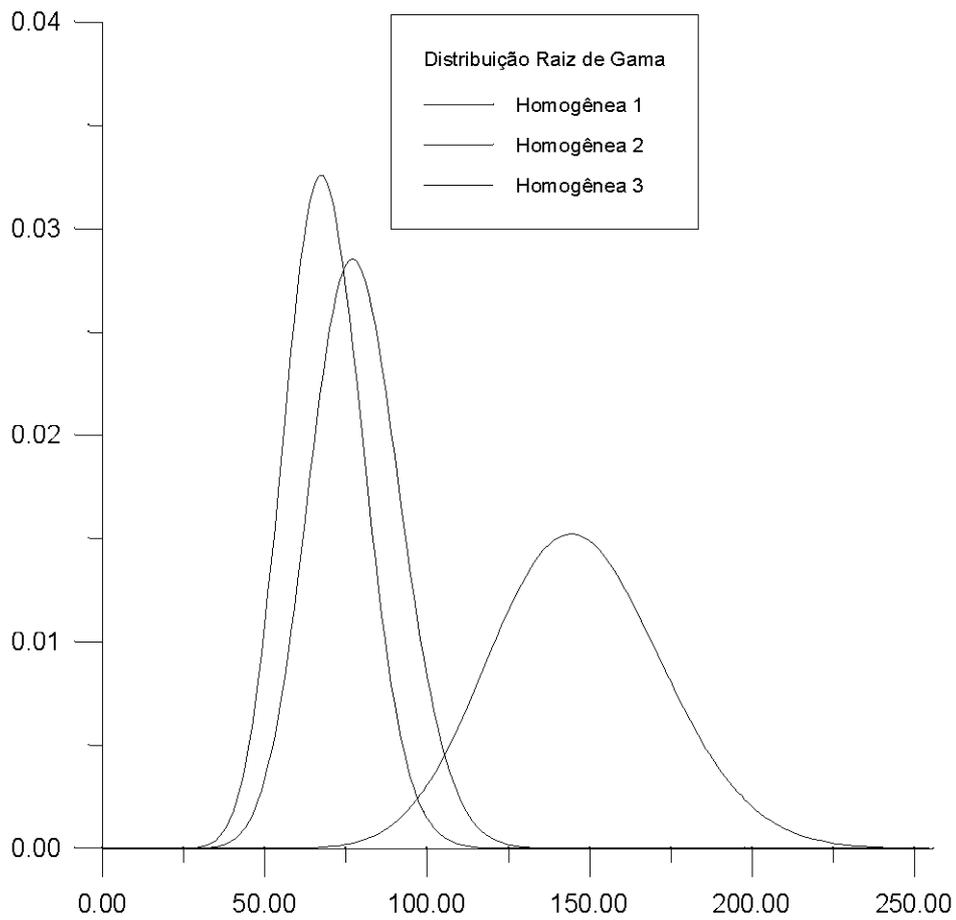


Fig. 7.13 – Densidades das distribuições $\Gamma^{\frac{1}{2}}(8, 0.001653)$, $\Gamma^{\frac{1}{2}}(8, 0.001266)$, $\Gamma^{\frac{1}{2}}(8, 0.000360)$ usadas para modelar as regiões homogêneas 1, 2 e 3, respectivamente.

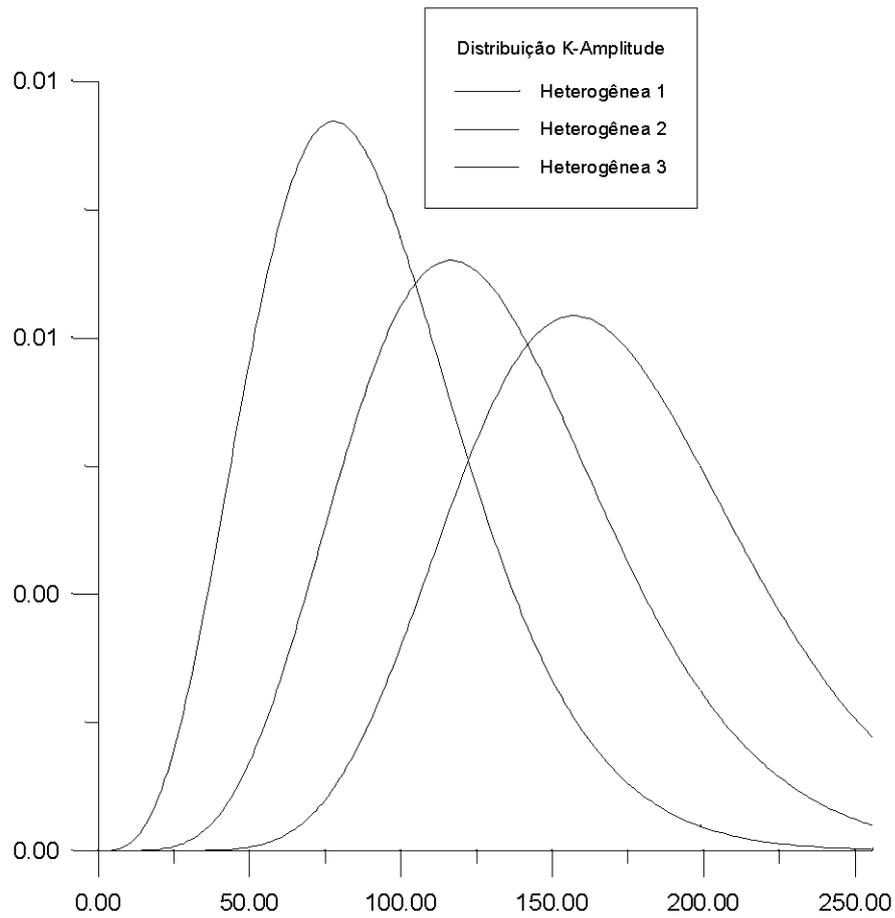


Fig. 7.14 – Densidades das distribuições $KA(2, 9400, 8)$, $KA(5, 31400, 8)$, $KA(3, 18900, 8)$ usadas para modelar as regiões heterogêneas 1, 2 e 3, respectivamente.

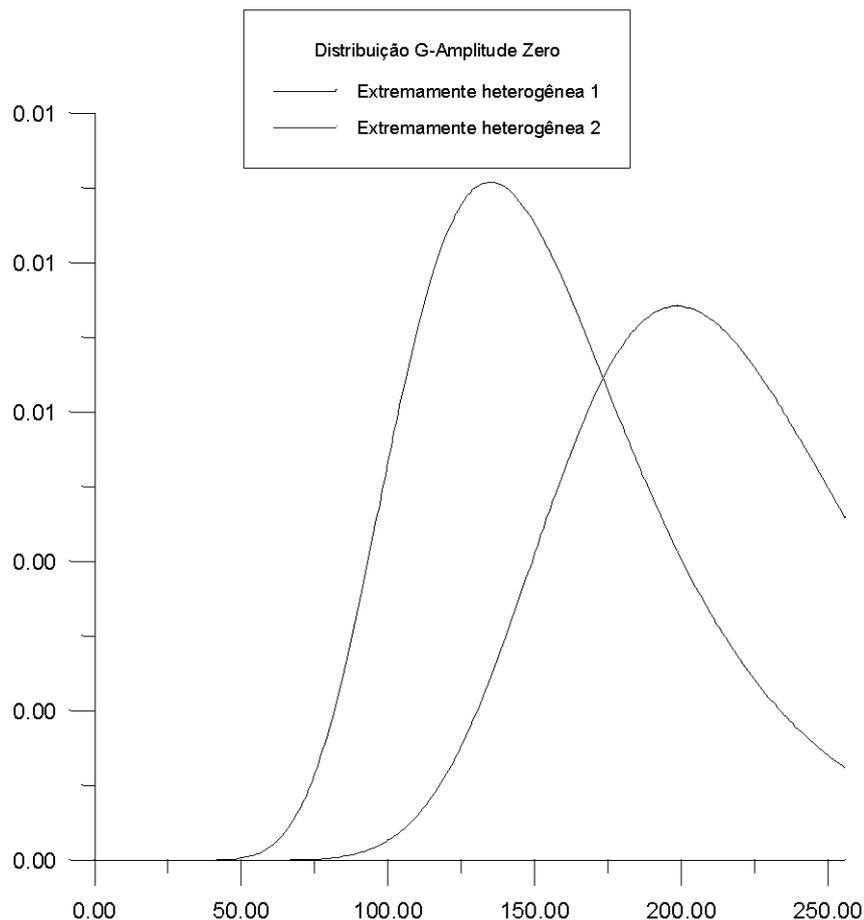


Fig. 7.15 – Densidades das distribuições $G_A^0(-7, 312300, 8)$ e $G_A^0(-4, 86000, 8)$ usadas para modelar as regiões extremamente heterogêneas 1 e 2, respectivamente.

Desta forma, após o processo de modelagem das regiões do *phantom*, obteve-se todas as imagens simuladas com 3 e 8 *looks* e em amplitude. As replicações de imagens de um mesmo número de *looks* foi feita variando-se os valores dos *pixels* das regiões de uma replicação para outra sem, contudo, alterar suas propriedades geométricas e estatísticas. As Figuras 7.16 e 7.17 apresentam duas imagens simuladas distintas com 3 *looks* e duas de 8 *looks*, respectivamente. Em relação ao aspecto visual destas imagens observa-se que nas de 8 *looks* as regiões possuem uma uniformidade interna maior, fruto do processo de reamostragem envolvido no processamento *multilook*.

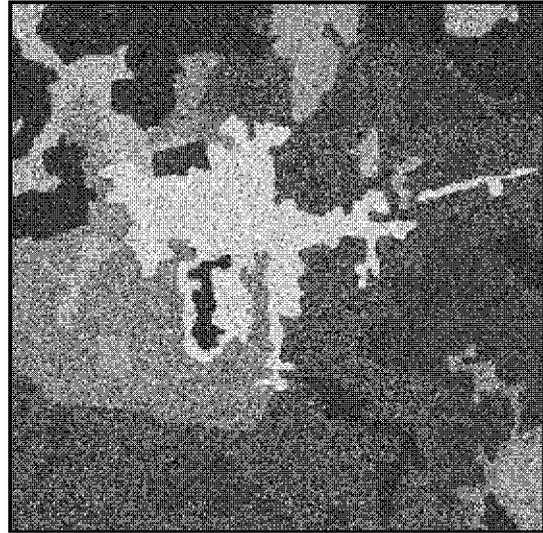
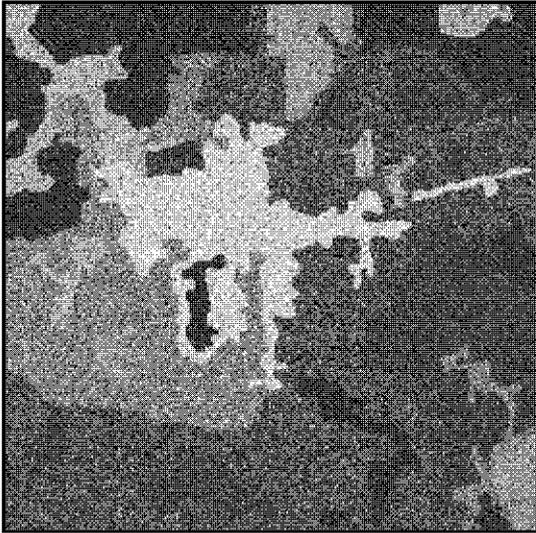


Fig. 7.16 - Imagens simuladas de 3 *looks* e em Amplitude.

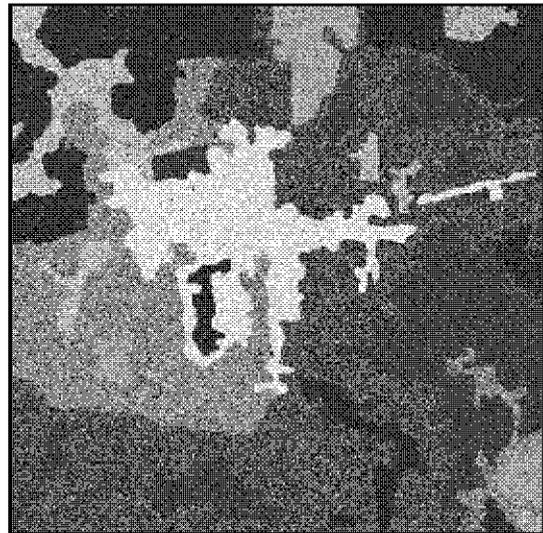
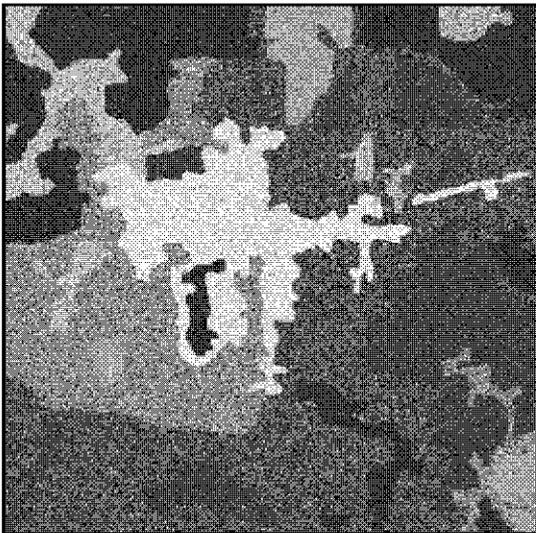


Fig. 7.17 - Imagens simuladas de 8 *looks* e em Amplitude.

7.3 - OBTENÇÃO E AVALIAÇÃO DAS SEGMENTAÇÕES DAS IMAGENS TESTES PELO MUM E PELO RWSEG

A segmentação das imagens testes foi feita em duas etapas e com objetivos distintos.

Na primeira etapa a imagem real, uma imagem simulada de 3 *looks* e uma imagem simulada de 8 *looks* foram segmentadas individualmente pelos dois algoritmos de modo a se obter todas as segmentações possíveis que cada um pode produzir a partir de um mesmo dado de entrada em função da variação dos valores atribuídos aos seus respectivos parâmetros.

As segmentações da imagem real a partir do algoritmo MUM foram obtidas selecionando-se o parâmetro i para dados em amplitude, o parâmetro l igual a 3,5 e o parâmetro p sucessivamente com um dos 17 valores possíveis (1 a 17), obtendo-se ao final 17 segmentações distintas. O mesmo processo foi empregado para segmentar as imagens simuladas de 3 e 8 *looks*, exceto pela seleção do parâmetro l (igual a 3 e 8 respectivamente).

As segmentações de cada uma das imagens de entrada a partir do algoritmo RWSEG foram obtidas selecionando-se o parâmetro i para dados em amplitude, o parâmetro e sucessivamente com os valores 1,65, 1,96, 2,33, 2,58, 2,81, 3,09, 3,29, 3,48, 3,72, 3,89, 4,06, 4,27, 4,42, 4,57, 4,77 e 4,91 e o parâmetro j com os valores 0, 2, 4, 6, 8 e 10. As combinações possíveis dos parâmetros e (16 valores) e j (6 valores) produziram 96 segmentações distintas de cada uma das imagens de entrada.

O tempo de processamento e o número de classes e segmentos obtidos em cada uma das segmentações foram computados. O número de classes indica quantos alvos distintos (em relação à propriedade nível médio de cinza) existem em uma segmentação. Esta medida guarda uma relação direta com o número de segmentos gerados, uma vez que, geralmente, quanto maior o número de alvos, maior o número de segmentos gerados. Permitiu avaliar a capacidade do algoritmo em identificar e isolar alvos distintos em uma imagem de entrada.

Em seguida todas as segmentações de cada uma das imagens de entrada obtidas por cada um dos algoritmos foram avaliadas qualitativamente e quantitativamente (através das medidas de qualidade obtidas), e com base no resultados destas avaliações, determinou-se a melhor segmentação de cada uma das imagens de entrada obtida através do MUM e através do RWSEG. O critério de decisão na escolha da melhor segmentação (ou dos parâmetros que a produziram) levou em consideração os resultados da duas análises. Esses parâmetros foram então empregados nos respectivos algoritmos para segmentar as imagens simuladas replicadas no experimento Monte Carlo.

O objetivo desta etapa foi produzir resultados que permitissem avaliar os algoritmos do ponto de vista da qualidade das segmentações produzidas, do custo computacional requerido para obtenção das segmentações, da capacidade de segmentar regiões de diferentes graus de homogeneidade e da influência da seleção dos valores possíveis dos parâmetros nas segmentações produzidas.

A segunda etapa consistiu no Experimento Monte Carlo e teve como objetivo complementar e comprovar o resultado da avaliação quantitativa das segmentações produzidas das imagens simuladas de 3 e 8 *looks* obtidas na etapa anterior, amenizando a influência de uma imagem particular nos resultados obtidos. Este experimento consistiu em segmentar uma a uma, as 100 imagens simuladas (replicações) de 3 *looks* e as 100 de 8 *looks* com o MUM e com o RWSEG, selecionando-se em cada um os valores dos parâmetros que produziram as segmentações das respectivas imagens simuladas eleitas como melhor na etapa anterior. A seguir, obteve-se as medidas de qualidade de todas as segmentações produzidas. Nesta etapa não foi feita a avaliação qualitativa devido ao grande volume de dados.

Cabe salientar que para se ter resultados representativos neste tipo de experimento, o número de replicações deve compensar a variabilidade das medidas. Esse número, portanto, não deveria ser inferior a, digamos, trinta. Em algumas experiências reportadas na literatura (Bustos e Frery, 1992) são necessárias milhares de repetições para atingir níveis aceitáveis de qualidade. Entretanto, devido ao custo computacional requerido, a

aplicação da metodologia foi aplicada para um conjunto de 100 imagens (replicações) de 3 *looks* e 100 de 8 *looks*.

Os resultados obtidos nas duas etapas serviram de base para comparar os dois algoritmos e serão discutidos no próximo Capítulo.

CAPÍTULO 8

RESULTADOS E DISCUSSÃO

Este capítulo tem a finalidade de apresentar e discutir, concomitantemente, os resultados obtidos nesta dissertação com a metodologia empregada. Os resultados são apresentados de modo a permitir a avaliação e a comparação dos algoritmos para cada dado de entrada.

Para cada um dos dados de entrada (imagens simuladas de 3 *looks* e de 8 *looks* e imagem real) e para cada algoritmo são apresentados e discutidos os seguintes resultados:

- Avaliação qualitativa e quantitativa da qualidade das segmentações obtidas através do MUM e do RWSEG para uma única imagem. Nesta fase, as segmentações possíveis que cada algoritmo produz a partir da mesma imagem de entrada são quantificadas através das medidas de ajuste de posição, tamanho, intensidade média, forma e média geral, bem como qualificadas visualmente como subsegmentada, supersegmentada ou satisfatória do ponto de vista da aplicação definida (estudo de uso e ocupação do solo) e para as imagens e suas respectivas segmentações de referência propostas. Estes resultados permitem avaliar a influência da seleção dos valores dos parâmetros nas segmentações produzidas por cada algoritmo e, principalmente, determinar qual dentre os mesmos gera a melhor segmentação do ponto de vista qualitativo e quantitativo para o tipo de aplicação definido. Esses parâmetros serão então empregados nos respectivos algoritmos para segmentar as imagens simuladas replicadas no experimento Monte Carlo. A avaliação quantitativa das segmentações inclui também a quantificação de cada segmentação em termos de número de classes e de segmentos, bem como do tempo de processamento requerido;
- Avaliação quantitativa da qualidade das segmentações das imagens simuladas replicadas obtidas no experimento Monte Carlo. Nesta etapa, cada segmentação é quantificada a partir das medidas de ajuste e da média geral. Em seguida, obtém-se a média amostral destas medidas tomadas das 100 segmentações produzidas por cada

algoritmo. A média amostral das medidas de ajuste e da média geral obtidas considerando-se isoladamente cada tipo distinto de região (homogênea, heterogênea e extremamente heterogênea) da imagem de entrada também é calculada. Este resultado tem por objetivo medir a capacidade dos algoritmos de segmentar as regiões com diferentes graus de homogeneidade;

- Comparação dos resultados obtidos por cada algoritmo. Nesta etapa, procede-se a comparação dos algoritmos através dos resultados qualitativos e quantitativos obtidos por cada um. Esta comparação é feita do ponto de vista da qualidade das segmentações obtidas, da capacidade de segmentar regiões de diferentes graus de homogeneidade e do custo computacional. Cabe salientar que a qualidade da segmentação produzida por cada algoritmo é a principal referência de comparação entre os mesmos e, desta forma, os resultados do experimento Monte Carlo são de vital importância neste trabalho para termos de determinação do algoritmo mais adequado para o tipo de aplicação definido.

8.1 - RESULTADOS OBTIDOS A PARTIR DA IMAGEM SIMULADA DE 3 LOOKS

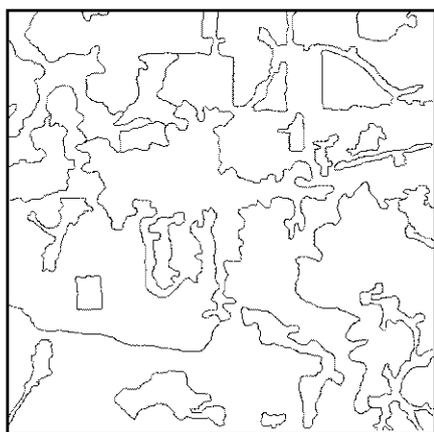
8.1.1 - RESULTADOS OBTIDOS PELO MUM

8.1.1.1 - AVALIAÇÃO QUALITATIVA

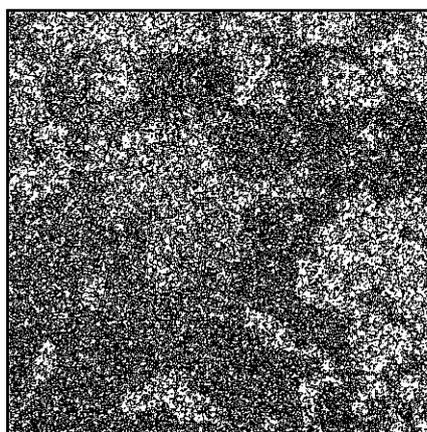
A partir da comparação visual das 17 segmentações produzidas pelo MUM com a segmentação de referência verificou-se que o grau de subdivisão destas segmentações teve relação inversa com o valor atribuído ao parâmetro p . Quanto maior seu valor, menor o grau de subdivisão. A influência do valor do parâmetro p selecionado nas segmentações produzidas pode ser visualizada na Figura 8.1.

A Figura 8.1 apresenta a segmentação manual (referência) da imagem simulada 3 looks e as segmentações (apresentadas na forma de mapa de bordas) da mesma imagem produzidas pelo MUM com p igual a 1, 6, 10, 13 e 17. Estes valores foram escolhidos para dar uma noção geral do efeito da seleção do valor de p , apresentando os dois extremos (maior e menor) e três intermediários.

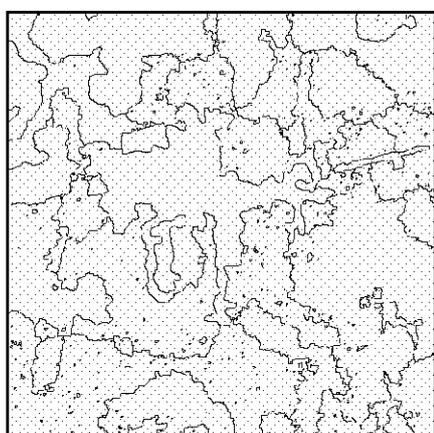
Verificou-se que o aumento do valor atribuído ao parâmetro p produziu segmentações com regiões em menor número e tamanho médio maior. Do ponto de vista da aplicação definida e da segmentação verdadeira (referência) proposta, as segmentações produzidas com valores do parâmetro p iguais a 1, 2 e 3 apresentaram-se extremamente segmentadas, enquanto que as com valores superiores a 10 apresentaram-se subsegmentadas. Desta forma, as segmentações qualitativamente satisfatórias foram obtidas com os valores de p situados entre 4 e 10 (inclusive). A Figura 8.2 apresenta as segmentações produzidas com parâmetro p iguais a 4, 5, 7, 8 e 9.



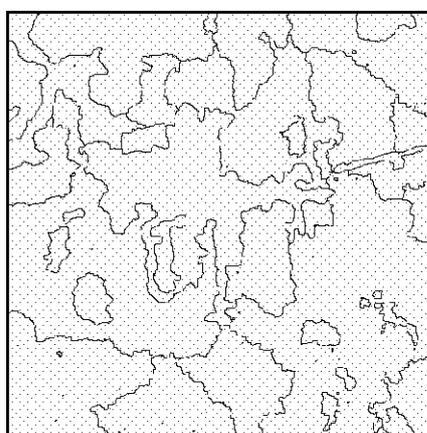
(a)



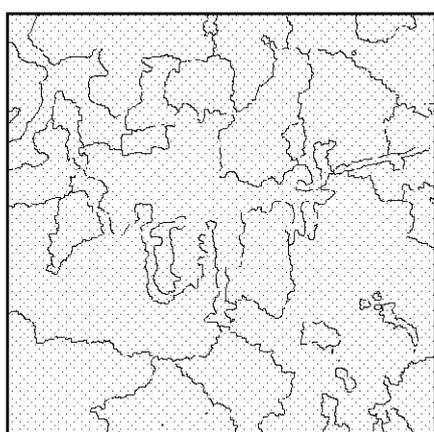
(b)



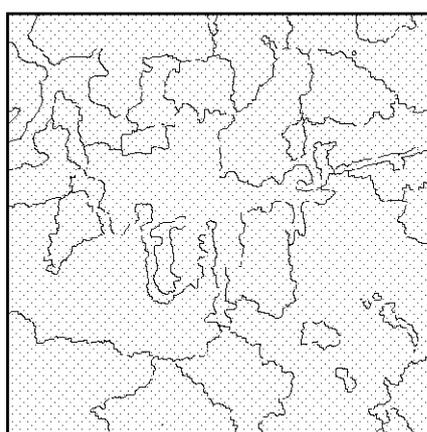
(c)



(d)

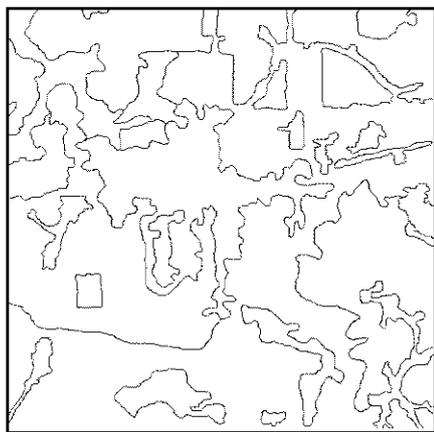


(e)

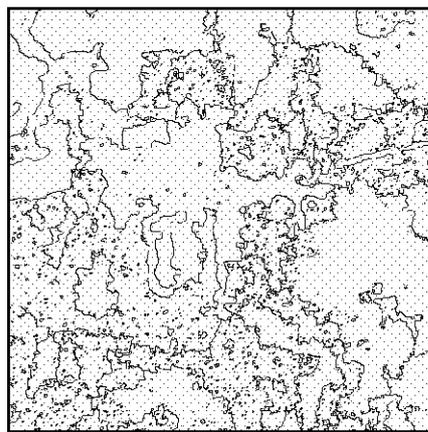


(f)

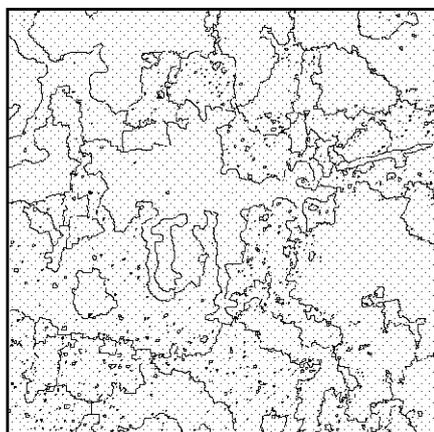
Fig. 8.1 - Segmentação manual (a) e segmentações da imagem 3 *looks* produzidas pelo MUM com $p=1$ (b), $p=6$ (c), $p=10$ (d), $p=13$ (e) e $p=17$ (f).



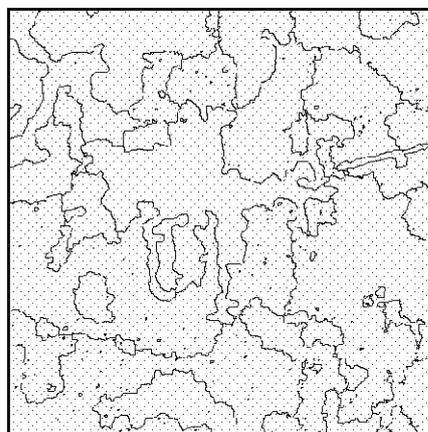
(a)



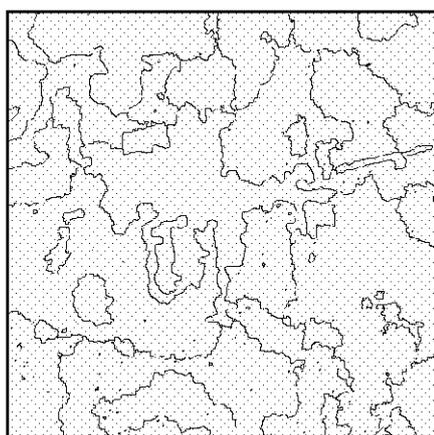
(b)



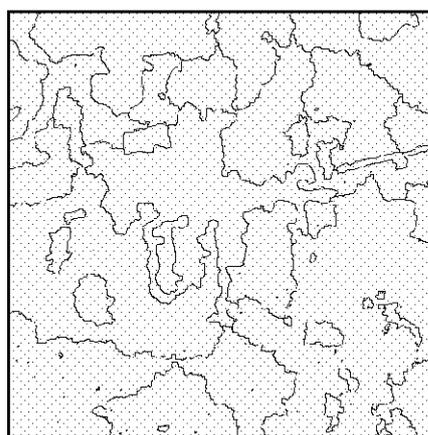
(c)



(d)



(e)



(f)

Fig. 8.2 - Segmentação manual (a) e segmentações da imagem 3 *looks* produzidas pelo MUM com $p=4$ (b), $p=5$ (c), $p=7$ (d), $p=8$ (e) e $p=9$ (f).

8.1.1.2 - AVALIAÇÃO QUANTITATIVA

A avaliação quantitativa das segmentações produzidas foi realizada calculando-se a média geral ($\hat{\mu}_g$) das medidas de ajuste obtida em cada segmentação. Considera-se que quanto maior for esta média, melhor é o resultado quantitativo da segmentação, sendo que $0 \leq \hat{\mu}_g \leq 1$. A Figura 8.3 apresenta as médias gerais obtidas em cada uma das segmentações em função do parâmetro p selecionado.

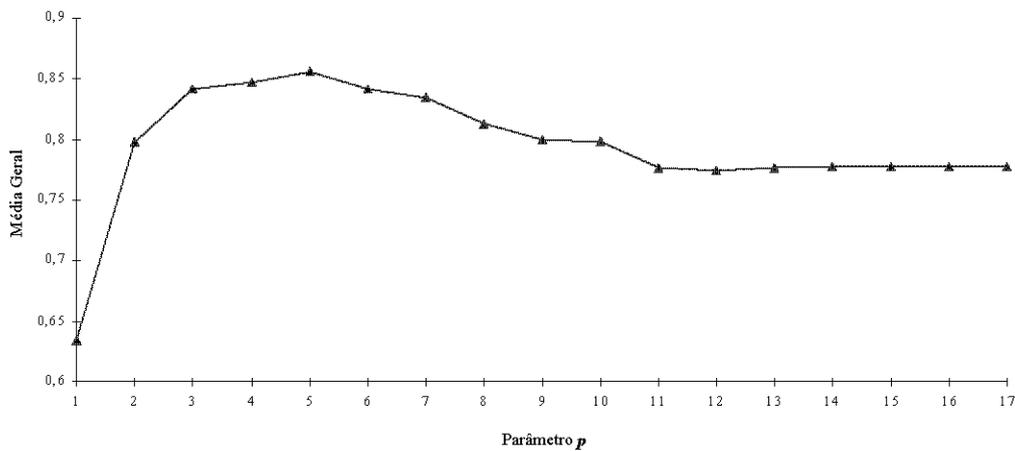


Fig. 8.3 - Média geral das segmentações da imagem de 3 *looks* produzidas pelo MUM.

Da Figura 8.3 verificou-se que a segmentação com maior média geral foi obtida com p igual a 5 ($\hat{\mu}_g = 0,8556$). Pode-se observar também que a maioria das segmentações tiveram média geral compreendida entre 0,78 e 0,85, isto é, com bons resultados quantitativos. Valores de p compreendidos no intervalo de 3 a 10 produziram as segmentações com maiores médias gerais, enquanto que os valores iguais e ou superiores a 11 apresentaram basicamente a mesma média.

O tempo real de processamento (yymin:zz.zs) e o número de classes e de segmentos obtidos nas segmentações produzidas pelo MUM para cada valor de p estão contidos na Tabela 8.1.

TABELA 8.1 - TEMPO DE PROCESSAMENTO E NÚMERO DE CLASSES E DE SEGMENTOS OBTIDOS

p	Tempo	Classes	Segmentos
1	5:08.9	224	30091
2	23:20.9	228	11545
3	36:18.9	221	4915
4	37:11.1	205	2179
5	35:44.5	190	998
6	37:09.4	169	531
7	36:03.9	138	304
8	39:07.1	107	193
9	40:53.6	84	124
10	43:13.0	70	95
11	44:54.3	55	74
12	45:01.6	44	61
13	45:27.0	40	53
14	41:04.4	37	51
15	41:05.0	32	50
16	47:21.8	31	43
17	45:39.7	29	40

Da Tabela 8.1 observou-se que o número de classes distintas e o número total de segmentos diminuiu à medida que o valor do parâmetro p foi aumentado. Este resultado pode ser entendido a partir da análise da estrutura do algoritmo. Uma vez que o valor do parâmetro p define quão diferente duas regiões adjacentes devem de ser em termos de intensidade média para serem consideradas distintas entre si, o aumento do seu valor aumenta a probabilidade de duas regiões serem a mesma (provinda de um mesmo retroespalhamento) e assim regiões com “pequenas” diferenças de intensidade média são agrupadas e desta forma menos regiões distintas são produzidas.

Considerando-se a segmentação de referência (9 classes distintas e 36 segmentos), quase todos os valores de p produziram segmentações com excessivo número de classes e de segmentos.

Da Tabela 8.1 observou-se que o tempo de processamento requerido para produzir as segmentações tendeu a aumentar proporcionalmente ao valor atribuído ao parâmetro p .

Este resultado deve-se ao fato de que quanto maior o valor atribuído a p , mais iterações de agrupamento de regiões são feitas para obter a segmentação final.

Considerando-se os resultados das avaliações qualitativa e quantitativa da qualidade de todas as segmentações da imagem simulada 3 *looks* produzidas pelo MUM, a obtida com p igual a 5 foi eleita como a mais representativa da verdadeira (referência).

8.1.2 - RESULTADOS OBTIDOS PELO RWSEG

8.1.2.1 - AVALIAÇÃO QUALITATIVA

A partir da comparação visual das 96 segmentações produzidas pelo RWSEG com a segmentação de referência, verificou-se que o aumento do valor do parâmetro e , para um mesmo j , originou segmentações com menor número de segmentos. Do mesmo modo, para um mesmo valor de e , o aumento do valor do parâmetro j produziu o mesmo efeito. Verificou-se também que este algoritmo tendeu a produzir segmentações com elevado número de microsegmentos para a maioria dos valores atribuídos ao parâmetro e , principalmente quando aplicados com pequenos valores do parâmetro j .

A influência dos valores atribuídos aos dois parâmetros nas segmentações produzidas será discutida de modo a determinar o subconjunto de valores de cada um que produziu as segmentações qualitativamente satisfatórias do ponto de vista da aplicação definida e da segmentação verdadeira (referência) proposta.

Da avaliação visual das 96 segmentações observou-se que as segmentações produzidas com valores de j igual a zero apresentaram-se subsegmentadas (não levando em conta os microsegmentos) para valores do parâmetro e superiores a 2,81 e supersegmentadas para os inferiores a 2,58. As produzidas com valores de j iguais a 6, 8 e 10 apresentaram-se subsegmentadas para todos os valores do parâmetro e superiores a 1,65. Os valores 2 e 4 do parâmetro j foram os que produziram segmentações qualitativamente mais satisfatórias.

A influência do valor atribuído ao parâmetro j pode ser verificada a partir das Figuras 8.4 e 8.5, as quais apresentam (na forma de mapa de bordas) a segmentação de referência e as segmentações da imagem simulada de 3 *looks* produzidas pelo RWSEG com valores de e iguais a 1,65, 2,58, 3,29, 4,06 e 4,91 e, respectivamente, com valores de j igual a 0 e 8. Os valores de e apresentados representam uma amostragem dos 16 utilizados e compreende os valores máximo, mínimo e 3 intermediários.

A partir das Figuras 8.4 e 8.5, verificou-se que para um mesmo valor do parâmetro e , o aumento do valor atribuído ao parâmetro j ocasionou a diminuição do número total de segmentos. Também foi possível verificar que o aumento do valor atribuído ao parâmetro e , para um dado j , produziu o mesmo efeito.

As segmentações produzidas com valor de e igual a 1,65 apresentaram-se extremamente segmentadas para todos os valores de j . As produzidas com valores de e iguais a 1,96 e 2,33 apresentaram-se supersegmentadas para valores de j iguais a 0 e 2 e subsegmentadas para os superiores a 4. As produzidas com valores de e igual e superiores a 3,29 apresentaram-se no geral subsegmentadas (descontando os microsegmentos) para todos os valores de j . Os valores do parâmetro e que produziram segmentações qualitativamente satisfatórias foram os iguais a 2,33, 2,58, 2,81, 3,09 e 3,29.

As segmentações obtidas a partir dos subconjuntos de valores dos parâmetros e e j que produziram segmentações qualitativamente satisfatórias do ponto de vista da aplicação definida e da segmentação verdadeira (referência) proposta podem ser visualizadas a partir das Figuras 8.6 e 8.7, as quais apresentam a segmentação manual e as segmentações da imagem de 3 *looks* produzidas pelo RWSEG selecionando-se valores de e iguais a 2,33, 2,58, 2,81, 3,09 e 3,29 e valores de j respectivamente iguais a 2 e 4.

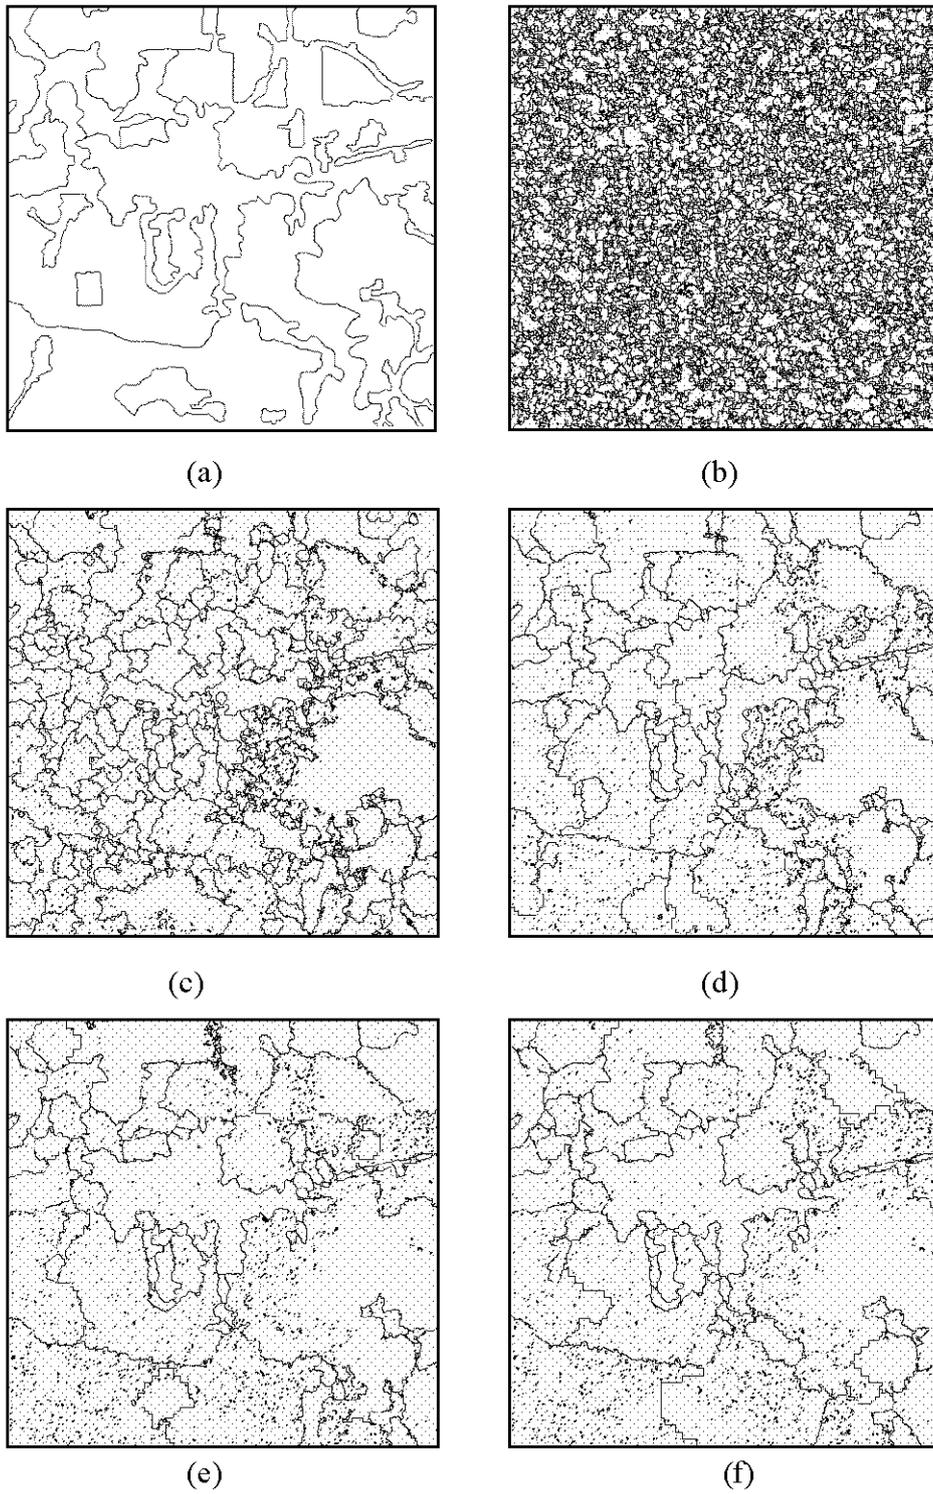
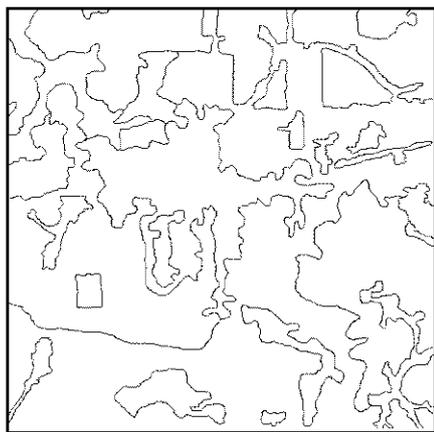
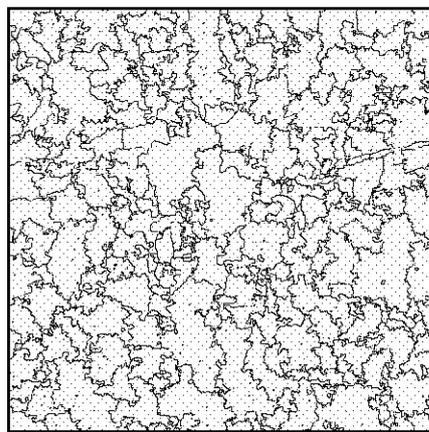


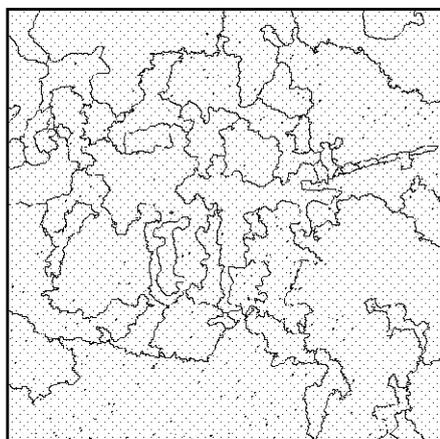
Fig. 8.4 - Segmentação manual (a) e segmentações da imagem 3 *looks* produzidas pelo RWSEG com $j=0$ e $e=1,65$ (b), $e=2,58$ (c), $e=3,29$ (d), $e=4,06$ (e) e $e=4,91$ (f).



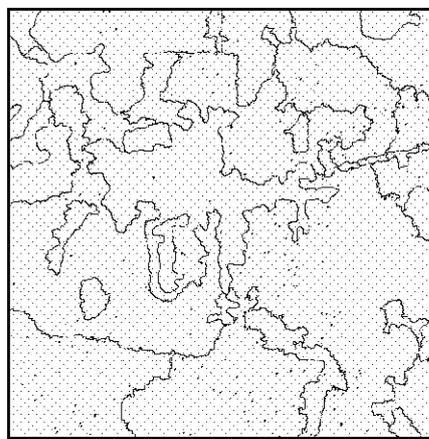
(a)



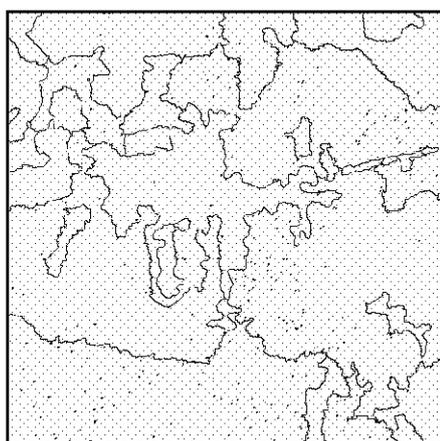
(b)



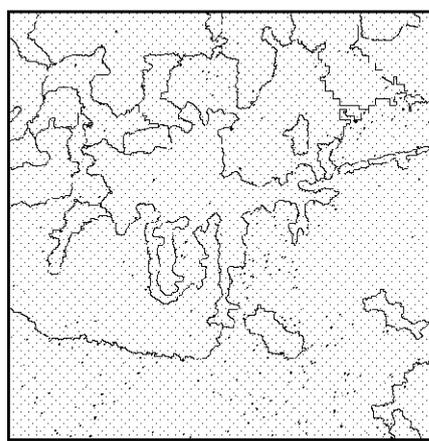
(c)



(d)

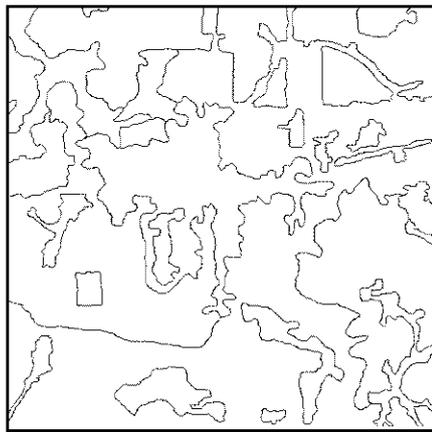


(e)

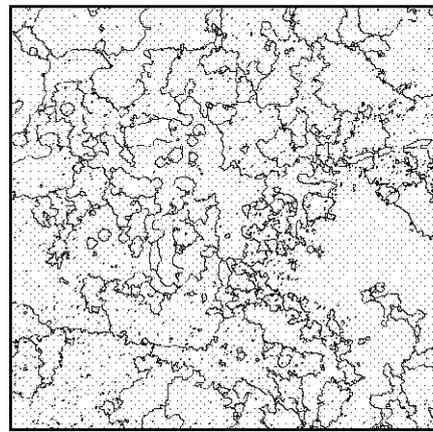


(f)

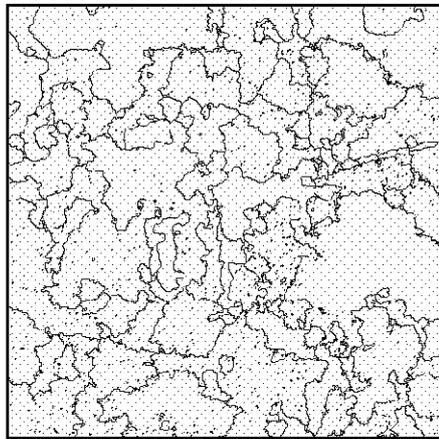
Fig. 8.5 - Segmentação manual (a) e segmentações da imagem 3 *looks* produzidas pelo RWSEG com $j=8$ e $e=1,65$ (b), $e=2,58$ (c), $e=3,29$ (d), $e=4,06$ (e) e $e=4,91$ (f).



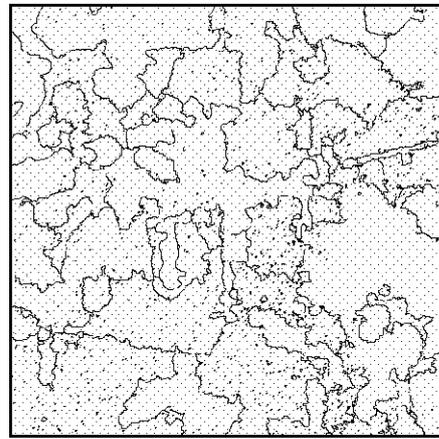
(a)



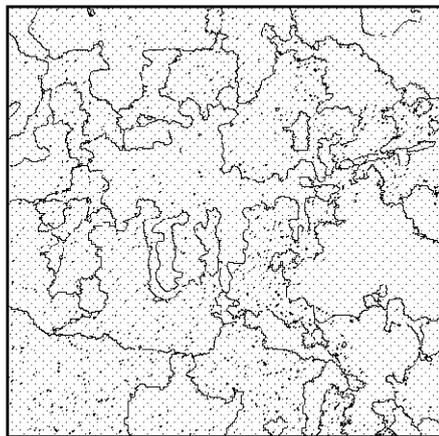
(b)



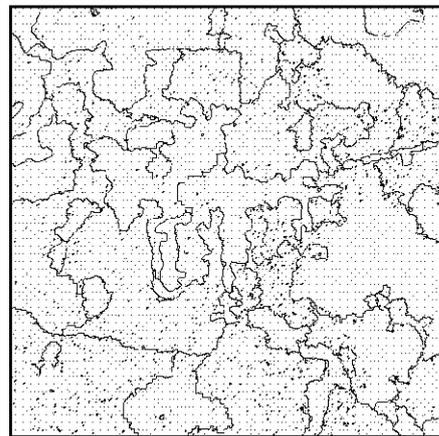
(c)



(d)

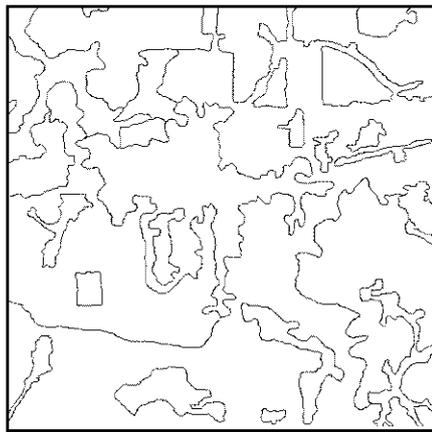


(e)

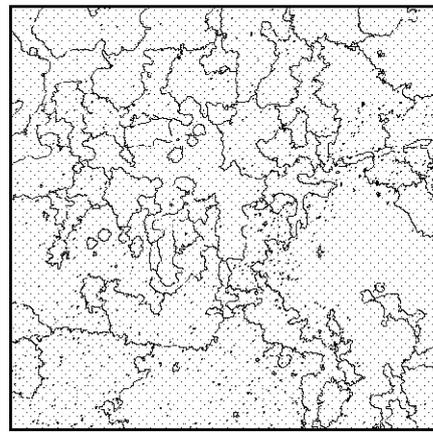


(f)

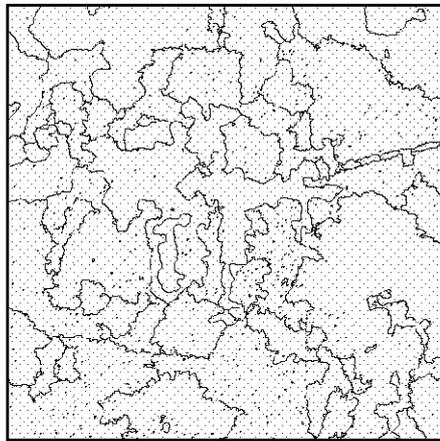
Fig. 8.6 - Segmentação manual (a) e segmentações da imagem 3 *looks* produzidas pelo RWSEG com $j=2$ e $e=2,33$ (b), $e=2,58$ (c), $e=2,81$ (d), $e=3,09$ (e) e $e=3,29$ (f).



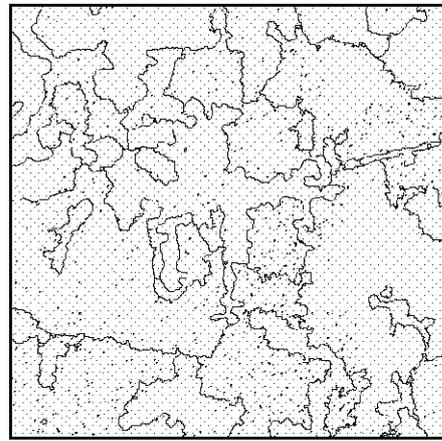
(a)



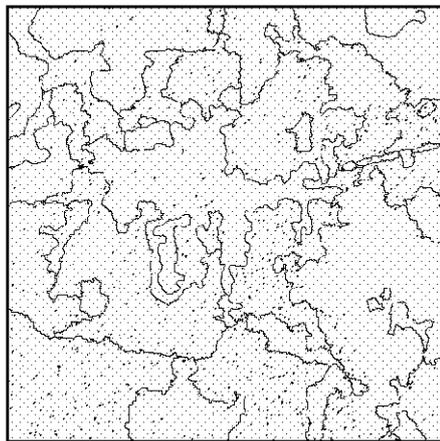
(b)



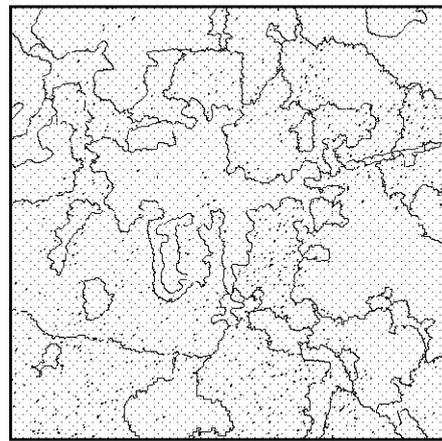
(c)



(d)



(e)



(f)

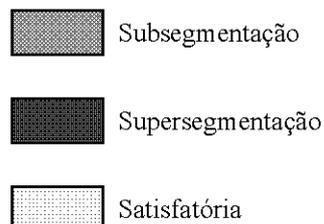
Fig. 8.7 - Segmentação manual (a) e segmentações da imagem 3 looks produzidas pelo RWSEG com com $j=4$ e $e=2,33$ (b), $e=2,58$ (c), $e=2,81$ (d), $e=3,09$ (e) e $e=3,29$ (f).

Da análise das Figuras 8.6 e 8.7 verificou-se que as segmentações obtidas com e igual a 2,58 e j igual a 2 (Figura 8.6 c), com e igual a 2,58 e j igual a 4 (Figura 8.7 c) e com e igual a 2,81 e j igual a 2 (Figura 8.6 d) puderam ser consideradas como satisfatórias do ponto de vista qualitativo e do tipo de aplicação definido.

A Tabela 8.2 apresenta a classificação qualitativa das segmentações da imagem simulada de 3 looks produzidas pelo RWSEG em função dos valores dos parâmetros selecionados.

TABELA 8.2 - CLASSIFICAÇÃO QUALITATIVA DAS SEGMENTAÇÕES

e	j	0	2	4	6	8	10
1,65		Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação
1,96		Subsegmentação	Subsegmentação	Satisfatória	Subsegmentação	Subsegmentação	Subsegmentação
2,33		Subsegmentação	Subsegmentação	Satisfatória	Subsegmentação	Subsegmentação	Subsegmentação
2,58		Satisfatória	Satisfatória	Satisfatória	Subsegmentação	Subsegmentação	Subsegmentação
2,81		Satisfatória	Satisfatória	Satisfatória	Subsegmentação	Subsegmentação	Subsegmentação
3,09		Subsegmentação	Satisfatória	Satisfatória	Subsegmentação	Subsegmentação	Subsegmentação
3,29		Subsegmentação	Satisfatória	Satisfatória	Subsegmentação	Subsegmentação	Subsegmentação
3,48		Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação
3,72		Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação
3,89		Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação
4,06		Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação
4,27		Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação
4,42		Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação
4,57		Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação
4,77		Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação
4,91		Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação



Da Tabela 8.2 observou-se que das 96 segmentações possíveis, apenas 12 (12,5%) apresentaram resultados qualitativamente satisfatórios. A grande maioria das segmentações produzidas apresentaram-se subsegmentadas. Cabe salientar que todas as segmentações classificadas como "subsegmentadas" possuem um número muito maior de segmentos que a segmentação de referência, sendo a grande maioria representados por microsegmentos. No entanto, a classificação foi feita considerando-se as regiões de tamanho médio maior, e do ponto de vista da adequação das mesmas para a aplicação definida.

8.1.2.2 - AVALIAÇÃO QUANTITATIVA

A avaliação quantitativa das segmentações produzidas foi realizada calculando-se a média geral ($\hat{\mu}_g$) das medidas de ajuste obtida em cada segmentação. A Figura 8.8 apresenta as médias gerais obtidas em cada uma das segmentações em função dos valores e e j selecionados.

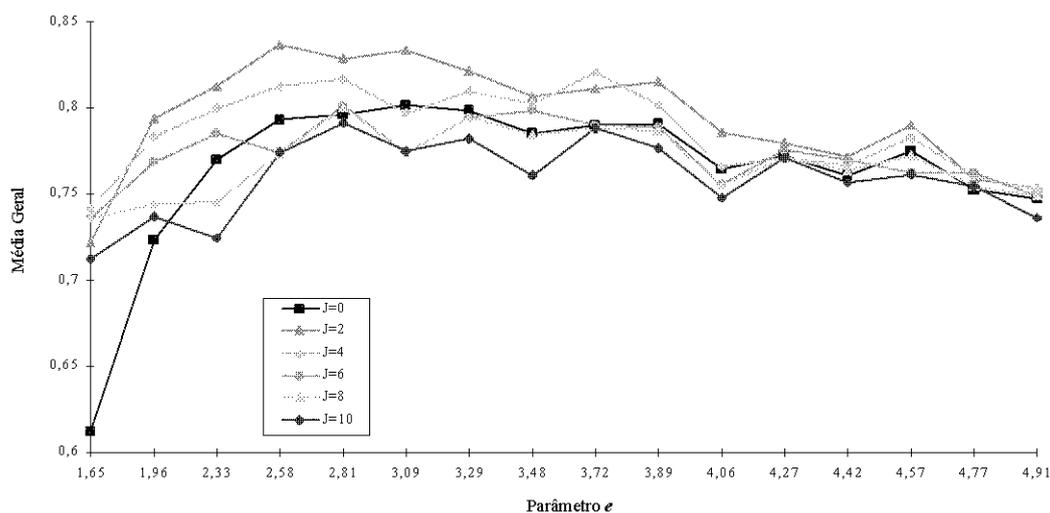


Fig. 8.8 - Média geral das segmentações produzidas pelo RWSEG.

Da Figura 8.8 verificou-se que as maiores médias gerais foram obtidas nas segmentações produzidas com valores de j iguais a 2 e 4 e para a maioria dos parâmetros e , ao passo que as menores são obtidas com valores de j iguais a 0, 8 e 10. O intervalo de valores do parâmetro e compreendido entre 2,58 e 3,29 apresentaram as melhores médias gerais. Estes resultados foram concordantes com os obtidos na avaliação qualitativa (visual). Do ponto de vista quantitativo, a melhor segmentação produzida pelo RWSEG foi a obtida com e igual a 2,58 e j igual a 2 ($\hat{\mu}_g = 0,8362$).

A maioria das segmentações produzidas apresentaram média geral compreendida no intervalo de 0,73 a 0,83. Valores de e igual e superiores a 4,06 apresentaram média geral praticamente constante para todos os valores de j .

O tempo de processamento (yymin:zz.zs) e o número de classes e de segmentos obtidos nas segmentações produzidas pelo RWSEG para cada combinação de valores de e e j selecionados estão contidos nas Tabelas 8.3 a 8.8.

TABELA 8.3 - TEMPO DE PROCESSAMENTO E NÚMERO DE CLASSES E DE SEGMENTOS OBTIDOS COM $J=0$

Parâmetros		Tempo	Classes	Segmentos
e	j			
1,65	0	3:47.7	198	8467
1,96	0	2:32.4	184	4396
2,33	0	2:45.0	181	3137
2,58	0	3:01.4	183	2610
2,81	0	3:05.0	183	2470
3,09	0	3:05.0	181	2316
3,29	0	6:15.0	180	2319
3,48	0	3:04.5	180	2303
3,72	0	3:02.6	181	2282
3,89	0	3:03.1	179	2227
4,06	0	3:08.8	177	2270
4,27	0	3:12.5	179	2266
4,42	0	3:05.7	180	2239
4,57	0	3:05.1	178	2178
4,77	0	3:12.3	178	2206
4,91	0	3:07.7	178	2159

TABELA 8.4 - TEMPO DE PROCESSAMENTO E NÚMERO DE CLASSES E DE SEGMENTOS OBTIDOS COM $J=2$

Parâmetros		Tempo	Classes	Segmentos
<i>e</i>	<i>j</i>			
1,65	2	4:19.3	197	3151
1,96	2	3:13.6	184	1924
2,33	2	3:16.5	180	1562
2,58	2	2:51.8	183	1361
2,81	2	2:55.5	180	1315
3,09	2	3:03.3	176	1283
3,29	2	3:34.5	176	1306
3,48	2	3:03.4	176	1298
3,72	2	3:04.4	170	1268
3,89	2	3:04.5	171	1245
4,06	2	3:05.8	170	1282
4,27	2	3:07.3	166	1305
4,42	2	3:19.3	169	1293
4,57	2	3:17.1	164	1268
4,77	2	3:07.3	166	1293
4,91	2	3:07.4	168	1295

TABELA 8.5 - TEMPO DE PROCESSAMENTO E NÚMERO DE CLASSES E DE SEGMENTOS OBTIDOS COM $J=4$

Parâmetros		Tempo	Classes	Segmentos
<i>e</i>	<i>j</i>			
1,65	4	4:15.1	188	1370
1,96	4	3:01.1	170	943
2,33	4	3:07.5	166	903
2,58	4	3:06.9	159	810
2,81	4	3:22.3	155	791
3,09	4	3:32.8	154	784
3,29	4	3:31.8	153	820
3,48	4	3:02.8	152	800
3,72	4	3:02.8	153	816
3,89	4	3:10.3	152	789
4,06	4	3:14.7	156	820
4,27	4	3:13.1	152	841
4,42	4	3:09.9	154	824
4,57	4	3:08.8	147	821
4,77	4	3:09.3	150	827
4,91	4	3:14.9	156	831

TABELA 8.6 - TEMPO DE PROCESSAMENTO E NÚMERO DE CLASSES E DE SEGMENTOS OBTIDOS COM $J=6$

Parâmetros		Tempo	Classes	Segmentos
<i>e</i>	<i>j</i>			
1,65	6	3:59.9	162	839
1,96	6	2:42.5	146	560
2,33	6	2:51.8	140	543
2,58	6	3:52.3	141	505
2,81	6	3:04.7	128	482
3,09	6	3:06.2	130	483
3,29	6	3:00.8	129	490
3,48	6	3:03.0	135	500
3,72	6	3:05.1	129	487
3,89	6	3:17.0	129	480
4,06	6	3:09.9	131	510
4,27	6	3:09.0	134	522
4,42	6	3:07.6	131	514
4,57	6	3:07.9	125	503
4,77	6	3:08.1	130	502
4,91	6	3:09.3	134	519

TABELA 8.7 - TEMPO DE PROCESSAMENTO E NÚMERO DE CLASSES E DE SEGMENTOS OBTIDOS COM $J=8$

Parâmetros		Tempo	Classes	Segmentos
<i>e</i>	<i>j</i>			
1,65	8	9:11.6	145	594
1,96	8	5:49.5	120	355
2,33	8	6:27.7	116	331
2,58	8	6:31.6	117	305
2,81	8	6:50.2	101	264
3,09	8	6:50.0	107	289
3,29	8	7:02.6	106	289
3,48	8	6:55.8	100	299
3,72	8	7:09.7	101	299
3,89	8	7:02.7	100	295
4,06	8	7:16.0	101	312
4,27	8	7:03.2	101	314
4,42	8	7:17.9	96	308
4,57	8	7:05.0	101	307
4,77	8	7:16.8	101	311
4,91	8	7:06.7	105	320

TABELA 8.8 - TEMPO DE PROCESSAMENTO E NÚMERO DE CLASSES E DE SEGMENTOS OBTIDOS COM $J=10$

Parâmetros		Tempo	Classes	Segmentos
e	j			
1,65	10	8:52.9	128	456
1,96	10	6:02.7	96	232
2,33	10	6:31.7	99	217
2,58	10	6:45.4	99	197
2,81	10	6:52.2	86	171
3,09	10	7:23.9	87	184
3,29	10	8:17.1	90	187
3,48	10	6:54.2	87	189
3,72	10	6:01.6	86	185
3,89	10	6:39.7	87	185
4,06	10	7:03.5	82	186
4,27	10	7:20.8	83	185
4,42	10	6:40.2	79	181
4,57	10	6:42.9	82	183
4,77	10	5:58.7	83	185
4,91	10	6:54.2	87	193

Das Tabelas 8.3 a 8.8 verificou-se que o número de classes e de segmentos, para um dado valor do parâmetro j , tendeu a diminuir suavemente à medida que o valor do parâmetro e foi aumentado. A redução do número de classes, dado o aumento de j , foi mais evidente que dado o aumento de e . Este resultado pode ser entendido a partir da análise da estrutura do algoritmo. O valor do parâmetro e define a probabilidade de detecção de bordas (em termos de números de desvio padrão), que é equivalente a uma certa probabilidade de falso alarme. Por exemplo, o valor de e igual a 1,65 é equivalente a uma probabilidade de falso alarme de 0,1 enquanto que o valor de e igual a 2,33 é equivalente a uma probabilidade de falso alarme de 0,02. Deste modo, o aumento do valor de e diminui a probabilidade de falso alarme ocasionando uma diminuição do número de bordas criadas e resultando em segmentações com menor número de classes e de segmentos.

Para um dado valor de e , o número de classes distintas e o número total de segmentos diminuiu à medida que o valor do parâmetro j foi aumentado. O valor do parâmetro j define a probabilidade de agrupamento de regiões (em termos de números de desvio

padrão). Desta forma, quanto maior seu valor, maior a probabilidade de duas regiões vizinhas serem da mesma classe (provindas de um mesmo retroespalhamento) e consequentemente agrupadas, resultando em segmentações com menor número de classes e de segmentos.

Considerando-se a segmentação de referência (9 classes distintas e 36 segmentos), todos os valores de e e j produziram segmentações com excessivo número de classes e principalmente de segmentos, até mesmo as obtidas com valores elevados destes parâmetros.

O tempo de processamento requerido para produzir as segmentações foi praticamente o mesmo para todos os valores de e e um mesmo valor de j . Entretanto, o aumento do valor atribuído ao parâmetro j , para um mesmo valor de e , tendeu a aumentar o tempo de processamento requerido, principalmente para valores mais elevados.

Considerando-se os resultados da avaliação qualitativa e quantitativa da qualidade de todas as segmentações da imagem simulada 3 *looks* produzidas pelo RWSEG, a obtida com e igual a 2,58 e j igual a 2 foi eleita como a mais representativa da verdadeira (referência).

8.1.3 – EXPERIMENTO MONTE CARLO

Uma vez determinados os melhores parâmetros para o MUM ($p=5$) e para o RWSEG ($e=2,58$ e $j=2$) efetuou-se o experimento Monte Carlo para obter os resultados que permitiram comparar os dois algoritmos do ponto de vista da qualidade das segmentações produzidas e da capacidade de segmentar regiões com diferentes graus de homogeneidade.

O experimento Monte Carlo consistiu em segmentar as 100 imagens replicadas de 3 *looks* a partir do MUM com $p=5$ e do RWSEG com $e=2,58$ e $j=2$. Em seguida calculou-se os valores de Fit_{xy} , Fit_i , Fit_n , $Gforma$ e média geral ($\hat{\mu}_g$) para cada uma das 100 segmentações produzidas por cada algoritmo. Ao final, obteve-se a média ($\hat{\mu}_e$) e a

variância ($\hat{\sigma}_e^2$) amostrais dos valores de $Fitxy$, $Fiti$, $Fitn$, $Gforma$ e $\hat{\mu}_g$ obtidos em todas as segmentações produzidas por cada algoritmo.

Os valores de $Fitxy$, $Fiti$, $Fitn$, $Gforma$ e média geral ($\hat{\mu}_g$) obtidos em cada uma das 100 segmentações produzidas pelo MUM e pelo RWSEG são apresentados, respectivamente, nas Figuras 8.9, 8.10, 8.11, 8.12 e 8.13.

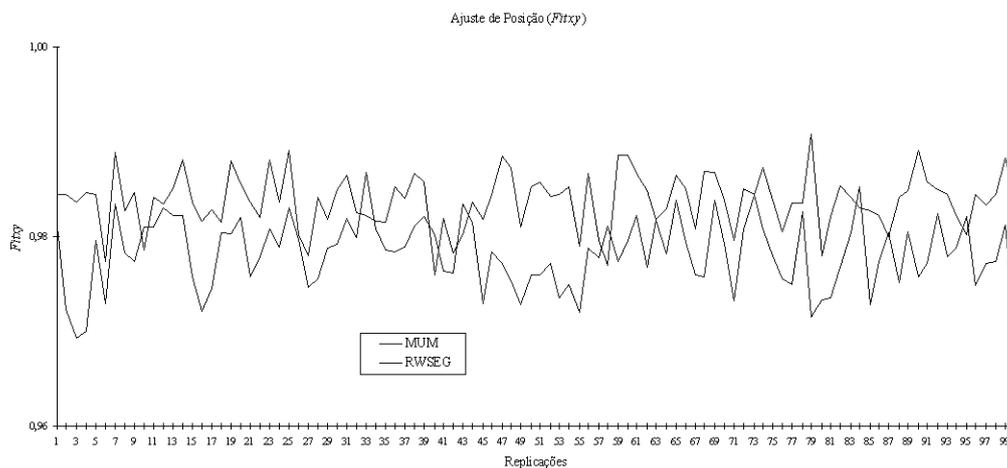


Fig.8.9 - Valores do ajuste de posição obtidos em cada segmentação produzida pelo MUM e pelo RWSEG no experimento Monte Carlo.

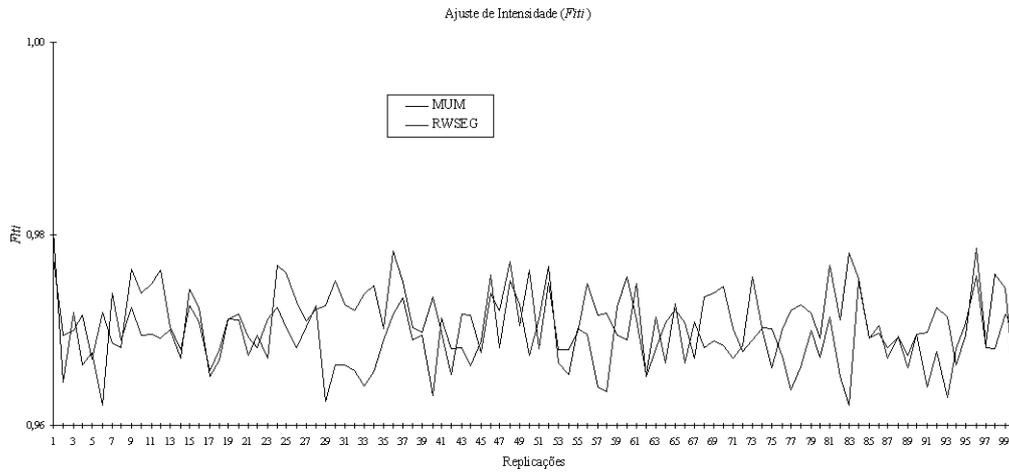


Fig.8.10 - Valores do ajuste de intensidade média obtidos em cada segmentação produzida pelo MUM e pelo RWSEG no experimento Monte Carlo.

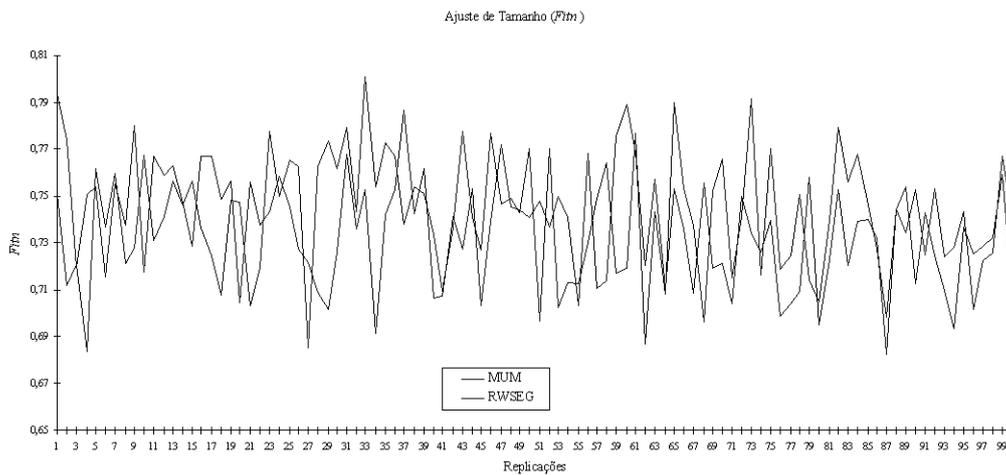


Fig.8.11 - Valores do ajuste de tamanho obtidos em cada segmentação produzida pelo MUM e pelo RWSEG no experimento Monte Carlo.

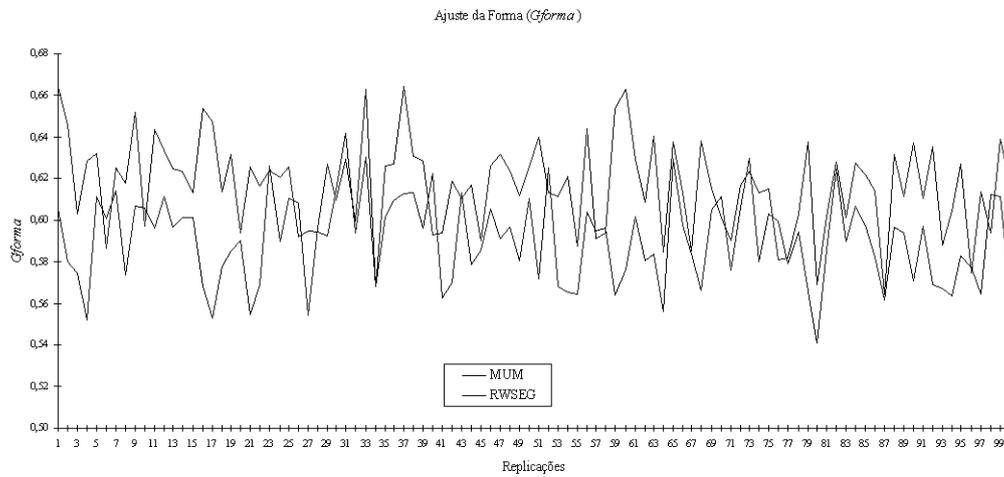


Fig.8.12 - Valores do ajuste da forma obtidos em cada segmentação produzida pelo MUM e pelo RWSEG no experimento Monte Carlo.

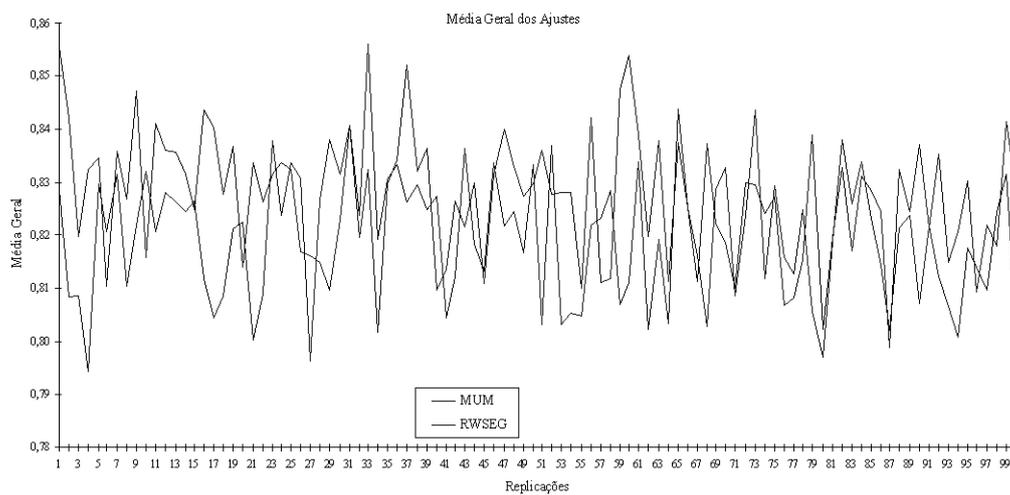


Fig.8.13 - Valores da média geral obtida em cada segmentação produzida pelo MUM e pelo RWSEG no experimento Monte Carlo.

A média ($\hat{\mu}_e$) e a variância ($\hat{\sigma}_e^2$) amostrais dos valores de *Fitxy*, *Fiti*, *Fitn*, *Gforma* e $\hat{\mu}_g$ obtidos em todas as segmentações produzidas pelo MUM e pelo RWSEG são apresentadas na Tabela 8.9.

TABELA 8.9 - MÉDIA E VARIÂNCIA AMOSTRAIS DAS MEDIDAS DE AJUSTE OBTIDAS NO EXPERIMENTO MONTE CARLO

	MUM		RWSEG	
	$\hat{\mu}_e$	$\hat{\sigma}_e^2$	$\hat{\mu}_e$	$\hat{\sigma}_e^2$
<i>Fitxy</i>	0,98377	0,000009	0,97819	0,000013
<i>Fiti</i>	0,96903	0,000012	0,97124	0,000011
<i>Fitn</i>	0,73799	0,000554	0,73986	0,000672
<i>Gforma</i>	0,61625	0,000475	0,59092	0,000479
$\hat{\mu}_g$	0,82676	0,000142	0,82007	0,000153

Da análise das Figuras 8.9 a 8.12 e a partir de testes estatísticos efetuados utilizando-se os valores apresentados na Tabela 8.9, concluiu-se que com relação ao ajuste de posição e forma, as segmentações produzidas pelo MUM obtiveram médias amostrais maiores, ao nível de significância de 1%, que as obtidas pelo RWSEG. A supremacia do MUM sobre o RWSEG no tocante a estes ajustes pode ser facilmente observada a partir das Figuras 8.14 e 8.17 respectivamente. As médias amostrais do ajuste de tamanho foram estatisticamente iguais ao nível de significância de 5% (Figura 8.16). A média amostral do ajuste de intensidade média das segmentações produzidas pelo RWSEG foi maior que à obtida pelo MUM ao nível de significância de 1% (Figura 8.15).

Da Figura 8.13 verificou-se que para a maioria das replicações o MUM produziu segmentações com maior média geral que as produzidas pelo RWSEG. Da Tabela 8.9

verificou-se que a média amostral das médias gerais obtidas nas segmentações produzidas pelo MUM foi superior à obtida pelo RWSEG ao nível de significância de 1% (Figura 8.18).

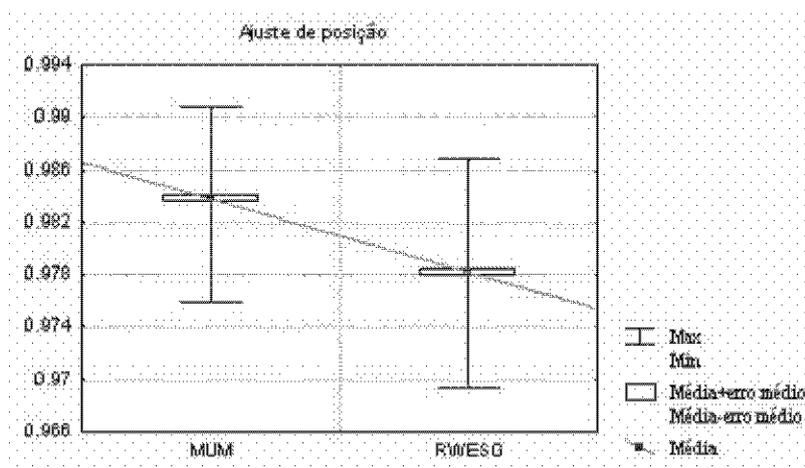


Fig.8.14 - Comparação das médias amostrais do ajuste de posição obtidas pelo MUM e pelo RWSEG no experimento Monte Carlo.

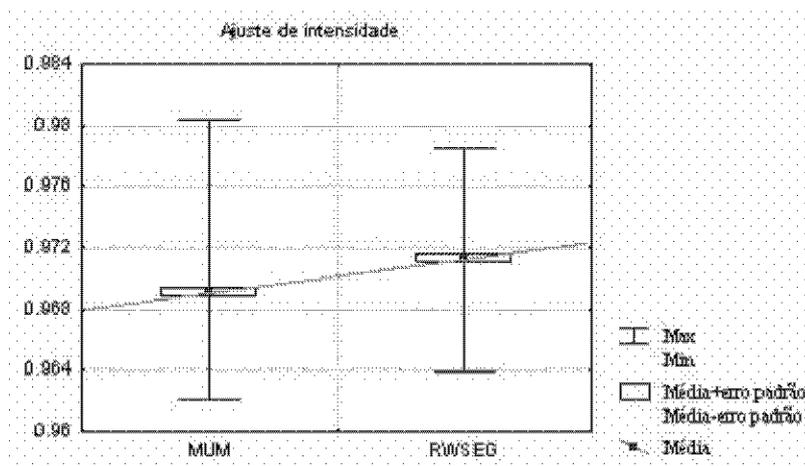


Fig.8.15 - Comparação das médias amostrais do ajuste de intensidade obtidas pelo MUM e pelo RWSEG no experimento Monte Carlo.

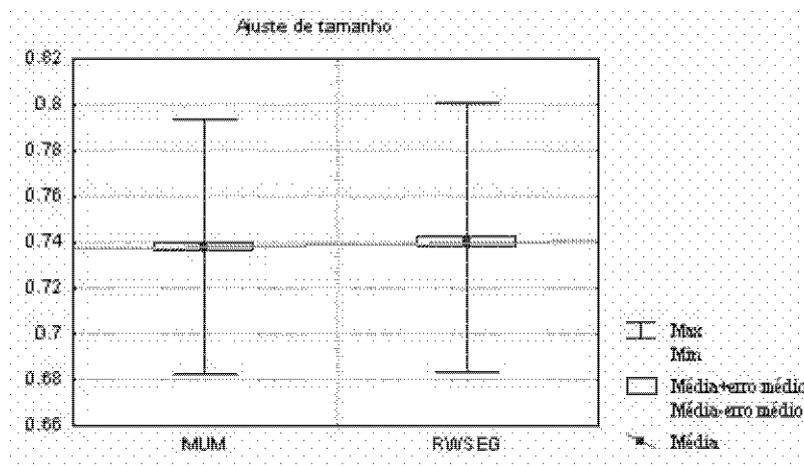


Fig.8.16 - Comparação das médias amostrais do ajuste de tamanho obtidas pelo MUM e pelo RWSEG no experimento Monte Carlo.

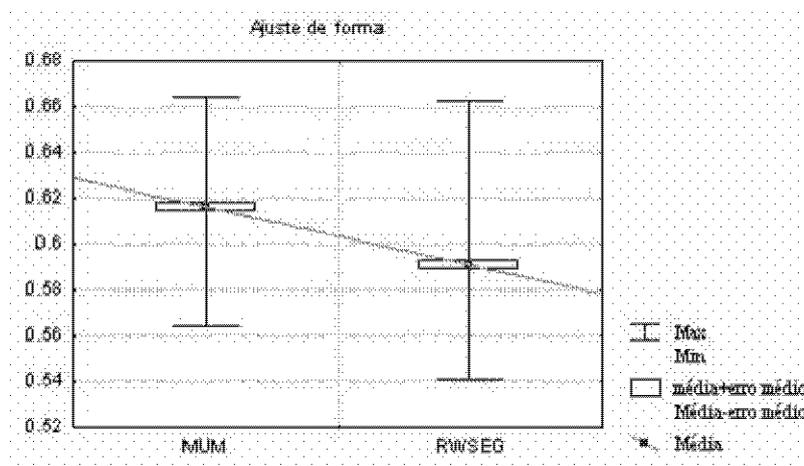


Fig.8.17 - Comparação das médias amostrais do ajuste de forma obtidas pelo MUM e pelo RWSEG no experimento Monte Carlo.

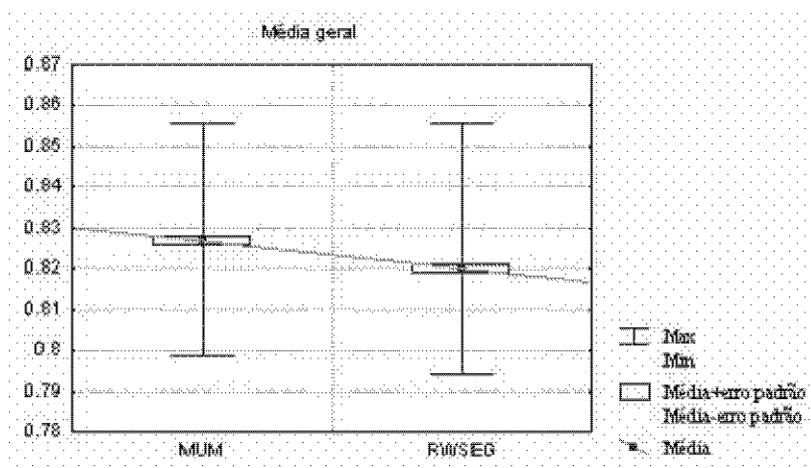


Fig.8.18 - Comparação das médias amostrais da média geral obtidas pelo MUM e pelo RWSEG no experimento Monte Carlo.

A média e variância amostrais das medidas de ajuste obtidas pelo MUM e pelo RWSEG no experimento Monte Carlo em função do tipo de região estão listadas, respectivamente, nas Tabelas 8.10 e 8.11.

TABELA 8.10 – MÉDIA E VARIÂNCIA AMOSTRAIS DAS MEDIDAS DE AJUSTE OBTIDAS PELO MUM EM FUNÇÃO DO TIPO DE REGIÃO

	Homogêneas		Heterogêneas		Ext. Heterogêneas	
	$\hat{\mu}_e$	$\hat{\sigma}_e^2$	$\hat{\mu}_e$	$\hat{\sigma}_e^2$	$\hat{\mu}_e$	$\hat{\sigma}_e^2$
<i>Fitxy</i>	0,9887	0,000015	0,9687	0,000052	0,9987	0,000001
<i>Fiti</i>	0,9690	0,000023	0,9637	0,000051	0,9831	0,000011
<i>Fitn</i>	0,7283	0,001104	0,6724	0,000935	0,9687	0,000195
<i>Gforma</i>	0,6292	0,000839	0,4916	0,000788	0,8905	0,000570
$\hat{\mu}_g$	0,8288	0,000123	0,7741	0,000114	0,9602	0,000048

TABELA 8.11 – MÉDIA E VARIÂNCIA AMOSTRAIS E GLOBAL DAS MEDIDAS DE AJUSTE OBTIDAS PELO RWSEG EM FUNÇÃO DO TIPO DE REGIÃO

	Homogêneas		Heterogêneas		Ext. Heterogêneas	
	$\hat{\mu}_e$	$\hat{\sigma}_e^2$	$\hat{\mu}_e$	$\hat{\sigma}_e^2$	$\hat{\mu}_e$	$\hat{\sigma}_e^2$
<i>Fitxy</i>	0,9851	0,000017	0,9606	0,000063	0,9896	0,000022
<i>Fiti</i>	0,9699	0,000016	0,9678	0,000073	0,9873	0,000008
<i>Fitn</i>	0,7730	0,001448	0,6350	0,002584	0,8540	0,002109
<i>Gforma</i>	0,6339	0,000950	0,4606	0,001757	0,7231	0,003229
$\hat{\mu}_g$	0,8405	0,000157	0,7560	0,000279	0,8885	0,000335

Das Tabelas 8.10 e 8.11 verificou-se que, do ponto de vista quantitativo, os dois algoritmos segmentaram os três tipos de regiões com boa correção de posição e intensidade média. Entretanto, tanto o MUM quanto o RWSEG tiveram menos sucesso para segmentar corretamente os três tipos de regiões em termos de tamanho e principalmente da forma. Neste aspecto o desempenho dos dois algoritmos foi diferenciado para as três regiões, sendo melhor para as regiões extremamente heterogêneas e pior para as heterogêneas, as quais apresentaram grande incorreção em termos de forma.

Utilizando-se os valores apresentados na Tabela 8.10, foram efetuados testes estatísticos e concluiu-se que a segmentação das regiões extremamente heterogêneas produzidas pelo MUM foi mais correta que as das homogêneas e heterogêneas em termos de posição, intensidade média, tamanho e forma ao nível de significância de 1%. A segmentação das regiões homogêneas foi mais correta que as das heterogêneas em termos de posição e forma ao nível de significância de 1%, mais correta em termos de tamanho ao nível de significância de 5% e estatisticamente igual em termos de

intensidade média ao nível de significância de 5%. Estes resultados podem ser visualizados a partir da Figura 8.19.

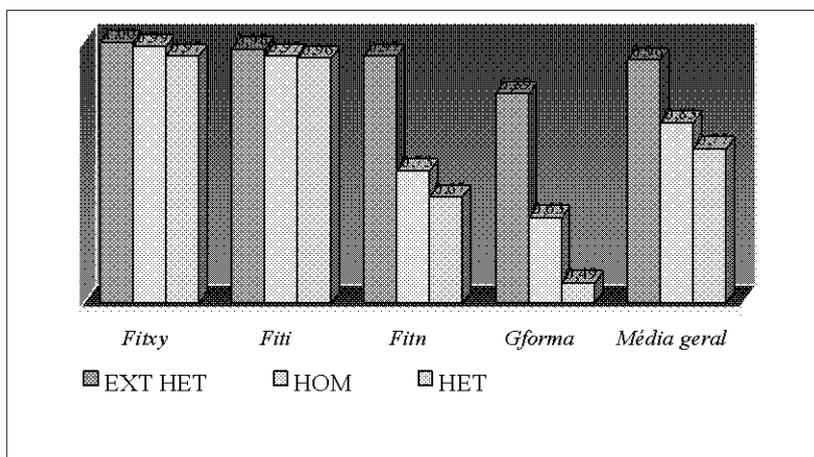


Fig.8.19 - Comparação das médias amostrais das medidas de ajuste obtidas pelo MUM em função do tipo de região.

Utilizando-se os valores apresentados na Tabela 8.11, foram efetuados testes estatísticos e concluiu-se que a segmentação das regiões extremamente heterogêneas produzidas pelo RWSEG foi mais correta que as das heterogêneas em termos de posição, intensidade média, tamanho e forma ao nível de significância de 1%. Também foi mais correta que as das homogêneas em termos de forma (significância de 1%), tamanho e intensidade média (significância de 5%), mas estatisticamente igual em termos de posição ao nível de significância de 5%. A segmentação das regiões homogêneas foi mais correta que as das heterogêneas em termos de posição, tamanho e forma ao nível de significância de 1% e estatisticamente igual em termos de intensidade média ao nível de significância de 5%. Estes resultados podem ser visualizados a partir da Figura 8.20.

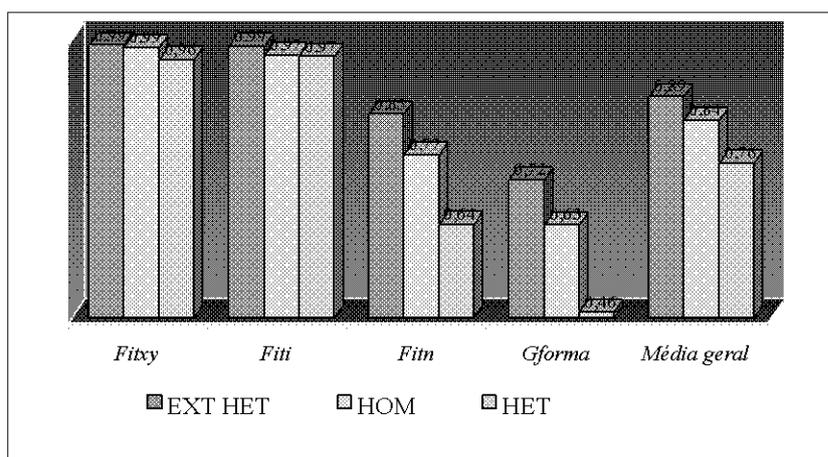


Fig.8.20 - Comparação das médias amostrais das medidas de ajuste obtidas pelo RWSEG em função do tipo de região.

Do ponto de vista da média geral, os dois algoritmos apresentaram boa capacidade para segmentar os três tipos de regiões. Esta média, tanto para o MUM quanto para o RWSEG foi maior, respectivamente, para as regiões extremamente heterogêneas, homogêneas e heterogêneas, ao nível de significância de 1%.

Cabe aqui questionar porque os dois algoritmos tiveram melhor desempenho quantitativo para segmentar as regiões extremamente heterogêneas que para as homogêneas, se os mesmos foram desenvolvidos sob hipóteses distribucionais aplicáveis somente para regiões homogêneas. Uma possível explicação é que todas as regiões extremamente heterogêneas das imagens simuladas possuem valores médios de intensidade bem diferenciado dos das regiões vizinhas. Essa diferença (contraste) pode ser verificada a partir das Figuras 7.8 e 7.9, apresentadas no Capítulo 7. O fato do MUM e do RWSEG utilizarem testes estatísticos baseados na comparação entre as médias dos valores de intensidade de regiões vizinhas possibilita uma maior precisão no processo de localização de bordas entre regiões de maior contraste, onde a diferença entre estas médias é maior.

Por outro lado, um indicativo do desempenho dos algoritmos para segmentar regiões homogêneas pode ser verificado a partir da análise das Figuras 8.1, 8.2, 8.4 e 8.5. Das

Figuras 8.1 e 8.2 observou-se que o MUM segmentou com boa correção as regiões homogêneas, tanto de alto quanto de baixo contraste, mesmo com os menores valores de p (onde a probabilidade de duas regiões vizinhas terem médias iguais é menor). A mesma observação pode ser feita para as regiões extremamente heterogêneas. No entanto, nas segmentações obtidas com valores de p maiores, as regiões homogêneas de baixo contraste foram agrupadas com regiões vizinhas, mas as de maior contraste sofreram pouca variação, como o observado para as regiões extremamente heterogêneas.

Da Figura 8.4 observou-se que nas segmentações obtidas pelo RWSEG, as regiões homogêneas de baixo e alto contraste foram segmentadas com certa correção com e igual a 2,58, ao passo que as extremamente heterogêneas só atingem o mesmo grau de correção com e igual a 4,06. Da Figura 8.5 observou-se que as regiões homogêneas de baixo contraste foram agrupadas com regiões vizinhas em função do aumento do valor do parâmetro j , o qual controla o crescimento de regiões a partir da comparação dos valores de intensidade média de regiões vizinhas. No entanto as homogêneas de maior contraste variaram muito pouco e as extremamente heterogêneas puderam ser identificadas com um menor valor do parâmetro e .

O fato dos dois algoritmos segmentarem primeiro as regiões homogêneas de baixo contraste que as extremamente heterogêneas (alto contraste) à medida que os valores dos seus respectivos parâmetros foram aumentados, pode ser um indicativo da melhor capacidade dos mesmos para segmentar regiões homogêneas. Entretanto, o contraste entre uma dada região e sua vizinhança pode ter maior influência que o seu grau de homogeneidade no desempenho dos dois algoritmos em segmentá-la.

As Figuras 8.21 a 8.23 ilustram o desempenho comparativo entre os dois algoritmos para cada um dos graus de homogeneidade em termos das médias amostrais das medidas de ajuste e média geral.

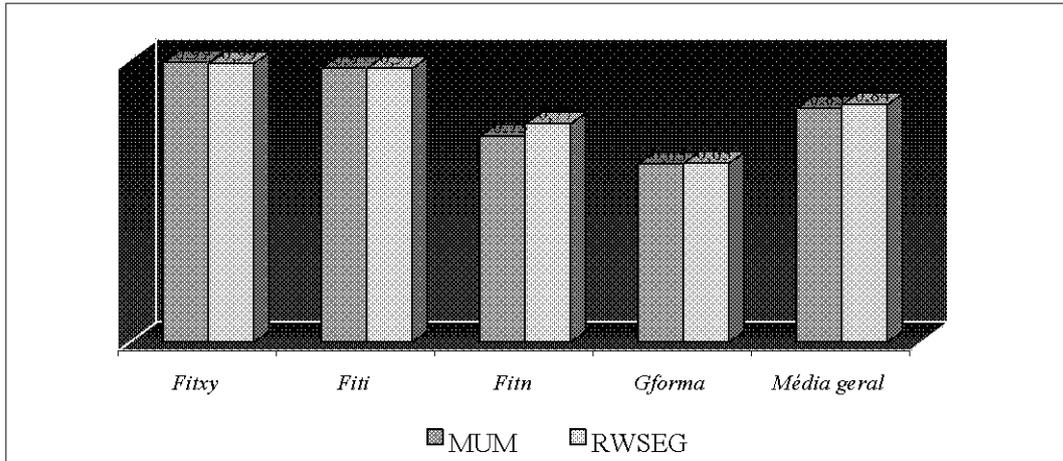


Fig.8.21 - Comparação das médias amostrais das medidas de ajuste e média geral obtidas pelo MUM e pelo RWSEG para regiões homogêneas.

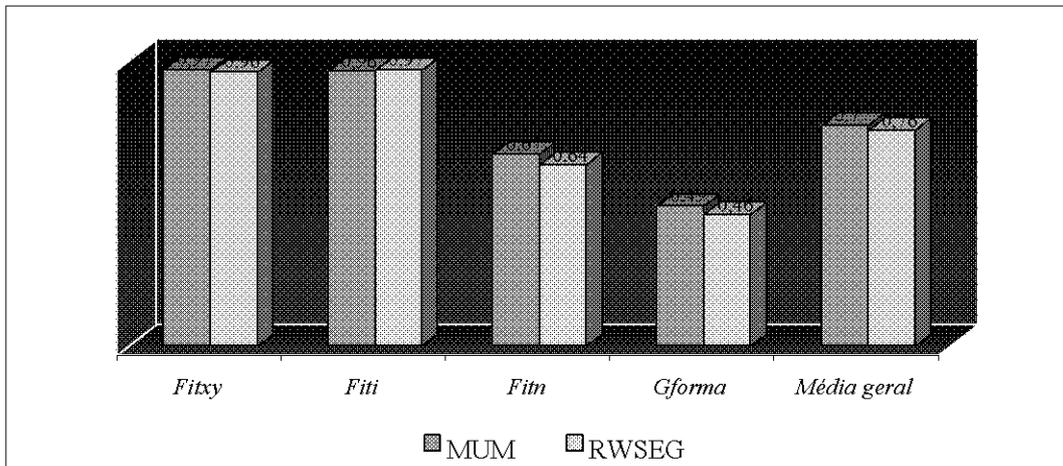


Fig.8.22 - Comparação das médias amostrais das medidas de ajuste e média geral obtidas pelo MUM e pelo RWSEG para regiões heterogêneas.

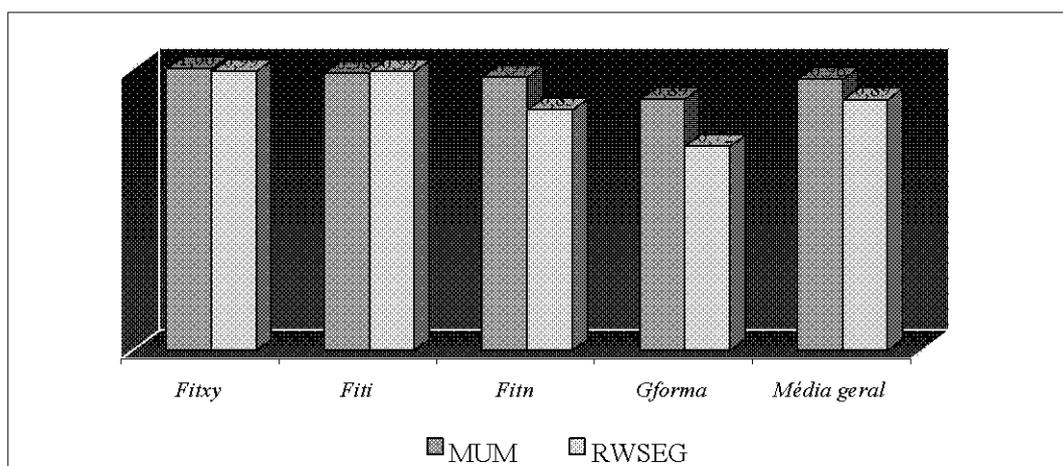


Fig.8.23 - Comparação das médias amostrais das medidas de ajuste e média geral obtidas pelo MUM e pelo RWSEG para regiões extremamente heterogêneas.

Das Figuras 8.21 a 8.23 observa-se que comparativamente, o MUM e o RWSEG tiveram o mesmo desempenho para segmentar regiões homogêneas e heterogêneas em termos de posição, intensidade média, tamanho e forma ao nível de significância de 5%. A segmentação das regiões extremamente heterogêneas produzidas pelo MUM foi mais correta em termos de forma, tamanho e posição ao nível de significância de 1% e estatisticamente igual em termos intensidade média ao nível de significância de 5%.

A média geral obtida pelo MUM foi maior que a do RWSEG para as regiões extremamente heterogêneas e heterogêneas ao nível de significância de 1%. Para as regiões homogêneas, a obtida pelo RWSEG foi maior que a do MUM ao nível de significância de 1%.

Para avaliar os resultados obtidos do experimento Monte Carlo, analisou-se visualmente as segmentações de uma única imagem simulada de 3 *looks* obtidas pelo MUM e pelo RWSEG. As segmentações utilizadas foram as obtidas da imagem simulada utilizada para determinar os valores dos parâmetros de cada algoritmo empregados no experimento Monte Carlo e eleitas como mais representativa da verdadeira, ou seja, a

obtida pelo MUM com p igual a 5 e a obtida pelo RWSEG com e igual a 2,58 e j igual a 2.

A Figura 8.24 apresenta a segmentação de referência, o *phantom* e as segmentações eleitas como mais representativas da verdadeira obtidas pelo MUM e pelo RWSEG para uma única imagem.

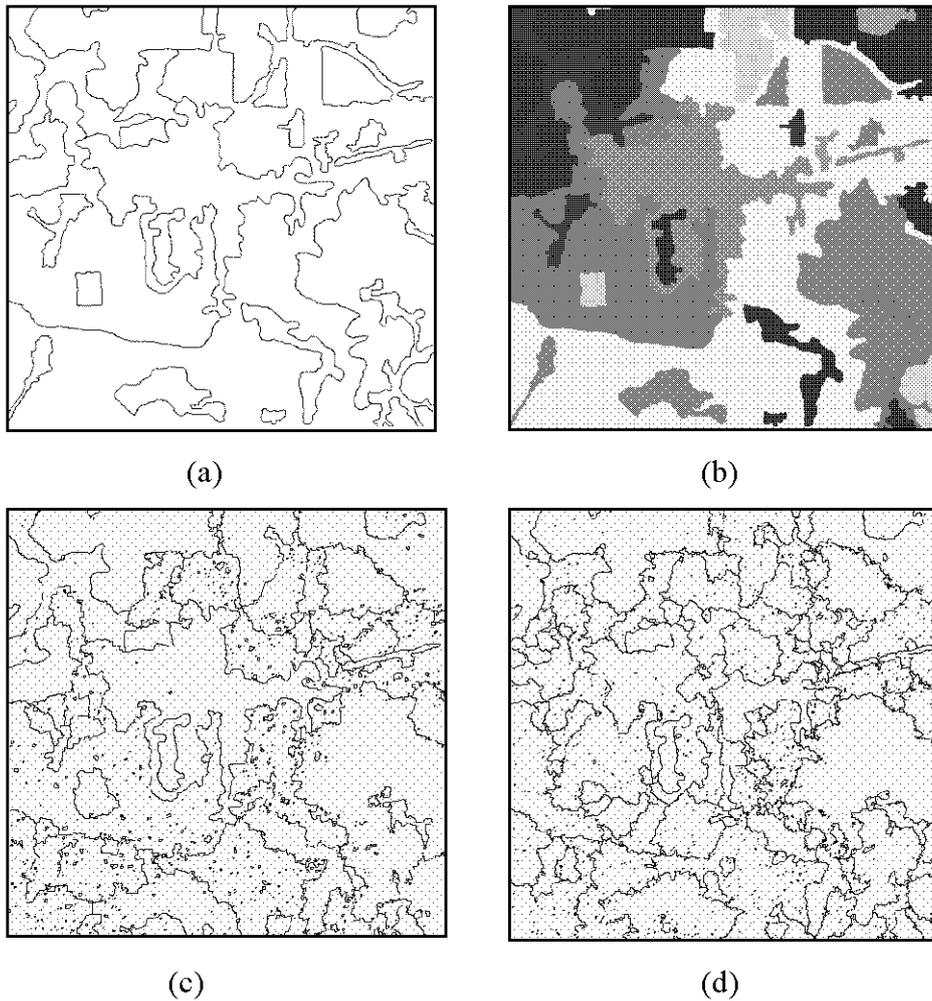


Fig. 8.24 - Segmentação manual (a), *phantom* (b) e segmentações da imagem 3 *looks* produzidas pelo MUM com $p=5$ (c) e RWSEG com $e=2,58$ e $j=2$ (d).

Da Figura 8.24 verificou-se visualmente que o MUM segmentou com boa correção as regiões extremamente heterogêneas (cores vermelha e magenta) e homogêneas (cores azul, azul claro e cyan) em termos de forma, tamanho e posição. As heterogêneas (cores marrom escuro, claro e amarela) foram subdivididas em regiões menores e com elevado número de microsegmentos internos.

O RWSEG segmentou as regiões homogêneas extensas com boa correção de posição e tamanho. As regiões extremamente heterogêneas e as heterogêneas foram particionadas

em regiões menores e, no caso das heterogêneas, tal partição foi consideravelmente mais acentuada e com elevado número de microsegmentos.

Da comparação entre as segmentações produzidas pelos algoritmos com a segmentação de referência verificou-se que, do ponto de vista qualitativo, os dois algoritmos foram mais eficazes para segmentar regiões homogêneas e extremamente heterogêneas e mais deficientes para segmentar as heterogêneas, confirmando a análise quantitativa dos valores contidos nas Tabelas 8.10 e 8.11. A acentuada subdivisão das regiões heterogêneas, tanto na segmentação obtida pelo MUM quanto na obtida pelo RWSEG justifica o baixo desempenho quantitativo em termos de tamanho e forma observado para este tipo de região no experimento Monte Carlo.

O tempo de processamento médio requerido pelo MUM foi de 35 minutos e o do RWSEG foi de 4 minutos. O custo computacional requerido pelo RWSEG para segmentar as imagens de entrada foi em média 11,45% do requerido pelo MUM.

8.2 - RESULTADOS OBTIDOS A PARTIR DA IMAGEM SIMULADA DE 8 LOOKS

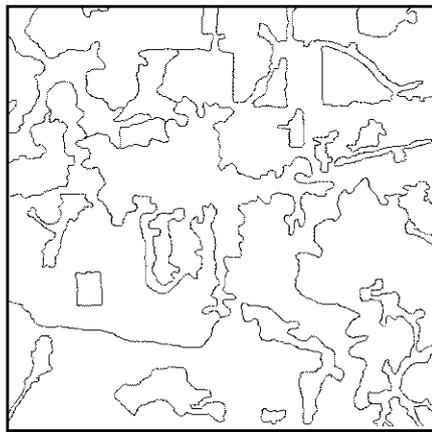
8.2.1 - RESULTADOS OBTIDOS PELO MUM

8.2.1.1 - AVALIAÇÃO QUALITATIVA

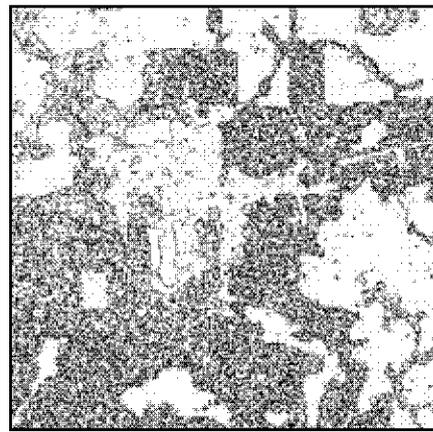
A influência do valor do parâmetro p selecionado nas segmentações produzidas, no tocante ao grau de subdivisão, foi a mesma observada para a imagem de 3 *looks*. A Figura 8.25 apresenta a segmentação manual (referência) da imagem simulada 8 *looks* e as segmentações (apresentadas na forma de mapa de bordas) da mesma imagem produzidas pelo MUM com valores de p iguais a 1, 6, 10, 13 e 17.

Do ponto de vista da aplicação definida e da segmentação verdadeira (referência) proposta, as segmentações produzidas com valores do parâmetro p iguais a 1, 2, 3, 4 e 5

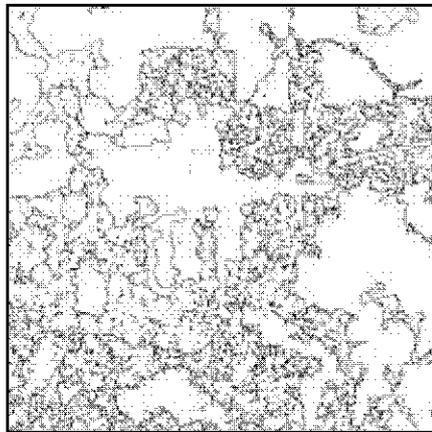
apresentaram-se extremamente segmentadas, enquanto que as com valores superiores a 13 apresentaram-se subsegmentadas. Desta forma, as segmentações qualitativamente satisfatórias foram obtidas com os valores de p entre 6 e 12. A Figura 8.26 apresenta as segmentações produzidas com valores do parâmetro p iguais a 7, 8, 9, 11 e 12.



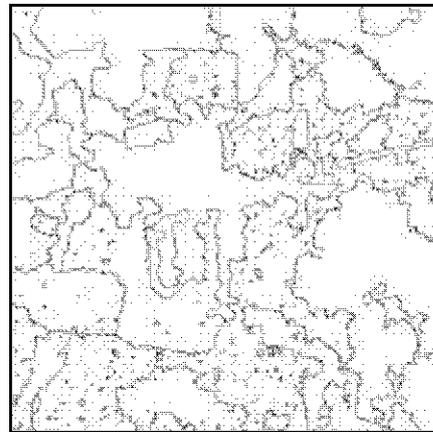
(a)



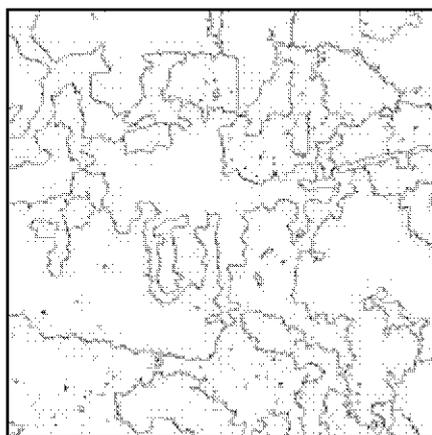
(b)



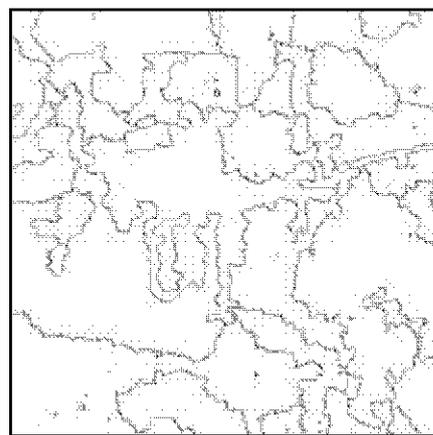
(c)



(d)

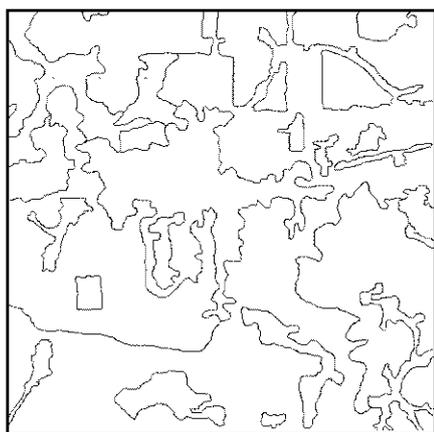


(e)

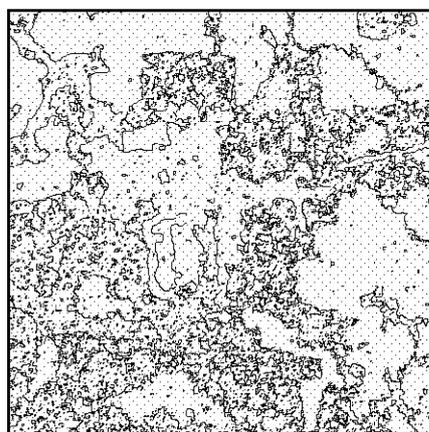


(f)

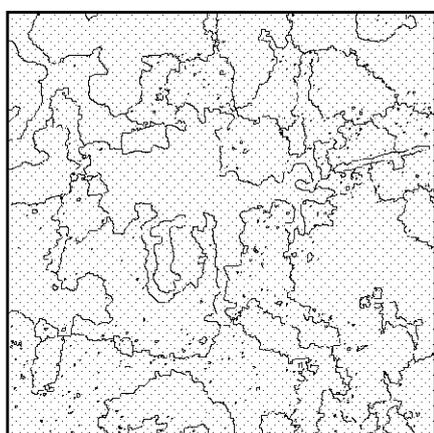
Fig. 8.25 - Segmentação manual (a) e segmentações da imagem 8 *looks* produzidas pelo MUM com $p=3$ (b), $p=6$ (c), $p=10$ (d), $p=13$ (e) e $p=17$ (f).



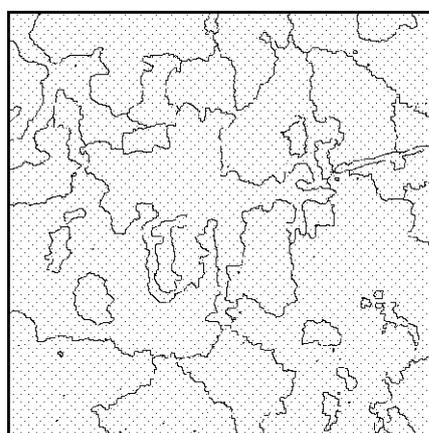
(a)



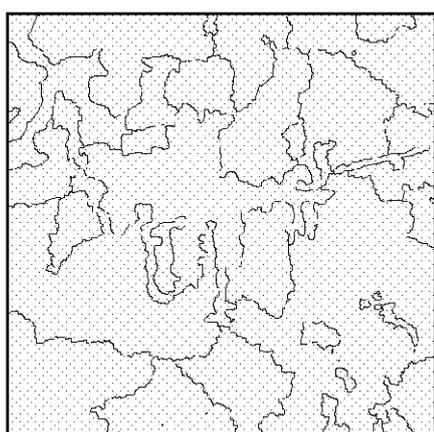
(b)



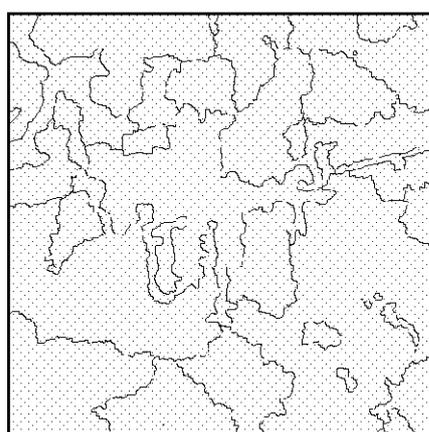
(c)



(d)



(e)



(f)

Fig. 8.26 - Segmentação manual (a) e segmentações da imagem 8 *looks* produzidas pelo MUM com $p=7$ (b), $p=8$ (c), $p=9$ (d), $p=11$ (e) e $p=12$ (f).

8.2.1.2 - AVALIAÇÃO QUANTITATIVA

A Figura 8.27 apresenta as médias gerais ($\hat{\mu}_g$) obtidas em cada uma das segmentações da imagem simulada 8 *looks* em função do valor do parâmetro p selecionado.

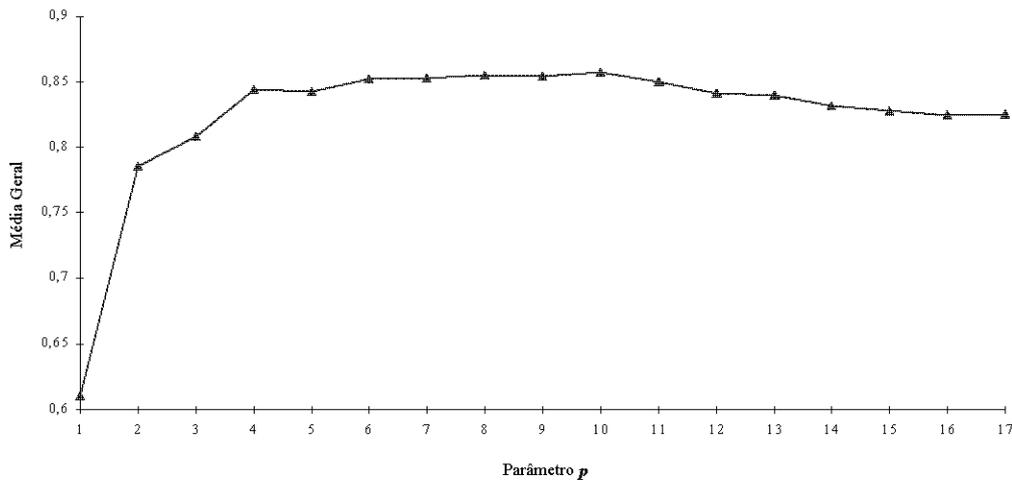


Fig. 8.27 - Média geral das segmentações da imagem de 8 *looks* produzidas pelo MUM

Da Figura 8.27 verificou-se que a segmentação com maior média geral foi obtida com p igual a 10 ($\hat{\mu}_g = 0,8576$). Pode-se observar também que a maioria das segmentações tiveram média geral compreendida entre 0,80 e 0,85, isto é, com bons resultados quantitativos. Valores de p compreendidos no intervalo de 6 a 10 produziram as segmentações com maiores médias gerais.

O tempo de processamento (yymin:zz.zs) e o número de classes e de segmentos obtidos nas segmentações produzidas pelo MUM para cada valor de p estão contidos na Tabela 8.12.

TABELA 8.12 - TEMPO DE PROCESSAMENTO E NÚMERO DE CLASSES E DE SEGMENTOS OBTIDOS

<i>p</i>	Tempo	Classes	Segmentos
1	4:47.6	230	43422
2	17:58.9	229	20139
3	23:25.1	231	12020
4	25:11.8	222	8069
5	25:27.8	211	5448
6	30:31.1	202	3644
7	32:57.9	192	2373
8	37:52.3	186	1618
9	34:51.8	176	1051
10	34:27.8	163	719
11	34:11.7	151	520
12	35:22.2	141	367
13	36:56.9	129	276
14	36:09.7	104	204
15	37:41.9	89	149
16	37:22.8	83	134
17	38:41.9	73	110

Da Tabela 8.12 observou-se que o tempo de processamento requerido para produzir as segmentações tendeu a aumentar proporcionalmente com o valor atribuído ao parâmetro p . O número de classes distintas e o número total de segmentos diminuiu à medida que o valor do parâmetro p foi aumentado. Considerando-se a segmentação de referência (9 classes distintas e 36 segmentos), todos os valores de p produziram segmentações com excessivo número de classes e de segmentos.

Considerando-se os resultados das avaliações qualitativa e quantitativa da qualidade de todas as segmentações da imagem simulada 8 *looks* produzidas pelo MUM, a obtida com p igual a 10 foi eleita como a mais representativa da verdadeira.

Comparativamente ao valor de p obtido para a imagem de 3 *looks* ($p = 5$), o obtido para a imagem de 8 *looks* foi maior. Uma possível explicação para este resultado se deve ao fato das variâncias dos dados da imagem de 8 *looks* serem menores que as das de três. Deste modo, espera-se que o valor da estatística t (descrita no Capítulo 5) obtida para a imagem de 3 *looks* seja menor que a obtida para a de 8 *looks*. Assim, para se obter

segmentações com aproximadamente o mesmo número de segmentos destas duas imagens, a probabilidade selecionada para aceitar a hipótese de igualdade das médias na imagem de 3 *looks* seja maior, a qual é obtida com um valor menor de p .

8.2.2 - RESULTADOS OBTIDOS PELO RWSEG

8.2.2.1 - AVALIAÇÃO QUALITATIVA

A partir da comparação visual das 96 segmentações da imagem simulada 8 *looks* produzidas pelo RWSEG com a segmentação de referência, observou-se que as segmentações produzidas com valores de j igual a zero apresentaram-se subsegmentadas para valores do parâmetro e superiores a 3,89 e supersegmentadas para os inferiores a 3,29. As produzidas com valores de j iguais a 6, 8 e 10 apresentaram-se subsegmentadas para os valores do parâmetro e superiores a 2,81. Os valores do parâmetro j que produziram segmentações qualitativamente mais satisfatórias foram o 2 e o 4, a exemplo do ocorrido para as imagens de 3 *looks*.

A influência do valor atribuído ao parâmetro j pode ser verificada a partir das Figuras 8.28 e 8.29, as quais apresentam o mapa de bordas da segmentação de referência e das segmentações da imagem simulada de 8 *looks* produzidas pelo RWSEG com valores de e iguais a 1,65, 2,58, 3,29, 4,06 e 4,91 e, respectivamente, com valores de j igual a 0 e 8. Os valores de e apresentados representam uma amostragem dos 16 utilizados e compreende os valores máximo, mínimo e três intermediários.

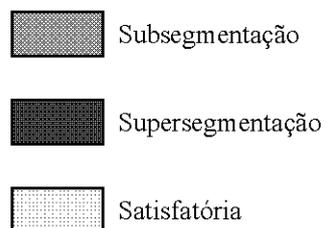
A partir das Figuras 8.28 e 8.29, verificou-se, a exemplo do observado nos resultados da imagem 3 *looks*, que para um mesmo valor do parâmetro e , o aumento do valor atribuído ao parâmetro j ocasionou a diminuição do número total de segmentos. Também foi possível verificar que o aumento do valor atribuído ao parâmetro e , para um dado j , produziu o mesmo efeito. As segmentações produzidas com valores de e iguais a 1,65 e 1,96 apresentaram-se extremamente segmentadas para todos os valores de j . As produzidas com valores de e iguais a 2,33, 2,58 e 2,81 apresentaram-se subsegmentadas

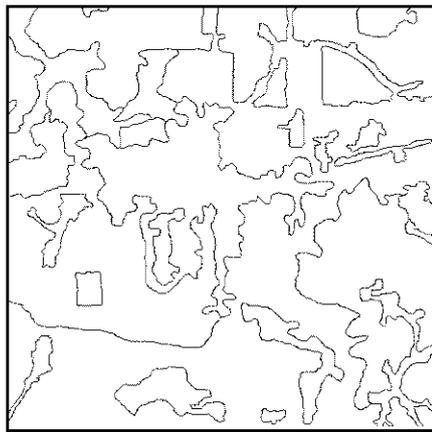
para valores de j iguais a 8 e 10. As produzidas com valores de e igual ou superiores a 3,48 apresentaram-se no geral subsegmentadas para todos os valores de j . Os valores do parâmetro e que produziram segmentações qualitativamente mais satisfatórias foram os iguais a 2,33, 2,58, 2,81, 3,09 e 3,29.

As segmentações obtidas a partir dos subconjuntos de valores dos parâmetros e e j que produziram segmentações qualitativamente mais satisfatórias do ponto de vista da aplicação definida e da segmentação verdadeira (referência) proposta podem ser visualizadas a partir das Figuras 8.30 e 8.31, as quais apresentam a segmentação manual e as segmentações da imagem de 8 *looks* produzidas pelo RWSEG selecionando-se valores de e iguais a 2,33, 2,58, 2,81, 3,09 e 3,29 e valores de j respectivamente iguais a 2 e 4. A Tabela 8.13 apresenta a classificação qualitativa das segmentações produzidas pelo RWSEG em função dos valores dos parâmetros selecionados.

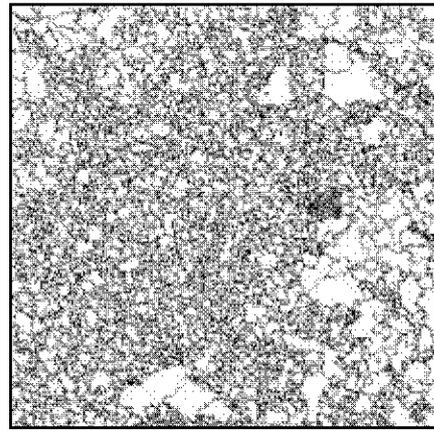
TABELA 8.13 - CLASSIFICAÇÃO QUALITATIVA DAS SEGMENTAÇÕES

<i>e</i>	<i>j</i>	0	2	4	6	8	10
1,65		Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação
1,96		Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação
2,33		Subsegmentação	Subsegmentação	Satisfatória	Satisfatória	Subsegmentação	Subsegmentação
2,58		Subsegmentação	Satisfatória	Satisfatória	Satisfatória	Subsegmentação	Subsegmentação
2,81		Subsegmentação	Satisfatória	Satisfatória	Satisfatória	Subsegmentação	Subsegmentação
3,09		Subsegmentação	Satisfatória	Satisfatória	Subsegmentação	Subsegmentação	Subsegmentação
3,29		Satisfatória	Satisfatória	Satisfatória	Subsegmentação	Subsegmentação	Subsegmentação
3,48		Subsegmentação	Satisfatória	Satisfatória	Subsegmentação	Subsegmentação	Subsegmentação
3,72		Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação
3,89		Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação
4,06		Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação
4,27		Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação
4,42		Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação
4,57		Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação
4,77		Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação
4,91		Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação	Subsegmentação

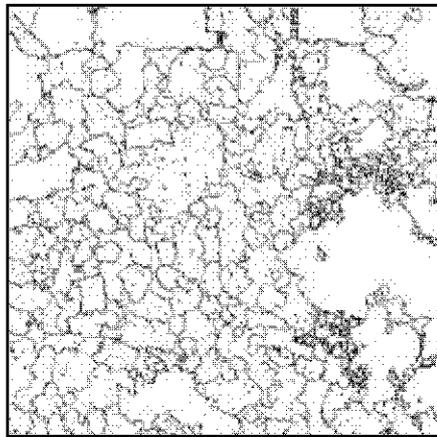




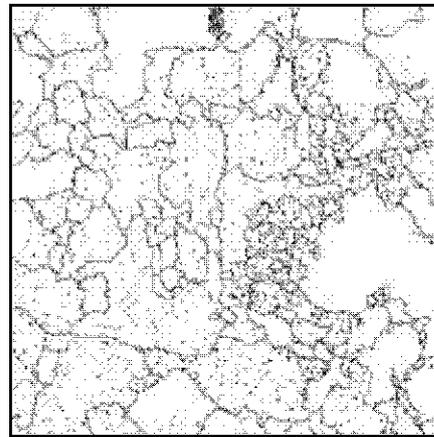
(a)



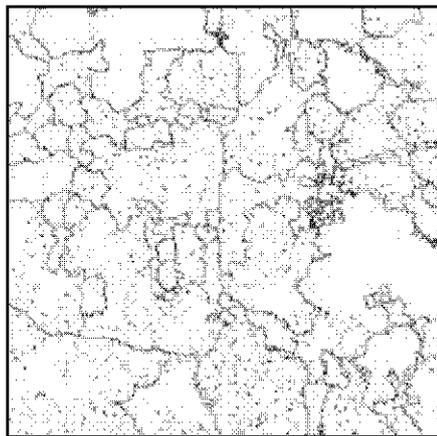
(b)



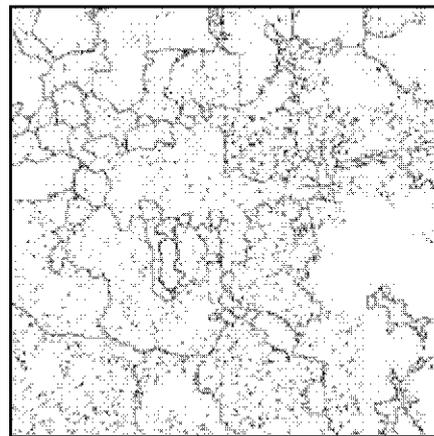
(c)



(d)

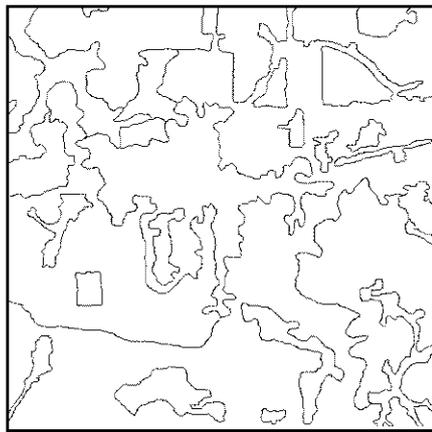


(e)

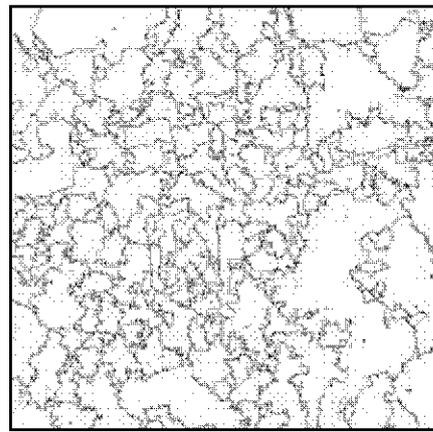


(f)

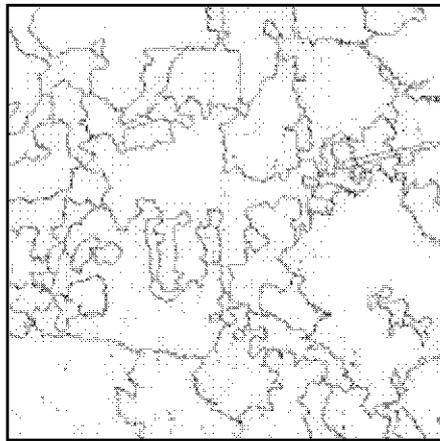
Fig. 8.28 - Segmentação manual (a) e segmentações da imagem 8 *looks* produzidas pelo RWSEG com $j=0$ e $e=1,65$ (b), $e=2,58$ (c), $e=3,29$ (d), $e=4,06$ (e) e $e=4,91$ (f).



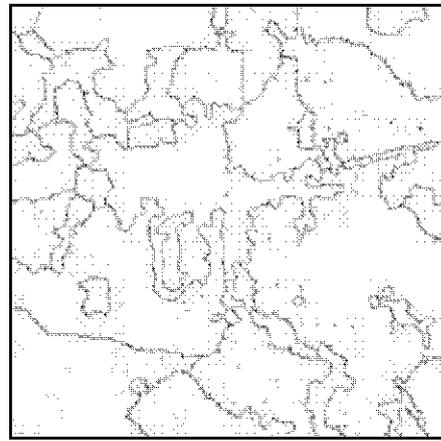
(a)



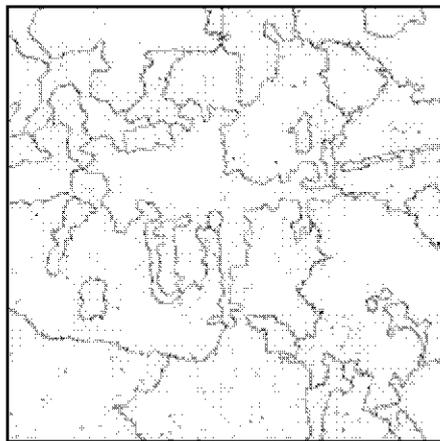
(b)



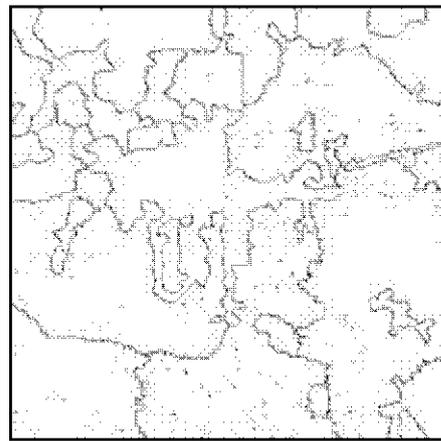
(c)



(d)

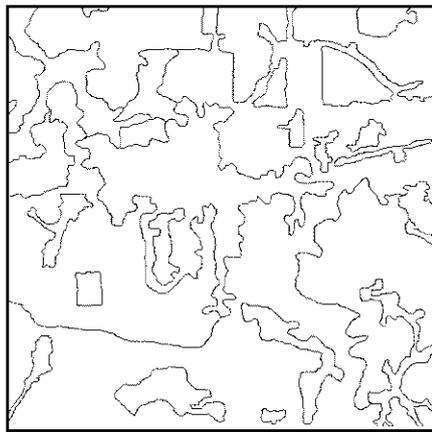


(e)

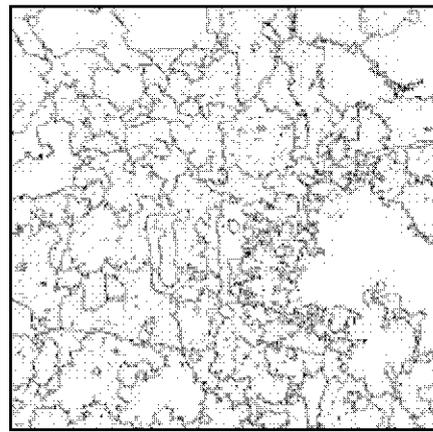


(f)

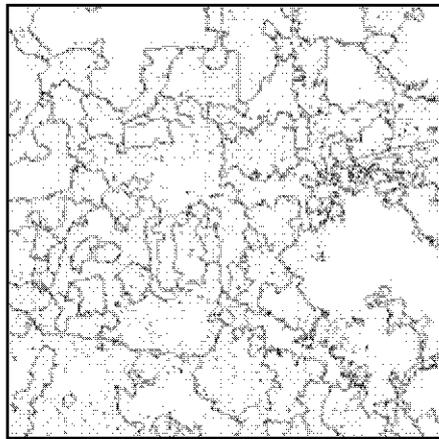
Fig. 8.29 - Segmentação manual (a) e segmentações da imagem 8 *looks* produzidas pelo RWSEG com $j=8$ e $e=1,65$ (b), $e=2,58$ (c), $e=3,29$ (d), $e=4,06$ (e) e $e=4,91$ (f).



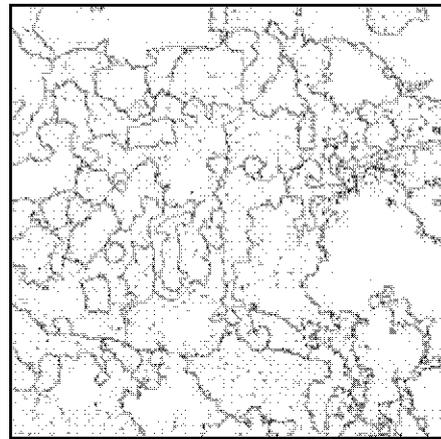
(a)



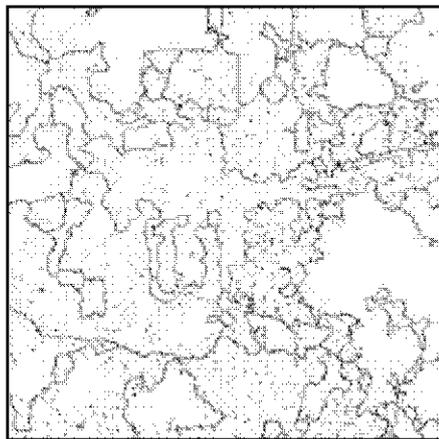
(b)



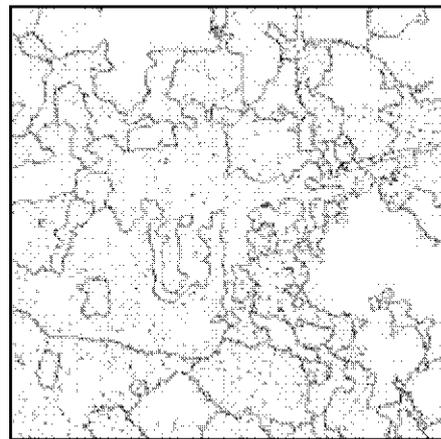
(c)



(d)

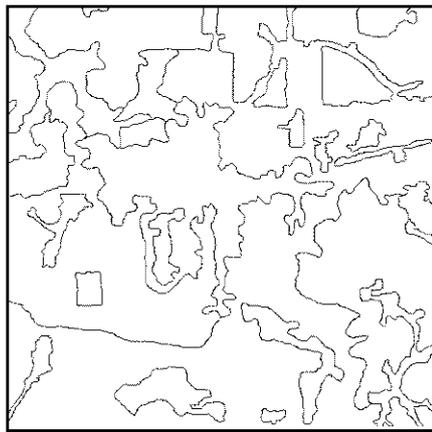


(e)

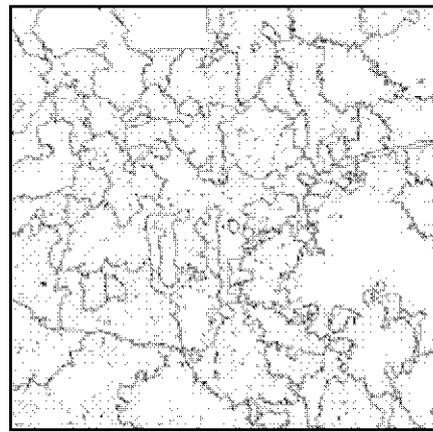


(f)

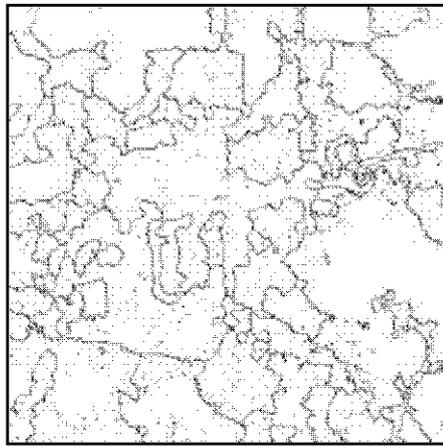
Fig. 8.30 - Segmentação manual (a) e segmentações da imagem 8 *looks* produzidas pelo RWSEG com $j=2$ e $e=2,33$ (b), $e=2,58$ (c), $e=2,81$ (d), $e=3,09$ (e) e $e=3,29$ (f).



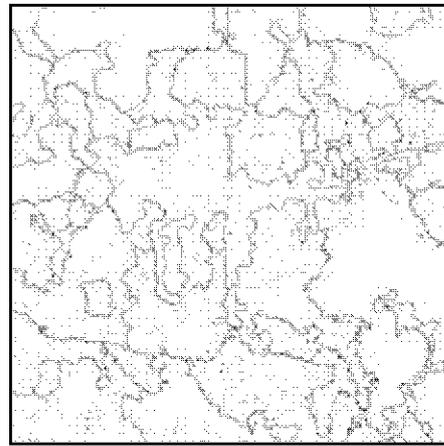
(a)



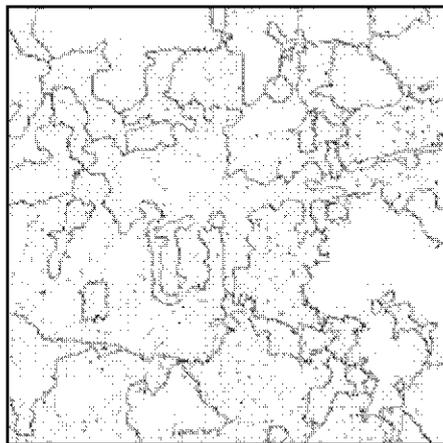
(b)



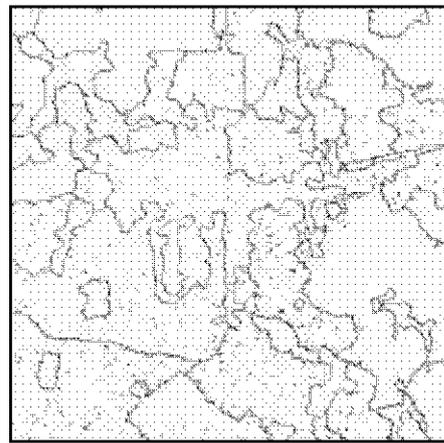
(c)



(d)



(e)



(f)

Fig. 8.31 - Segmentação manual (a) e segmentações da imagem 8 *looks* produzidas pelo RWSEG com $j=4$ e $e=2,33$ (b), $e=2,58$ (c), $e=2,81$ (d), $e=3,09$ (e) e $e=3,29$ (f).

Da análise das Figuras 8.30 e 8.31 verificou-se que as segmentações obtidas com e igual a 3,29 e j igual a 2 (Figura 8.30 f), com e igual a 3,29 e j igual a 4 (Figura 8.31 f) e com e igual a 3,09 e j igual a 2 (Figura 8.30 e) podem ser consideradas como mais satisfatórias do ponto de vista qualitativo.

Da Tabela 8.13 observou-se que das 96 segmentações possíveis, apenas 15 (15,6%) apresentaram resultados qualitativamente satisfatórios. A grande maioria das segmentações produzidas apresentaram-se subsegmentadas.

8.2.2.2 - AVALIAÇÃO QUANTITATIVA

A avaliação quantitativa das segmentações produzidas foi realizada calculando-se a média geral das medidas de ajuste obtidas em cada segmentação. A Figura 8.32 apresenta as médias gerais obtidas em cada uma das segmentações em função dos valores e e j selecionados.

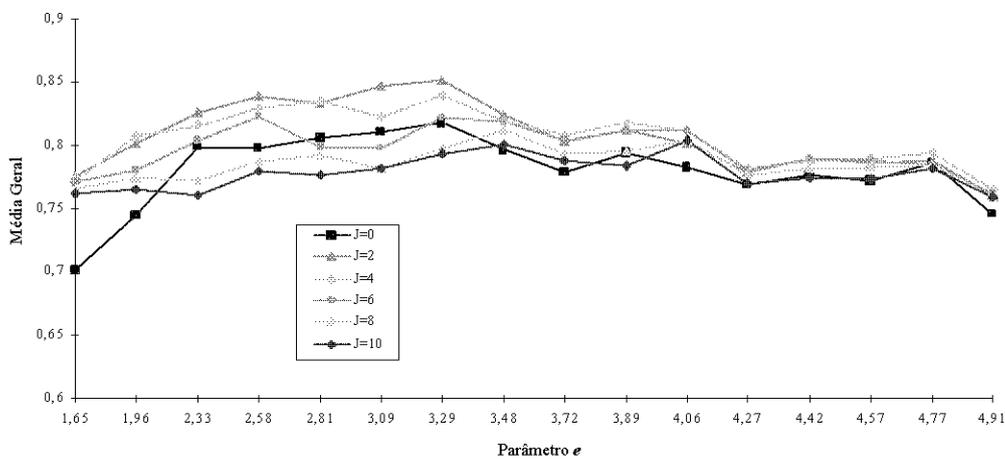


Fig. 8.32 - Média geral das segmentações da imagem 8 looks produzidas pelo RWSEG.

Da Figura 8.32 verificou-se que as maiores médias gerais foram obtidas nas segmentações produzidas com valores de j iguais a 2 e 4 para a maioria dos parâmetros e , ao passo que as menores são obtidas com valores de j iguais a 0 e 10. O intervalo de

valores do parâmetro e compreendido entre 2,58 e 3,29 apresentou as melhores médias gerais. Estes resultados confirmaram os obtidos na avaliação qualitativa (visual).

A maioria das segmentações produzidas apresentaram média geral compreendida no intervalo de 0,75 a 0,85. Valores de e igual e superiores a 4,27 apresentaram média geral praticamente constante para todos os valores de j . Do ponto de vista quantitativo, a melhor segmentação produzida pelo RWSEG foi a obtida com e igual a 3,29 e j igual a 2 ($\hat{\mu}_g = 0,8509$).

O tempo de processamento (yymin:zz.zs) e o número de classes e de segmentos obtidos nas segmentações produzidas pelo RWSEG para cada combinação de valores de e e j selecionados estão contidos nas Tabelas 8.14 a 8.19.

TABELA 8.14 - TEMPO DE PROCESSAMENTO E NÚMERO DE CLASSES E DE SEGMENTOS OBTIDOS COM $J=0$

Parâmetros		Tempo	Classes	Segmentos
e	j			
1,65	0	3:42.5	210	7230
1,96	0	2:48.4	206	4514
2,33	0	2:55.3	206	3337
2,58	0	3:00.3	207	2906
2,81	0	3:01.5	206	2761
3,09	0	3:04.3	207	2560
3,29	0	3:06.5	207	2576
3,48	0	3:04.8	208	2484
3,72	0	3:13.5	209	2585
3,89	0	3:16.4	208	2569
4,06	0	5:19.9	206	2002
4,27	0	3:13.6	209	2472
4,42	0	3:11.0	210	2522
4,57	0	3:07.1	210	2488
4,77	0	5:06.3	206	2013
4,91	0	3:10.8	209	2481

**TABELA 8.15 - TEMPO DE PROCESSAMENTO E NÚMERO DE CLASSES E
DE SEGMENTOS OBTIDOS COM $J=2$**

Parâmetros		Tempo	Classes	Segmentos
<i>e</i>	<i>j</i>			
1,65	2	2:59.3	210	2671
1,96	2	2:41.4	204	1891
2,33	2	2:51.8	202	1529
2,58	2	2:54.7	203	1335
2,81	2	2:59.4	203	1287
3,09	2	3:01.5	202	1285
3,29	2	3:09.1	198	1276
3,48	2	3:07.9	201	1269
3,72	2	3:08.3	196	1297
3,89	2	3:11.0	202	1286
4,06	2	5:14.8	198	1074
4,27	2	3:11.3	192	1265
4,42	2	3:06.2	197	1299
4,57	2	3:11.0	197	1297
4,77	2	5:23.6	199	1075
4,91	2	3:07.1	202	1320

**TABELA 8.16 - TEMPO DE PROCESSAMENTO E NÚMERO DE CLASSES E
DE SEGMENTOS OBTIDOS COM $J=4$**

Parâmetros		Tempo	Classes	Segmentos
<i>e</i>	<i>j</i>			
1,65	4	2:27.3	200	1192
1,96	4	2:35.0	191	934
2,33	4	2:52.6	178	824
2,58	4	3:05.8	183	775
2,81	4	3:08.0	178	723
3,09	4	3:04.7	171	730
3,29	4	3:02.7	171	712
3,48	4	3:02.1	176	753
3,72	4	3:04.4	171	736
3,89	4	3:03.9	176	746
4,06	4	5:08.0	169	660
4,27	4	3:05.1	173	789
4,42	4	3:07.2	173	786
4,57	4	3:05.4	170	783
4,77	4	5:09.7	171	666
4,91	4	3:06.9	177	813

TABELA 8.17 - TEMPO DE PROCESSAMENTO E NÚMERO DE CLASSES E DE SEGMENTOS OBTIDOS COM $J=6$

Parâmetros		Tempo	Classes	Segmentos
<i>e</i>	<i>j</i>			
1,65	6	2:25.0	180	711
1,96	6	2:44.1	152	518
2,33	6	2:49.5	148	469
2,58	6	2:54.8	146	449
2,81	6	2:56.1	138	423
3,09	6	3:00.0	132	403
3,29	6	3:01.9	130	391
3,48	6	3:03.8	135	422
3,72	6	3:03.6	131	418
3,89	6	3:05.7	138	426
4,06	6	5:08.9	133	403
4,27	6	3:07.3	138	449
4,42	6	3:08.3	140	454
4,57	6	3:06.7	134	442
4,77	6	5:10.1	133	395
4,91	6	3:08.0	137	480

TABELA 8.18 - TEMPO DE PROCESSAMENTO E NÚMERO DE CLASSES E DE SEGMENTOS OBTIDOS COM $J=8$

Parâmetros		Tempo	Classes	Segmentos
<i>e</i>	<i>j</i>			
1,65	8	2:28.9	142	456
1,96	8	2:37.1	124	330
2,33	8	2:50.4	105	285
2,58	8	2:52.4	107	254
2,81	8	2:57.0	97	225
3,09	8	3:00.0	97	227
3,29	8	3:25.1	95	196
3,48	8	3:03.5	94	221
3,72	8	3:04.6	93	231
3,89	8	3:05.2	92	222
4,06	8	5:10.3	97	225
4,27	8	3:05.5	105	257
4,42	8	3:07.7	110	253
4,57	8	3:06.0	103	238
4,77	8	5:12.2	97	215
4,91	8	3:07.8	98	250

TABELA 8.19 - TEMPO DE PROCESSAMENTO E NÚMERO DE CLASSES E DE SEGMENTOS OBTIDOS COM $J=10$

Parâmetros		Tempo	Classes	Segmentos
e	j			
1,65	10	2:26.2	118	336
1,96	10	2:26.2	98	204
2,33	10	2:49.3	80	192
2,58	10	2:52.4	85	174
2,81	10	2:55.1	79	151
3,09	10	3:00.9	77	141
3,29	10	3:01.4	75	122
3,48	10	3:03.6	74	133
3,72	10	3:03.4	70	132
3,89	10	3:05.0	77	140
4,06	10	5:06.4	75	143
4,27	10	3:06.6	80	158
4,42	10	3:08.2	84	153
4,57	10	3:07.0	78	142
4,77	10	5:08.9	77	138
4,91	10	3:07.5	79	148

Das Tabelas 8.14 a 8.19 verificou-se que o número de classes e de segmentos, para um dado valor do parâmetro j , tendeu a diminuir suavemente à medida que o valor do parâmetro e foi aumentado. Para um dado valor de e , o número de classes distintas e o número total de segmentos diminuiu à medida que o valor do parâmetro j foi aumentado.

Considerando-se a segmentação de referência (9 classes distintas e 36 segmentos), todos os valores de e e j produziram segmentações com excessivo número de classes e principalmente de segmentos, até mesmo as obtidas com valores elevados destes parâmetros.

O tempo de processamento requerido para produzir as segmentações foi praticamente o mesmo para todos os valores de e e um mesmo valor de j . Entretanto, o aumento do valor atribuído ao parâmetro j , para um mesmo valor de e , tendeu a aumentar o tempo de processamento requerido, principalmente para valores mais elevados.

Considerando-se os resultados da avaliação qualitativa e quantitativa de todas as segmentações da imagem simulada 8 *looks* produzidas pelo RWSEG, a obtida com e igual a 3,29 e j igual a 2 foi eleita como a mais representativa da verdadeira.

8.2.3 - EXPERIMENTO MONTE CARLO

Uma vez determinados os melhores parâmetros para o MUM ($p=10$) e para o RWSEG ($e=3,29$ e $j=2$) efetuou-se o experimento Monte Carlo para obter os resultados que permitiram comparar os dois algoritmos do ponto de vista da qualidade das segmentações produzidas e da capacidade de segmentar regiões com diferentes graus de homogeneidade.

O experimento Monte Carlo consistiu em segmentar as 100 imagens replicadas de 8 *looks* a partir do MUM com $p=10$ e do RWSEG com $e=3,29$ e $j=2$. Em seguida calculou-se os valores de $Fitxy$, $Fiti$, $Fitn$, $Gforma$ e média geral ($\hat{\mu}_g$) de cada uma das 100 segmentações produzidas por cada algoritmo. Ao final, obteve-se a média ($\hat{\mu}_e$) e a variância ($\hat{\sigma}_e^2$) amostrais dos valores de $Fitxy$, $Fiti$, $Fitn$, $Gforma$ e $\hat{\mu}_g$ obtidos em todas as segmentações produzidas por cada algoritmo.

Os valores de $Fitxy$, $Fiti$, $Fitn$, $Gforma$ e média geral ($\hat{\mu}_g$) obtidos em cada uma das 100 segmentações produzidas pelo MUM e pelo RWSEG são apresentados, respectivamente, nas Figuras 8.33, 8.34, 8.35, 8.36 e 8.37.



Fig.8.33 - Valores do ajuste de posição obtidos em cada segmentação produzida pelo MUM e pelo RWSEG no experimento Monte Carlo.

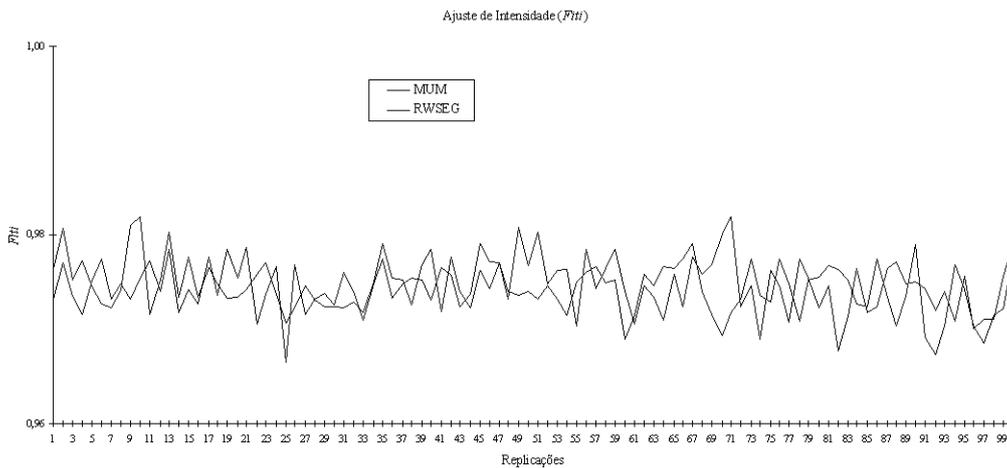


Fig.8.34 - Valores do ajuste de intensidade média obtidos em cada segmentação produzida pelo MUM e pelo RWSEG no experimento Monte Carlo.

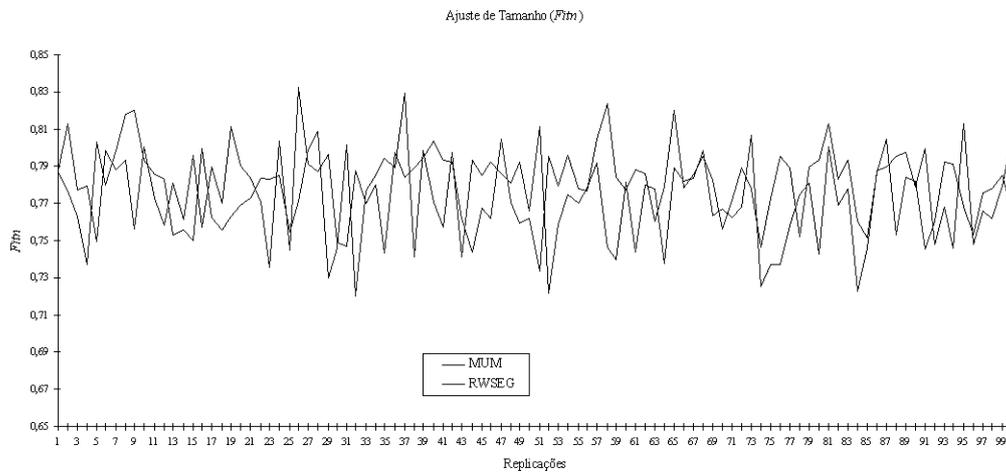


Fig.8.35 - Valores do ajuste de tamanho obtidos em cada segmentação produzida pelo MUM e pelo RWSEG no experimento Monte Carlo.



Fig.8.36 - Valores do ajuste da forma obtidos em cada segmentação produzida pelo MUM e pelo RWSEG no experimento Monte Carlo.

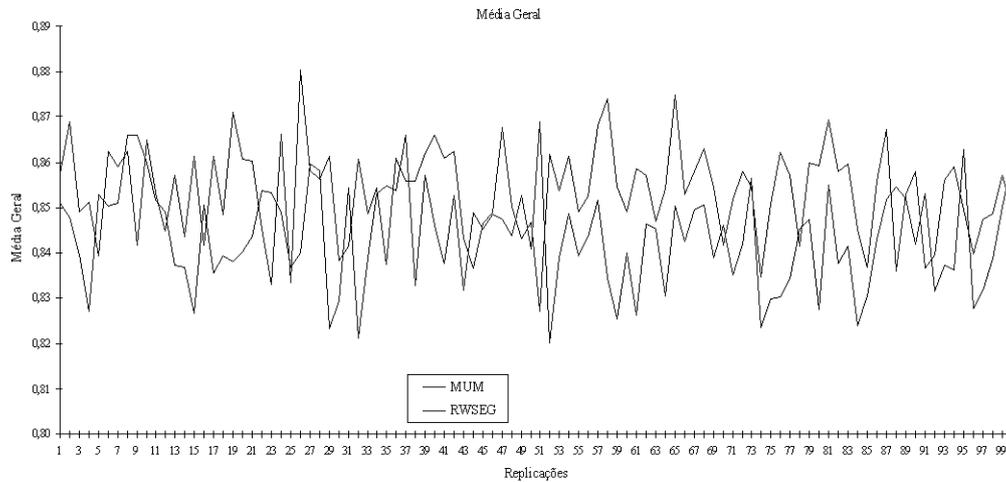


Fig.8.37 - Valores da média geral obtida em cada segmentação produzida pelo MUM e pelo RWSEG no experimento Monte Carlo.

A média ($\hat{\mu}_e$) e a variância ($\hat{\sigma}_e^2$) amostrais dos valores de *Fitxy*, *Fiti*, *Fitn*, *Gforma* e $\hat{\mu}_g$ obtidos em todas as segmentações produzidas pelo MUM e pelo RWSEG são apresentadas na Tabela 8.20.

TABELA 8.20 - MÉDIA E VARIÂNCIA AMOSTRAIS DAS MEDIDAS DE AJUSTE OBTIDAS NO EXPERIMENTO MONTE CARLO

	MUM		RWSEG	
	$\hat{\mu}_e$	$\hat{\sigma}_e^2$	$\hat{\mu}_e$	$\hat{\sigma}_e^2$
<i>Fitxy</i>	0,98675	0,000007	0,98042	0,000012
<i>Fiti</i>	0,97421	0,000007	0,97478	0,000009
<i>Fitn</i>	0,77917	0,000402	0,77369	0,000576
<i>Gforma</i>	0,67385	0,000357	0,64561	0,000392
$\hat{\mu}_g$	0,85349	0,000107	0,84362	0,000123

Da análise das Figuras 8.33 a 8.37 e a partir de testes estatísticos efetuados utilizando-se os valores apresentados na Tabela 8.20, concluiu-se que com respeito ao ajuste de posição e forma, as segmentações produzidas pelo MUM obtiveram médias amostrais maiores, ao nível de significância de 1%, que as obtidas pelo RWSEG. A supremacia do MUM sobre o RWSEG no tocante a estes ajustes pode ser facilmente observada a partir das Figuras 8.38 e 8.41 respectivamente. As médias amostrais do ajuste de tamanho foram estatisticamente iguais ao nível de significância de 5% (Figura 8.40). A média amostral do ajuste de intensidade média das segmentações produzidas pelo RWSEG foi maior que à obtida pelo MUM ao nível de significância de 5% (Figura 8.39).

Da Figura 8.37 verificou-se que para a maioria das replicações o MUM produziu segmentações com maior média geral que às produzidas pelo RWSEG. Da Tabela 8.20 verificou-se que a média amostral das médias gerais obtidas nas segmentações produzidas pelo MUM foi superior à obtida pelo RWSEG ao nível de significância de 1% (Figura 8.42).

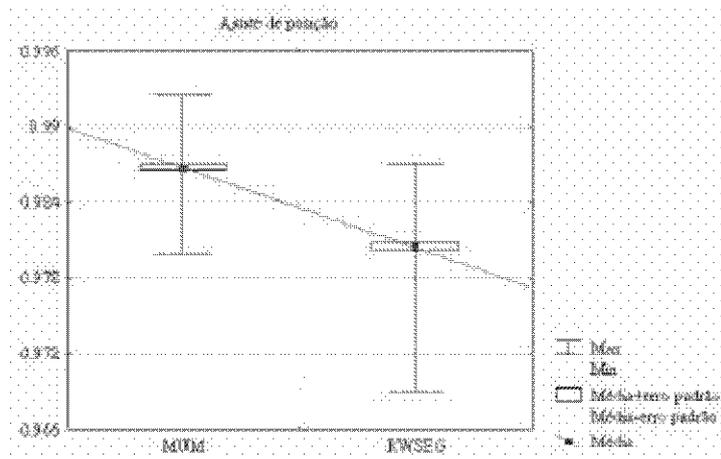


Fig.8.38 - Comparação das médias amostrais do ajuste de posição obtidas pelo MUM e pelo RWSEG no experimento Monte Carlo.

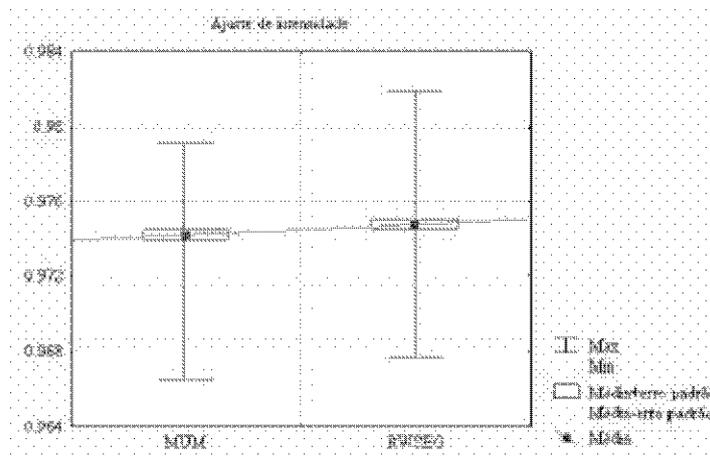


Fig.8.39 - Comparação das médias amostrais do ajuste de intensidade obtidas pelo MUM e pelo RWSEG no experimento Monte Carlo.

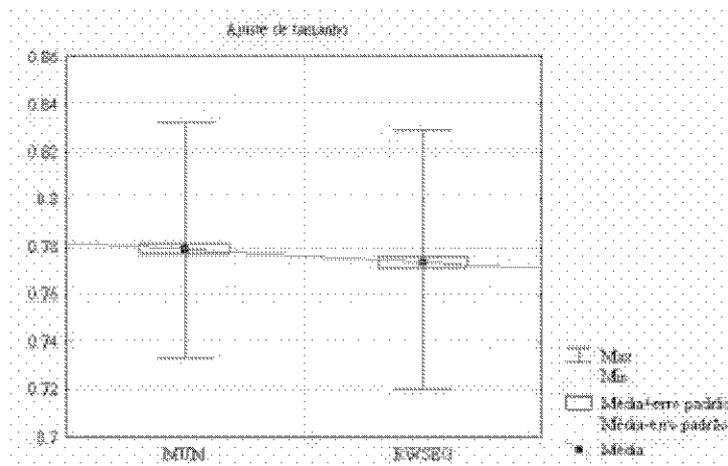


Fig.8.40 - Comparação das médias amostrais do ajuste de tamanho obtidas pelo MUM e pelo RWSEG no experimento Monte Carlo.

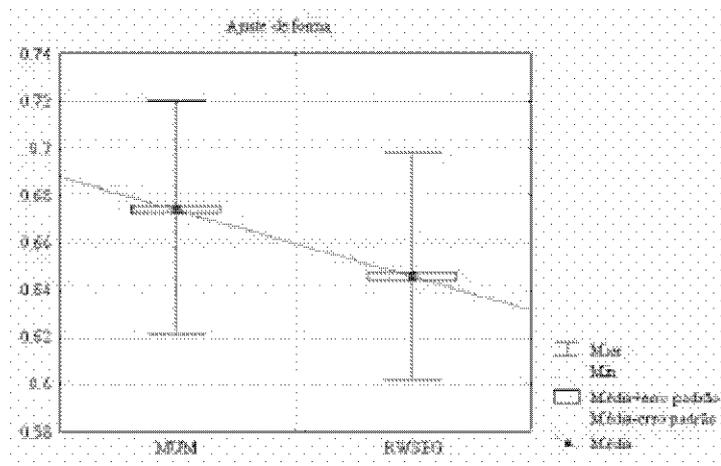


Fig.8.41 - Comparação das médias amostrais do ajuste de forma obtidas pelo MUM e pelo RWSEG no experimento Monte Carlo.

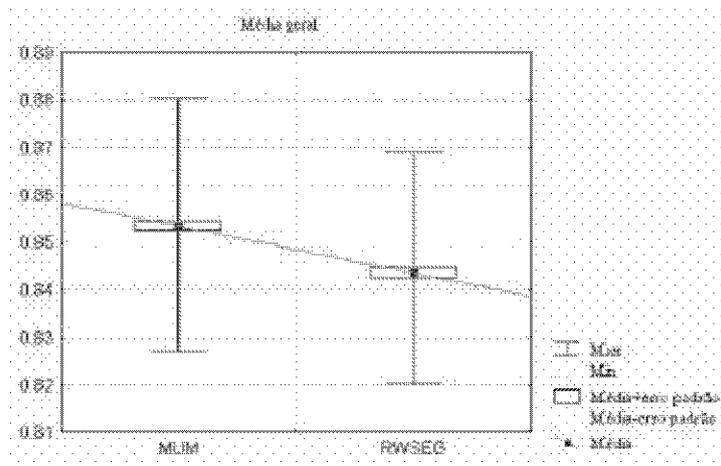


Fig.8.42 - Comparação das médias amostrais da média geral obtidas pelo MUM e pelo RWSEG no experimento Monte Carlo.

Comparativamente aos resultados obtidos para as imagens de 3 *looks*, as segmentações das imagens de 8 *looks* produzidas pelos dois algoritmos foram mais corretas (maior média) em termos de posição, intensidade média, tamanho e forma ao nível de significância de 1%. Este aumento de correção foi maior em termos de forma e tamanho. As médias gerais também foram superiores ao mesmo nível de significância.

A média e variância amostrais das medidas de ajuste obtidas pelo MUM e pelo RWSEG no experimento Monte Carlo em função do tipo de região estão listadas, respectivamente, nas Tabelas 8.21 e 8.22.

TABELA 8.21 – MÉDIA E VARIÂNCIA AMOSTRAIS DAS MEDIDAS DE AJUSTE OBTIDAS PELO MUM EM FUNÇÃO DO TIPO DE REGIÃO

	Homogêneas		Heterogêneas		Ext. Heterogêneas	
	$\hat{\mu}_e$	$\hat{\sigma}_e^2$	$\hat{\mu}_e$	$\hat{\sigma}_e^2$	$\hat{\mu}_e$	$\hat{\sigma}_e^2$
<i>Fitxy</i>	0,9925	0,000004	0,9711	0,000059	0,9992	0,000001
<i>Fiti</i>	0,9749	0,000009	0,9673	0,000023	0,9873	0,000005
<i>Fitn</i>	0,7788	0,000615	0,7081	0,001332	0,9758	0,002195
<i>Gforma</i>	0,6895	0,000601	0,5525	0,001116	0,9251	0,003570
$\hat{\mu}_g$	0,8589	0,000076	0,7998	0,000158	0,9718	0,000360

TABELA 8.22 – MÉDIA E VARIÂNCIA AMOSTRAIS DAS MEDIDAS DE AJUSTE OBTIDAS PELO RWSEG EM FUNÇÃO DO TIPO DE REGIÃO

	Homogêneas		Heterogêneas		Ext. Heterogêneas	
	$\hat{\mu}_e$	$\hat{\sigma}_e^2$	$\hat{\mu}_e$	$\hat{\sigma}_e^2$	$\hat{\mu}_e$	$\hat{\sigma}_e^2$
<i>Fitxy</i>	0,9863	0,000022	0,9648	0,000039	0,9924	0,000015
<i>Fiti</i>	0,9714	0,000026	0,9709	0,000022	0,9905	0,000005
<i>Fitn</i>	0,7996	0,001122	0,6809	0,002135	0,8895	0,001421
<i>Gforma</i>	0,6788	0,000789	0,5335	0,001171	0,7778	0,001878
$\hat{\mu}_g$	0,8590	0,000122	0,7875	0,000210	0,9126	0,000236

Das Tabelas 8.21 e 8.22 verificou-se, a exemplo do ocorrido com as imagens de 3 *looks*, que do ponto de vista quantitativo os dois algoritmos segmentaram os três tipos de regiões com boa correção de posição e intensidade média. Entretanto, tanto o MUM quanto o RWSEG tiveram menos sucesso para segmentar corretamente os três tipos de regiões em termos de tamanho e principalmente da forma. Neste aspecto o desempenho dos dois algoritmos também foi diferenciado para as três regiões, sendo melhor para as regiões extremamente heterogêneas e pior para as heterogêneas, as quais apresentaram maior incorreção em termos de forma.

Utilizando-se os valores apresentados na Tabela 8.21, foram efetuados testes estatísticos e concluiu-se que a segmentação das regiões extremamente heterogêneas produzidas pelo MUM foi mais correta que as das homogêneas e heterogêneas em termos de posição, intensidade média, tamanho e forma ao nível de significância de 1%. A segmentação das regiões homogêneas foi mais correta que as das heterogêneas em

termos de posição, intensidade média, tamanho e forma ao nível de significância de 1%. Estes resultados podem ser visualizados a partir da Figura 8.43.

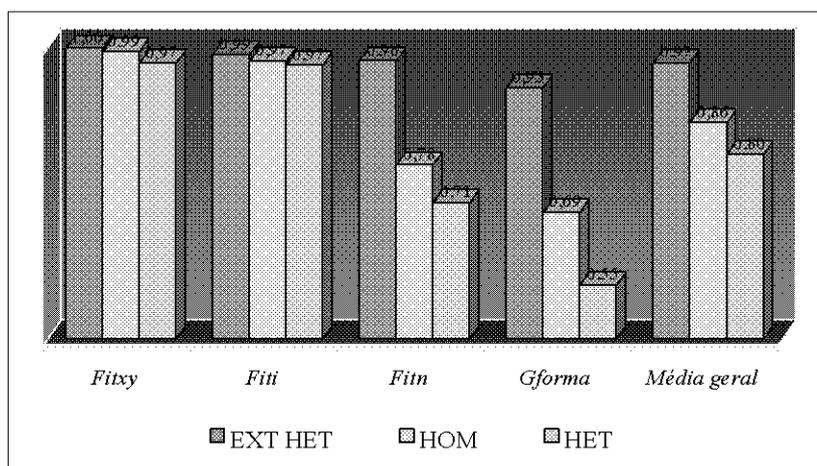


Fig.8.43 - Comparação das médias amostrais das medidas de ajuste obtidas pelo MUM em função do tipo de região.

Utilizando-se os valores apresentados na Tabela 8.22, foram efetuados testes estatísticos e concluiu-se que a segmentação das regiões extremamente heterogêneas produzidas pelo RWSEG foi mais correta que as das homogêneas e heterogêneas em termos de posição, intensidade média, tamanho e forma ao nível de significância de 1%. A segmentação das regiões homogêneas foi mais correta que as das heterogêneas em termos de posição, tamanho e forma ao nível de significância de 1% e estatisticamente igual em termos de intensidade média ao nível de significância de 5%. Estes resultados podem ser visualizados a partir da Figura 8.44.

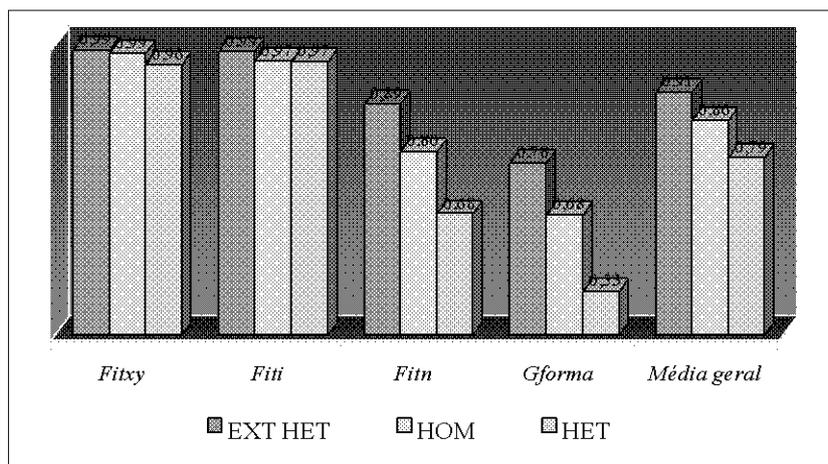


Fig.8.44 - Comparação das médias amostrais das medidas de ajuste obtidas pelo RWSEG em função do tipo de região.

Do ponto de vista da média geral, os dois algoritmos apresentaram boa capacidade para segmentar os três tipos de regiões. Esta média, tanto para o MUM quanto para o RWSEG foi maior, respectivamente, para as regiões extremamente heterogêneas, homogêneas e heterogêneas, ao nível de significância de 1%.

As Figuras 8.45 a 8.47 ilustram o desempenho comparativo entre os dois algoritmos para cada um dos graus de homogeneidade em termos das médias amostrais das medidas de ajuste e média geral.

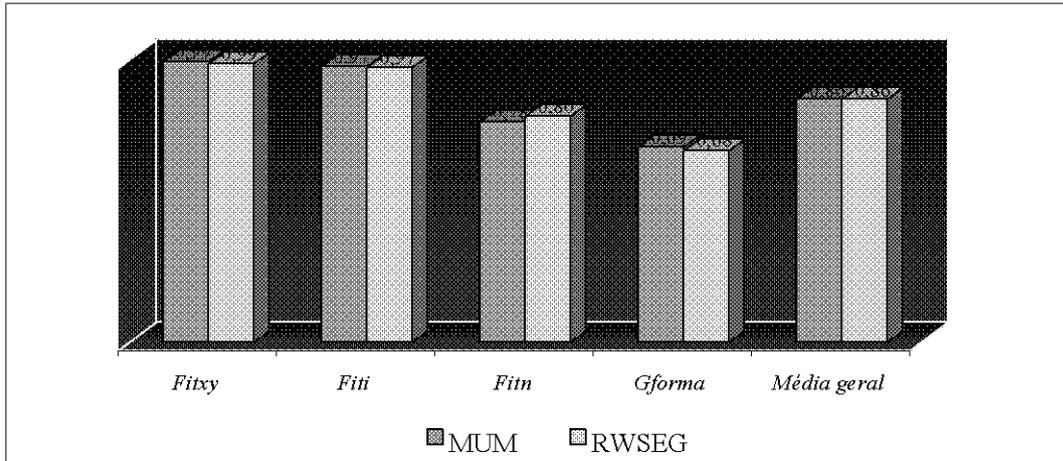


Fig.8.45 - Comparação das médias amostrais das medidas de ajuste e média geral obtidas pelo MUM e pelo RWSEG para regiões homogêneas.

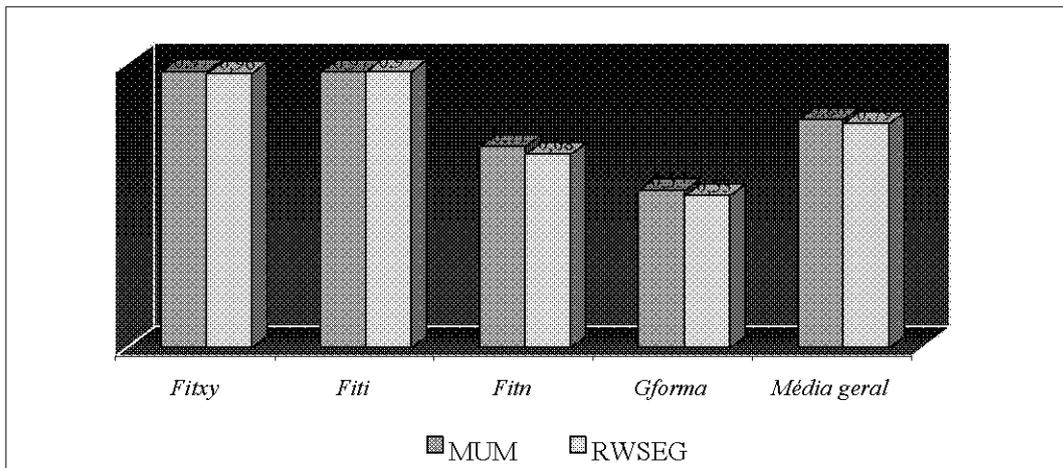


Fig.8.46 - Comparação das médias amostrais das medidas de ajuste e média geral obtidas pelo MUM e pelo RWSEG para regiões heterogêneas.

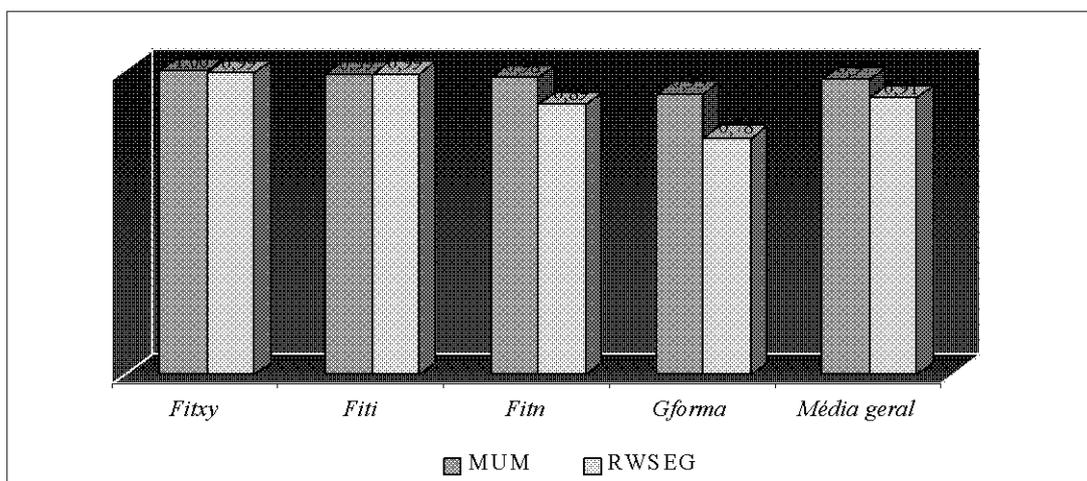


Fig.8.47 - Comparação das médias amostrais das medidas de ajuste e média geral obtidas pelo MUM e pelo RWSEG para regiões extremamente heterogêneas.

Das Figuras 8.45 a 8.47 observa-se que comparativamente, o MUM e o RWSEG tiveram o mesmo desempenho para segmentar regiões heterogêneas em termos de posição, intensidade média, tamanho e forma e homogêneas em termos de intensidade média, tamanho e forma ao nível de significância de 5%, mas em termos de posição o MUM foi mais correto ao nível de significância de 1%. A segmentação das regiões extremamente heterogêneas produzidas pelo MUM foi mais correta em termos de forma, tamanho e posição ao nível de significância de 1% e estatisticamente igual em termos de intensidade média ao nível de significância de 5%.

A média geral obtida pelo MUM e pelo RWSEG foram estatisticamente iguais para as regiões homogêneas ao nível de significância de 5%. Para as regiões heterogêneas e extremamente heterogêneas, a obtida pelo MUM foi maior que a do RWSEG ao nível de significância de 1%.

Comparativamente aos resultados obtidos para as imagens de 3 *looks*, os dois algoritmos tiveram melhor desempenho (maior média) nas imagens de 8 *looks* para segmentar os três tipos de regiões em termos de posição, intensidade média, tamanho e forma ao nível

de significância de 1%. A média geral também foi maior para os três tipos de regiões ao nível de significância de 1%.

Para avaliar os resultados obtidos do experimento Monte Carlo, analisou-se visualmente as segmentações de uma única imagem simulada de 8 *looks* obtidas pelo MUM e pelo RWSEG. As segmentações utilizadas foram as obtidas da imagem simulada empregada para determinar os valores dos parâmetros de cada algoritmo empregados no experimento Monte Carlo e eleitas como mais representativa da verdadeira, ou seja, a obtida pelo MUM com p igual a 10 e a obtida pelo RWSEG com e igual a 3,29 e j igual a 2.

A Figura 8.48 apresenta a segmentação de referência, o *phantom* e as segmentações eleitas como mais representativas da verdadeira obtidas pelo MUM e pelo RWSEG para uma única imagem.

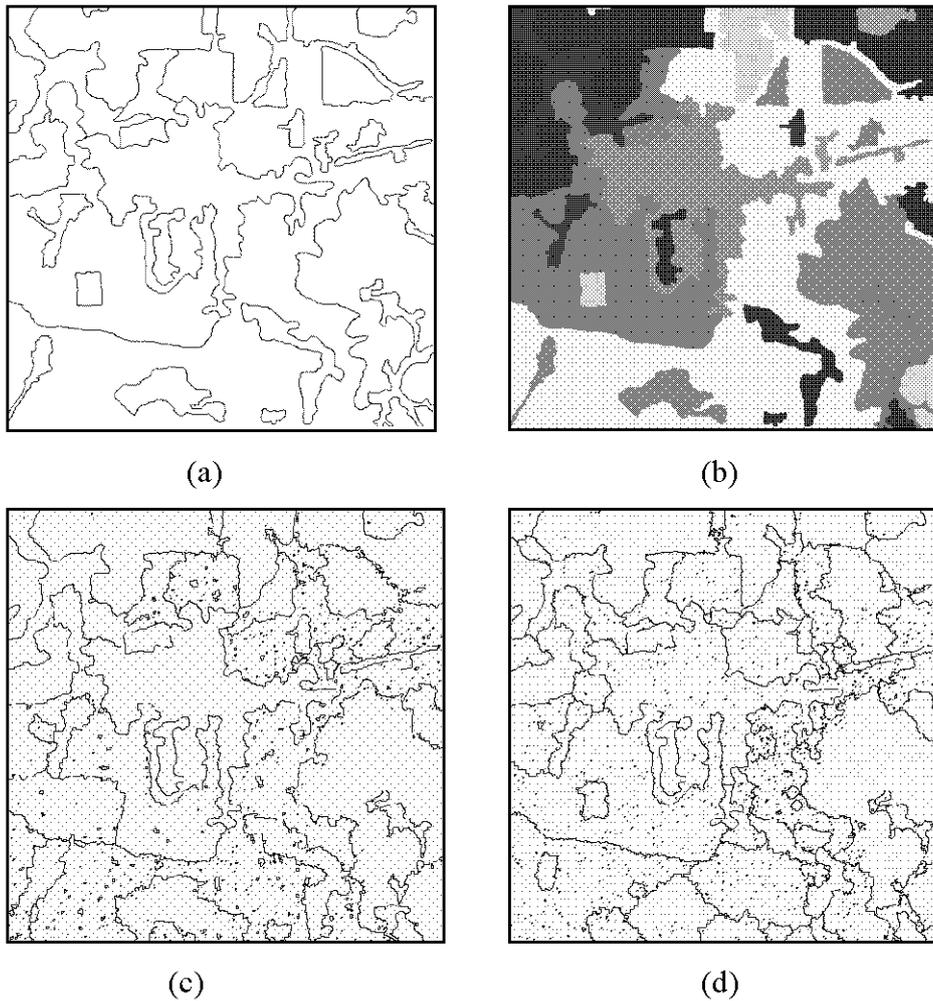


Fig. 8.48 - Segmentação manual (a), *phantom* (b) e segmentações da imagem 8 *looks* produzidas pelo MUM com $p=10$ (c) e RWSEG com $e=3,29$ e $j=2$ (d).

Da Figura 8.48 verificou-se visualmente que o MUM segmentou com boa correção as regiões extremamente heterogêneas (cores vermelha e magenta) e homogêneas (cores azul, azul claro e cyan) em termos de forma, tamanho e posição. As heterogêneas (cores marrom escuro, claro e amarela) tiveram melhor correção em termos de tamanho e forma que as verificadas para a imagem de 3 *looks*, porém com muitos microsegmentos internos.

O RWSEG segmentou as regiões homogêneas e extremamente heterogêneas com boa correção de posição e tamanho. Entretanto, as extremamente heterogêneas apresentaram

muitos microsegmentos internos. As regiões heterogêneas mais extensas apresentaram elevado número de microsegmentos.

Da comparação entre as segmentações produzidas pelos algoritmos com a segmentação de referência verificou-se que, do ponto de vista qualitativo, os dois algoritmos foram melhores para segmentar regiões homogêneas e extremamente heterogêneas e mais deficientes para segmentar as heterogêneas, confirmando a análise quantitativa dos valores contidos nas Tabelas 8.21 e 8.22. O excessivo número de microsegmentos presentes nas regiões heterogêneas, tanto na segmentação obtida pelo MUM quanto na obtida pelo RWSEG, justifica o pior desempenho quantitativo em termos de tamanho e forma observado para este tipo de região no experimento Monte Carlo.

O tempo de processamento médio requerido pelo MUM foi de 33 minutos e o do RWSEG foi de 3 minutos. O custo computacional requerido pelo RWSEG para segmentar as imagens de entrada foi em média cerca de 9% do requerido pelo MUM.

8.3 - RESULTADOS OBTIDOS A PARTIR DA IMAGEM REAL

8.3.1 - RESULTADOS OBTIDOS PELO MUM

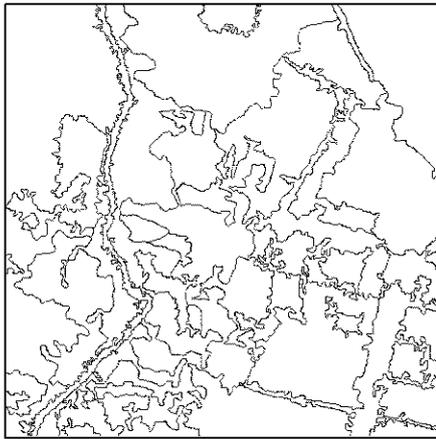
8.3.1.1 - AVALIAÇÃO QUALITATIVA

A partir da comparação visual das 17 segmentações produzidas pelo MUM com a segmentação de referência verificou-se que o grau de subdivisão destas segmentações teve relação inversa com o valor atribuído ao parâmetro p , a exemplo do ocorrido no caso das imagens simuladas de 3 e 8 *looks*. Quanto maior seu valor, menor o grau de subdivisão. A influência do valor do parâmetro p selecionado nas segmentações produzidas pode ser visualizada na Figura 8.49.

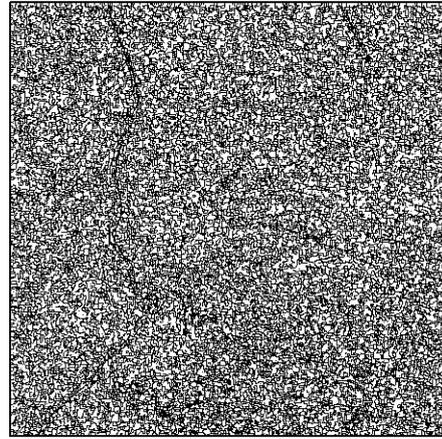
A Figura 8.49 apresenta a segmentação manual (referência) da imagem real e as segmentações (apresentadas na forma de mapa de bordas) da mesma imagem produzidas pelo MUM com p igual a 1, 6, 10, 13 e 17. Estes parâmetros foram escolhidos para dar

uma noção geral do efeito da seleção do valor de p , apresentando os dois extremos (maior e menor) e três intermediários.

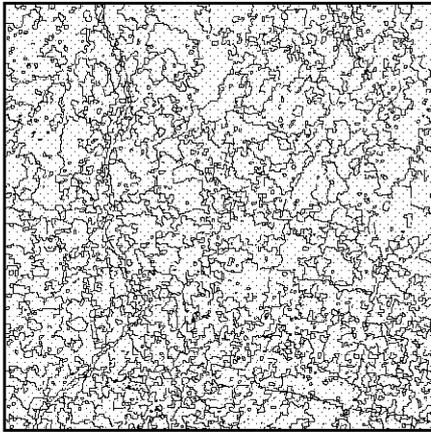
Do ponto de vista da aplicação definida e da segmentação verdadeira (referência) proposta, as segmentações produzidas com praticamente todos valores do parâmetro p apresentaram-se supersegmentadas. As produzidas com valores inferiores a 10 apresentaram-se extremamente segmentadas, enquanto que as produzidas com valores superiores a 11 apresentaram supersegmentação em algumas porções da imagem. As segmentações qualitativamente satisfatórias foram obtidas com os valores de p entre 11 e 17. A Figura 8.50 apresenta as segmentações produzidas com parâmetro p iguais a 11, 12, 14, 15 e 16.



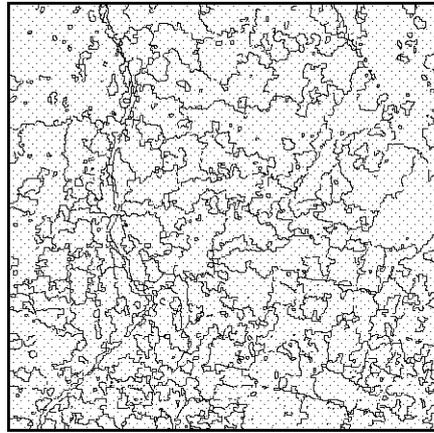
(a)



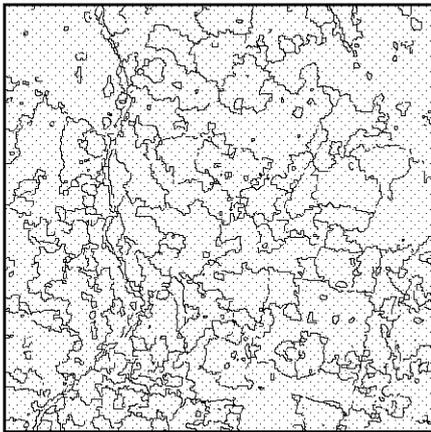
(b)



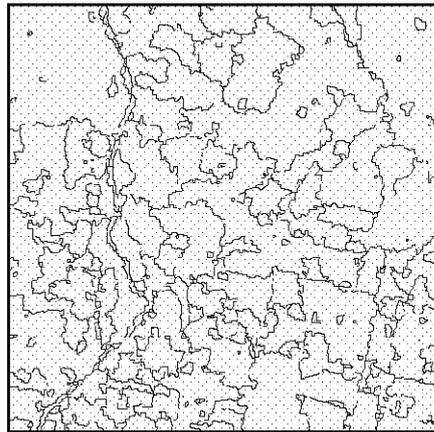
(c)



(d)

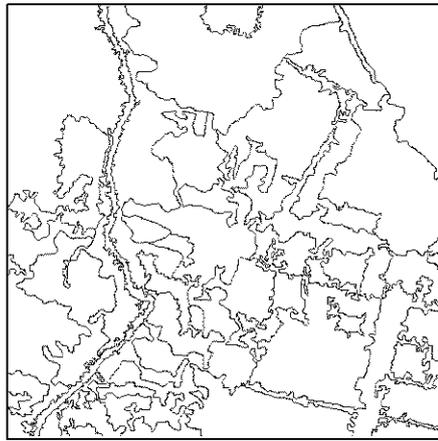


(e)

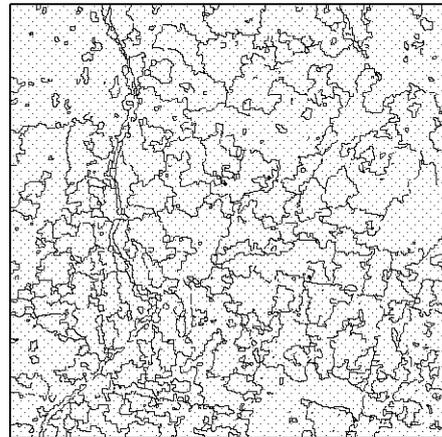


(f)

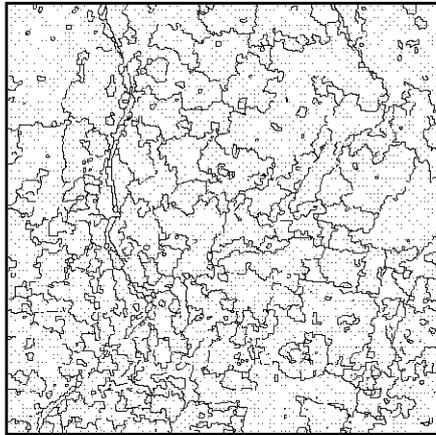
Fig. 8.49 - Segmentação manual (a) e segmentações da imagem real produzidas pelo MUM com $p=1$ (b), $p=6$ (c), $p=10$ (d), $p=13$ (e) e $p=17$ (f).



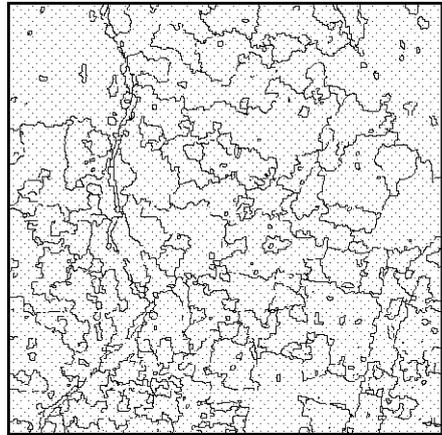
(a)



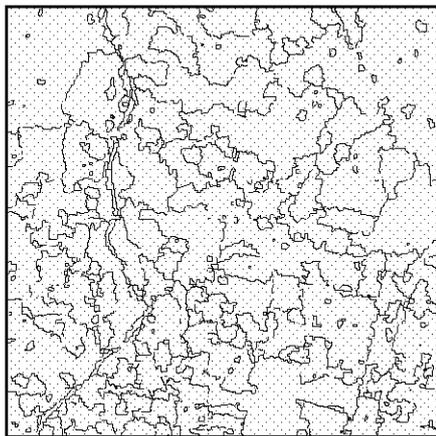
(b)



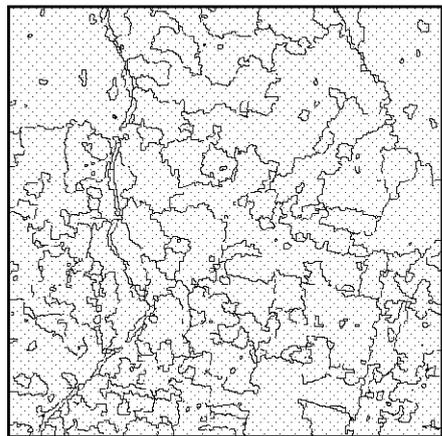
(c)



(d)



(e)



(f)

Fig. 8.50 - Segmentação manual (a) e segmentações da imagem real produzidas pelo MUM com $p=11$ (b), $p=12$ (c), $p=14$ (d), $p=15$ (e) e $p=16$ (f).

8.3.1.2 - AVALIAÇÃO QUANTITATIVA

A avaliação quantitativa das segmentações produzidas foi procedida calculando-se a média geral ($\hat{\mu}_g$) das medidas de ajuste obtidas em cada segmentação. A Figura 8.51 apresenta as médias gerais obtidas em cada uma das segmentações em função do parâmetro p selecionado.

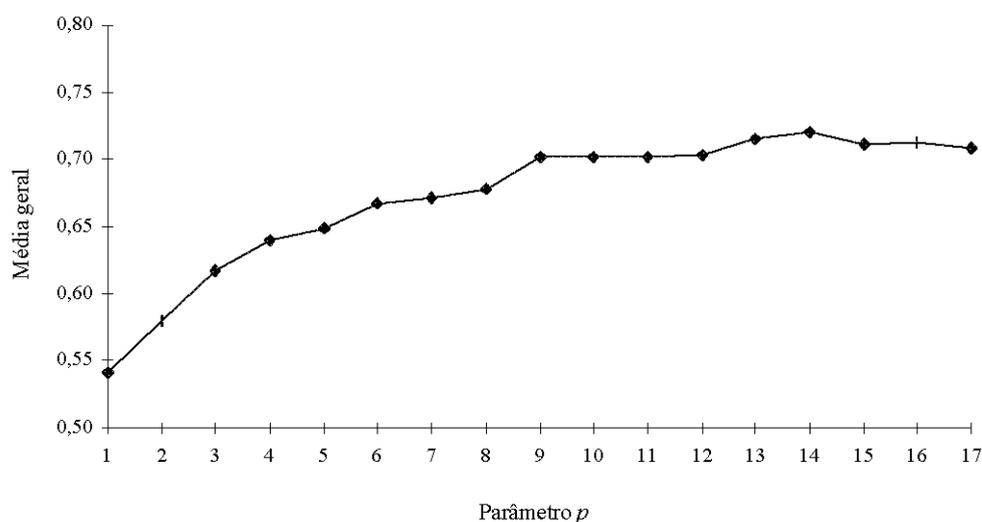


Fig. 8.51 - Média geral das segmentações da imagem real produzidas pelo MUM.

Da Figura 8.51 verificou-se que a segmentação com maior média geral foi obtida com p igual a 14 ($\hat{\mu}_g = 0,7204$). Pode-se observar também que a maioria das segmentações tiveram média geral compreendida entre 0,64 e 0,7. Valores de p compreendidos no intervalo de 13 a 17 produziram as segmentações com maiores médias gerais.

O tempo de processamento (yymin:zz.zs) e o número de classes e de segmentos obtidos nas segmentações produzidas pelo MUM para cada valor de p estão contidos na Tabela 8.23.

TABELA 8.23 - TEMPO DE PROCESSAMENTO E NÚMERO DE CLASSES E DE SEGMENTOS OBTIDOS

<i>p</i>	Tempo	Classes	Segmentos
1	34:36.7	252	11542
2	34:52.6	250	5463
3	35:09.3	240	3440
4	35:24.0	232	2470
5	35:38.9	228	1921
6	35:51.9	225	1524
7	36:07.7	224	1219
8	36:29.1	218	1005
9	37:04.4	216	842
10	37:14.2	200	691
11	37:30.9	187	581
12	38:02.8	179	504
13	38:25.1	180	428
14	38:31.3	169	382
15	38:40.3	151	323
16	39:03.1	141	287
17	39:23.8	129	269

Da Tabela 8.23 observou-se que o número de classes distintas e o número total de segmentos diminuiu à medida que o valor do parâmetro p foi aumentado.

Considerando-se a segmentação de referência (45 segmentos), quase todos os valores de p produziram segmentações com excessivo número de segmentos. O tempo de processamento requerido para produzir as segmentações aumentou proporcionalmente ao valor atribuído ao parâmetro p .

Considerando-se os resultados da avaliação qualitativa e quantitativa da qualidade de todas as segmentações da imagem real produzidas pelo MUM, a obtida com p igual a 14 foi eleita como a mais representativa da verdadeira. Comparativamente ao obtido para a imagem simulada de 3 *looks* ($p = 5$), este valor foi muito maior. Esta diferença pode ser devida à correlação espacial presente na imagem real e também pela sua maior complexidade em termos de número, forma e distribuição espacial dos segmentos. Outra razão pode ser devido ao contraste entre as regiões desta imagem, para a qual foi necessário um valor maior de p para produzir uma segmentação que apresentasse regiões

de tamanho médio maior como os presentes na segmentação de referência. Cabe salientar que embora os valores de p iguais a 5 e 14 tenham sido escolhidos como os que produziram, respectivamente, a melhor segmentação da imagem simulada de 3 *looks* e da imagem real (3,5 *looks*), os mesmos foram selecionados dentre um subconjunto de valores obtidos para cada imagem e que também produziram segmentações qualitativa e quantitativamente satisfatórias do ponto de vista da comparação com a segmentação de referência.

8.3.2 - RESULTADOS OBTIDOS PELO RWSEG

8.3.2.1 - AVALIAÇÃO QUALITATIVA

A partir da comparação visual das 96 segmentações produzidas pelo RWSEG com a segmentação de referência verificou-se que o aumento do valor do parâmetro e , para um mesmo j , originou segmentações com menor número de segmentos. Do mesmo modo, para um mesmo valor de e , o aumento do valor do parâmetro j produziu o mesmo efeito.

A influência do valor atribuído ao parâmetro j pode ser verificada a partir das Figuras 8.42 e 8.43, as quais apresentam os mapas de bordas da segmentação de referência e das segmentações da imagem real produzidas pelo RWSEG com valores de e iguais a 1,65, 2,58, 3,29, 4,06 e 4,91 e, respectivamente, com valores de j igual a 0 e 8. Os valores de e apresentados representam uma amostragem dos 16 utilizados e compreende os valores máximo, mínimo e três intermediários.

A partir das Figuras 8.52 e 8.53, verificou-se que para um mesmo valor do parâmetro e , o aumento do valor atribuído ao parâmetro j ocasionou a diminuição do número total de segmentos. Também foi possível verificar que o aumento do valor atribuído ao parâmetro e , para um dado j , produziu o mesmo efeito.

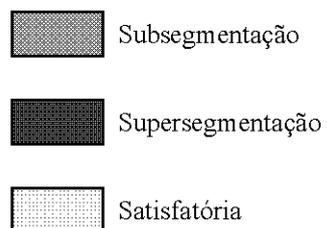
Da avaliação visual das 96 segmentações observou-se que as segmentações produzidas com valores de j iguais a 0, 2 e 4 apresentaram-se supersegmentadas para todos os valores do parâmetro e . Com j igual a 6 obteve-se resultados qualitativamente satisfatórios para valores de e superiores a 4,42 enquanto que com valores de j iguais a 8

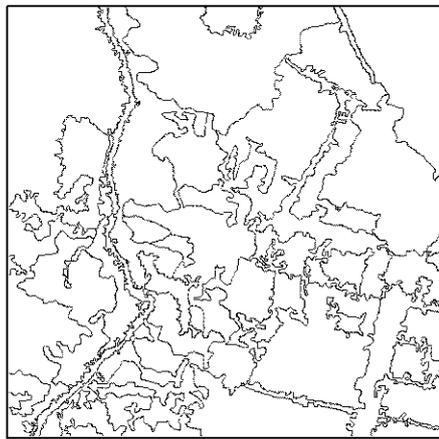
e 10 os resultados satisfatórios foram obtidos com valores de e superiores a 3,89. Nenhuma combinação entre os valores dos dois parâmetros produziu subsegmentação da imagem de entrada. A Tabela 8.24 apresenta a classificação qualitativa das segmentações produzidas pelo RWSEG em função dos valores dos parâmetros e (linhas) e j (colunas) selecionados.

As segmentações obtidas a partir dos subconjuntos de valores dos parâmetros e e j que produziram segmentações qualitativamente mais satisfatórias do ponto de vista da aplicação definida e da segmentação verdadeira (referência) proposta podem ser visualizadas a partir das Figuras 8.54 e 8.55, as quais apresentam a segmentação de referência e as segmentações da imagem de real produzidas pelo RWSEG selecionando-se os valores de e iguais a 4,27, 4,42, 4,57, 4,77 e 4,91 e valores de j iguais a 6, 8 e 10.

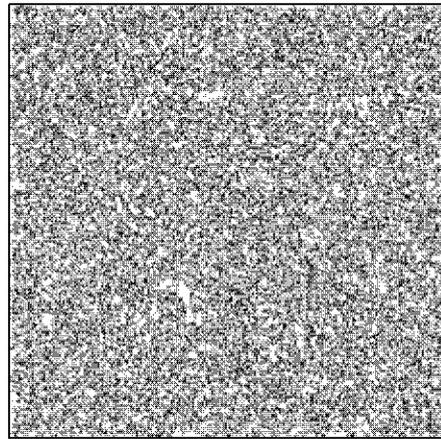
TABELA 8.24 - CLASSIFICAÇÃO QUALITATIVA DAS SEGMENTAÇÕES

<i>e</i>	<i>j</i>	0	2	4	6	8	10
1,65							
1,96							
2,33							
2,58							
2,81							
3,09							
3,29							
3,48							
3,72							
3,89							
4,06							
4,27							
4,42							
4,57							
4,77							
4,91							

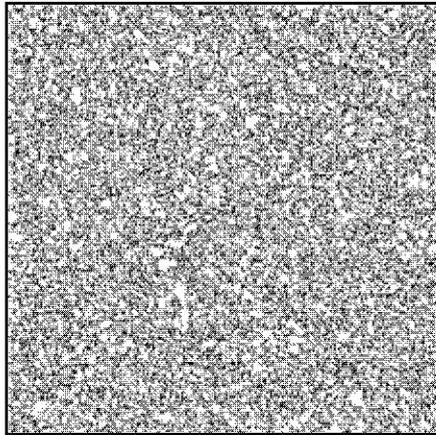




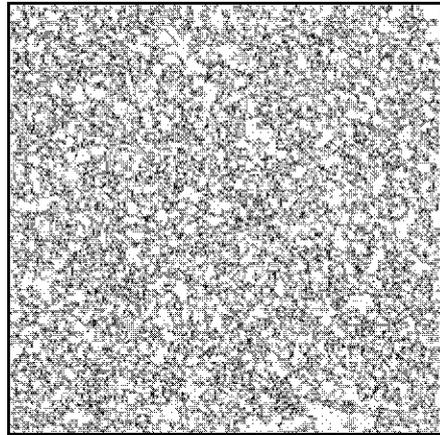
(a)



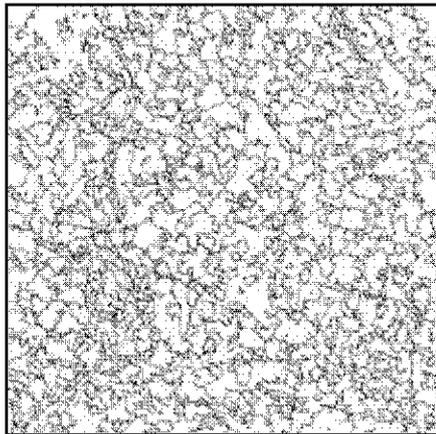
(b)



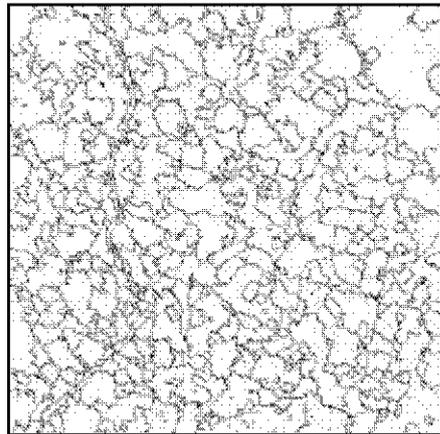
(c)



(d)

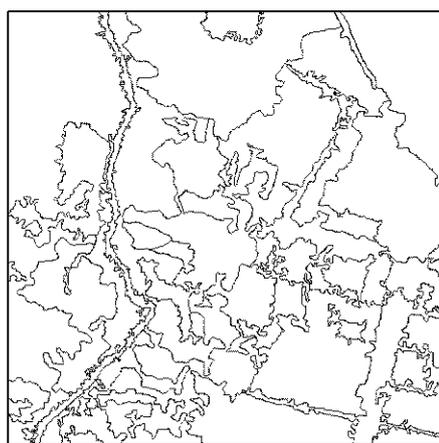


(e)

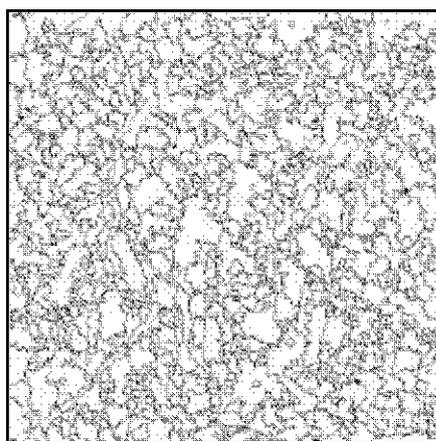


(f)

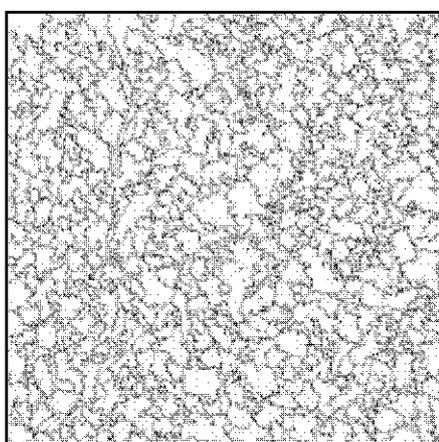
Fig. 8.52 - Segmentação manual (a) e segmentações da imagem real produzidas pelo RWSEG com $j=2$ e $e=1,65$ (b), $e=2,58$ (c), $e=3,29$ (d), $e=4,06$ (e) e $e=4,91$ (f).



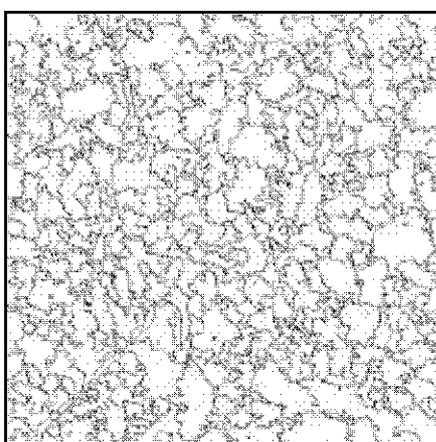
(a)



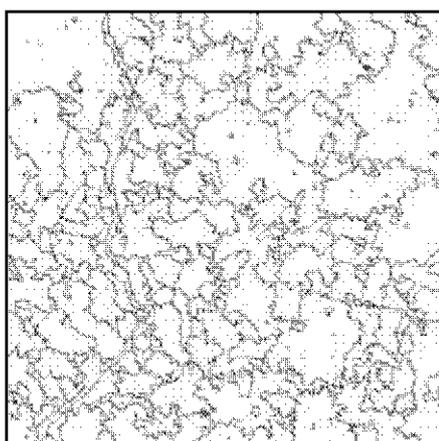
(b)



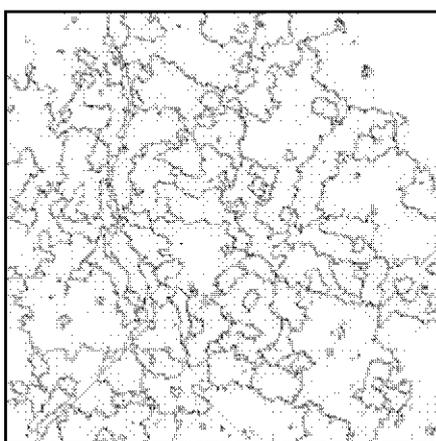
(c)



(d)

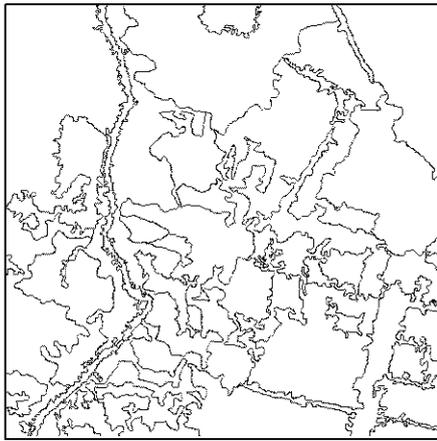


(e)

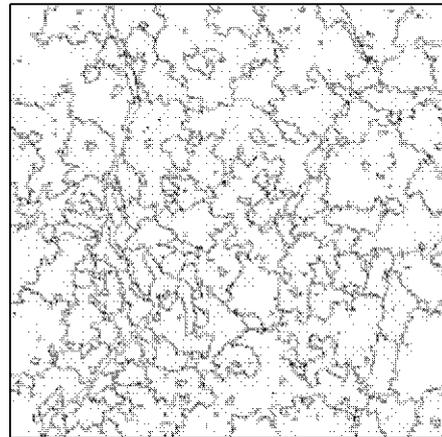


(f)

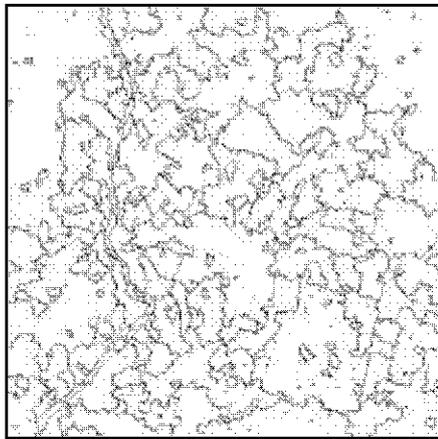
Fig. 8.53 - Segmentação manual (a) e segmentações da imagem real produzidas pelo RWSEG com $j=8$ e $e=1,65$ (b), $e=2,58$ (c), $e=3,29$ (d), $e=4,06$ (e) e $e=4,91$ (f).



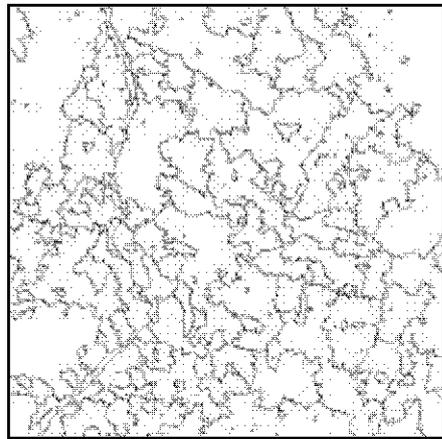
(a)



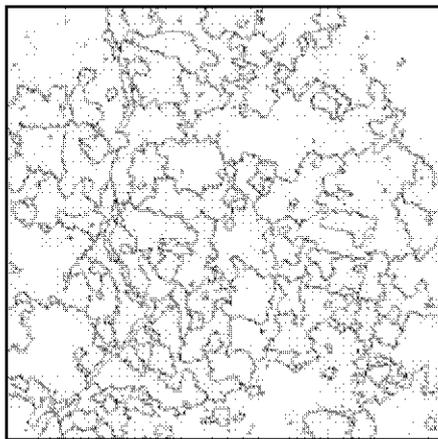
(b)



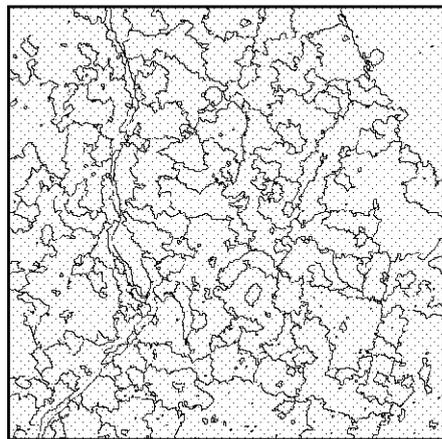
(c)



(d)

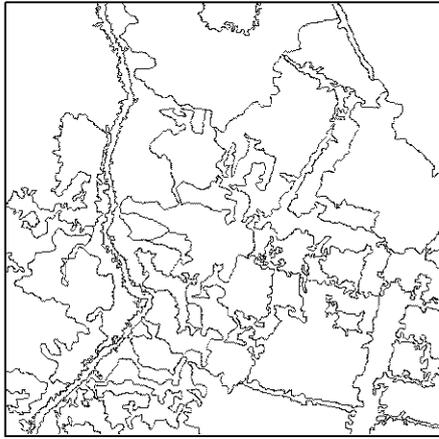


(e)

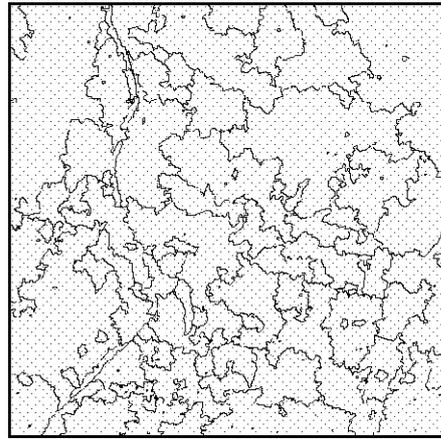


(f)

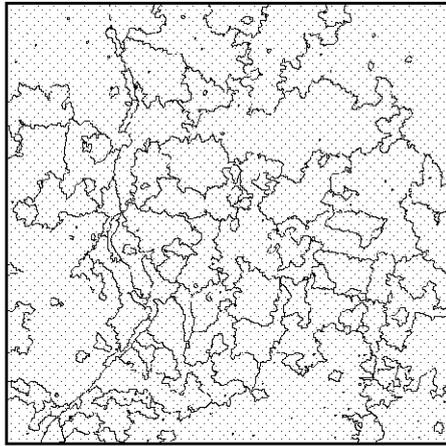
Fig. 8.54 - Segmentação manual (a) e segmentações produzidas pelo RWSEG com $j=8$ e $e=4,27$ (b), $e=4,42$ (c), $e=4,57$ (d), $e=4,77$ (e) e com $j=10$ e $e=4,91$ (f).



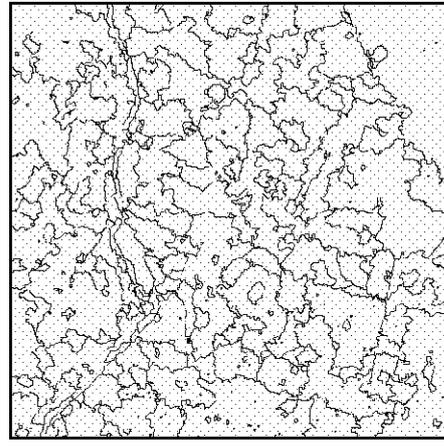
(a)



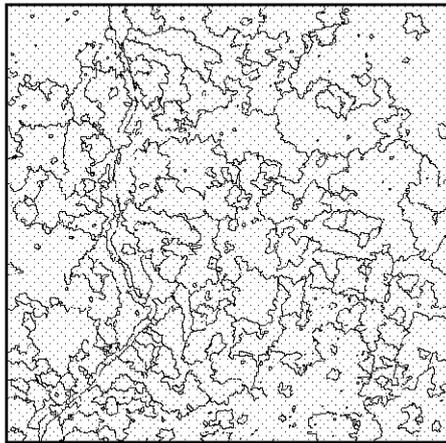
(b)



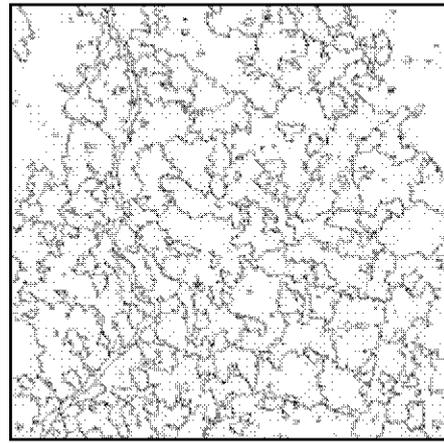
(c)



(d)



(e)



(f)

Fig. 8.55 - Segmentação manual (a) e segmentações produzidas pelo RWSEG com $j=10$ e $e=4,57$ (b), $e=4,77$ (c), $e=4,91$ (d) e com $j=6$ e $e=4,77$ (e) e $e=4,57$ (f).

Da análise das Figuras 8.54 e 8.55 verificou-se que as segmentações obtidas com e igual a 4,57 e j igual a 8 (Figura 8.54 d), com e igual a 4,57 e j igual a 10 (Figura 8.55 a) e com e igual a 4,77 e j igual a 8 (Figura 8.54 e) podem ser consideradas mais representativas da verdadeira (referência) do ponto de vista qualitativo.

8.1.2.2 - AVALIAÇÃO QUANTITATIVA

A avaliação quantitativa das segmentações produzidas foi realizada calculando-se a média geral das medidas de ajuste obtida em cada segmentação. A Figura 8.56 apresenta as médias gerais obtidas em cada uma das segmentações em função dos valores e e j selecionados.

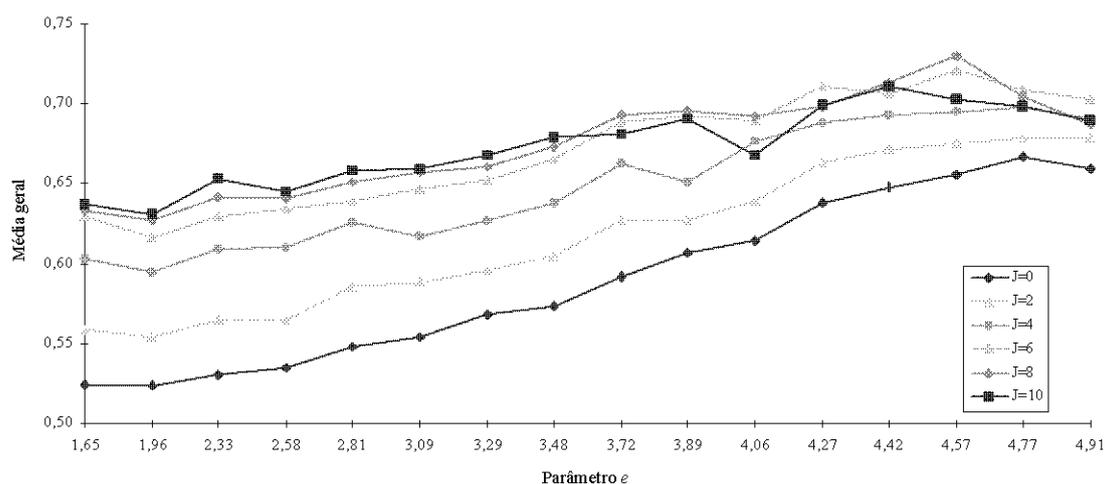


Fig. 8.56 - Média geral das segmentações produzidas pelo RWSEG.

Da Figura 8.56 verificou-se que as maiores médias gerais foram obtidas nas segmentações produzidas com valores de j iguais a 8 e 10 para a maioria dos parâmetros e , ao passo que as menores são obtidas com valores de j iguais a 0, 2 e 4. O intervalo de valores do parâmetro e compreendido entre 3,72 e 4,91 apresentaram as melhores médias gerais. Do ponto de vista quantitativo, a melhor segmentação produzida pelo RWSEG foi a obtida com e igual a 4,57 e j igual a 8 ($\hat{\mu}_g = 0,7302$).

O tempo de processamento (yymin:zz.zs) e o número de classes e de segmentos obtidos nas segmentações produzidas pelo RWSEG para cada combinação de valores de e e j selecionados estão contidos nas Tabelas 8.25 a 8.30.

TABELA 8.25 - TEMPO DE PROCESSAMENTO E NÚMERO DE CLASSES E DE SEGMENTOS OBTIDOS COM $J=0$

Parâmetros		Tempo	Classes	Segmentos
e	j			
1,65	0	1:48.6	240	16077
1,96	0	2:23.7	247	16425
2,33	0	2:32.0	246	13241
2,58	0	5:03.9	243	12591
2,81	0	3:20.9	240	10449
3,09	0	4:49.9	241	8903
3,29	0	5:44.3	244	7457
3,48	0	7:21.2	244	6265
3,72	0	5:22.3	241	4500
3,89	0	6:15.4	241	3865
4,06	0	4:54.1	243	3048
4,27	0	6:37.0	234	2575
4,42	0	4:17.9	226	1956
4,57	0	3:29.9	235	1713
4,77	0	4:26.5	228	1533
4,91	0	3:37.7	239	1418

TABELA 8.26 - TEMPO DE PROCESSAMENTO E NÚMERO DE CLASSES E DE SEGMENTOS OBTIDOS COM $J=2$

Parâmetros		Tempo	Classes	Segmentos
<i>e</i>	<i>j</i>			
1,65	2	1:43.5	239	8016
1,96	2	2:25.1	245	7783
2,33	2	2:32.8	239	6500
2,58	2	5:04.2	240	6168
2,81	2	3:22.3	237	5236
3,09	2	4:48.5	240	4638
3,29	2	5:41.0	240	3971
3,48	2	7:18.9	244	3430
3,72	2	5:23.1	235	2543
3,89	2	6:17.2	242	2266
4,06	2	4:57.6	241	1856
4,27	2	6:37.4	232	1580
4,42	2	4:19.5	223	1252
4,57	2	3:31.5	234	1109
4,77	2	4:27.1	225	1038
4,91	2	3:39.0	233	916

TABELA 8.27 - TEMPO DE PROCESSAMENTO E NÚMERO DE CLASSES E DE SEGMENTOS OBTIDOS COM $J=4$

Parâmetros		Tempo	Classes	Segmentos
<i>e</i>	<i>j</i>			
1,65	4	1:44.2	223	3489
1,96	4	2:26.6	230	3541
2,33	4	2:33.3	227	3057
2,58	4	5:03.3	226	2891
2,81	4	3:22.4	224	2514
3,09	4	4:50.3	227	2304
3,29	4	5:42.2	232	1989
3,48	4	7:31.4	230	1809
3,72	4	6:48.6	226	1417
3,89	4	7:16.0	235	1304
4,06	4	4:55.2	228	1126
4,27	4	6:38.5	227	1014
4,42	4	4:21.6	215	798
4,57	4	3:31.2	224	758
4,77	4	4:27.1	217	686
4,91	4	3:39.9	222	623

TABELA 8.28 - TEMPO DE PROCESSAMENTO E NÚMERO DE CLASSES E DE SEGMENTOS OBTIDOS COM $J=6$

Parâmetros		Tempo	Classes	Segmentos
<i>e</i>	<i>j</i>			
1,65	6	1:45.2	200	1538
1,96	6	2:25.3	213	1653
2,33	6	2:33.2	214	1434
2,58	6	5:05.1	202	1450
2,81	6	3:22.4	213	1230
3,09	6	4:50.5	207	1101
3,29	6	5:41.7	211	986
3,48	6	7:17.2	218	907
3,72	6	5:22.5	212	724
3,89	6	6:17.4	205	699
4,06	6	5:02.6	214	659
4,27	6	6:39.2	207	580
4,42	6	4:18.3	198	508
4,57	6	3:30.7	193	449
4,77	6	4:29.1	193	430
4,91	6	3:38.1	199	432

TABELA 8.29 - TEMPO DE PROCESSAMENTO E NÚMERO DE CLASSES E DE SEGMENTOS OBTIDOS COM $J=8$

Parâmetros		Tempo	Classes	Segmentos
<i>e</i>	<i>j</i>			
1,65	8	1:46.2	173	890
1,96	8	2:27.4	185	967
2,33	8	2:34.8	185	853
2,58	8	5:09.3	173	839
2,81	8	3:24.3	182	737
3,09	8	4:52.9	181	644
3,29	8	5:44.4	177	540
3,48	8	7:21.5	180	508
3,72	8	5:25.1	170	393
3,89	8	6:18.1	180	425
4,06	8	4:56.3	173	373
4,27	8	6:50.6	165	352
4,42	8	4:25.1	166	315
4,57	8	4:24.9	152	280
4,77	8	6:41.8	159	292
4,91	8	3:41.2	161	277

TABELA 8.30 - TEMPO DE PROCESSAMENTO E NÚMERO DE CLASSES E DE SEGMENTOS OBTIDOS COM $J=10$

Parâmetros		Tempo	Classes	Segmentos
e	j			
1,65	10	1:48.3	150	710
1,96	10	2:26.2	161	771
2,33	10	2:35.3	151	668
2,58	10	5:09.6	147	668
2,81	10	3:24.6	151	584
3,09	10	4:51.2	142	468
3,29	10	5:43.8	144	401
3,48	10	7:16.7	143	355
3,72	10	5:22.9	132	266
3,89	10	6:17.6	128	252
4,06	10	4:55.9	135	241
4,27	10	6:39.8	125	226
4,42	10	4:20.0	129	196
4,57	10	3:32.7	110	187
4,77	10	4:27.2	122	208
4,91	10	3:38.6	127	184

Das Tabelas 8.25 a 8.30 verificou-se que, para um dado valor do parâmetro j , o número de classes tendeu a variar em torno de um valor médio e o de segmentos tendeu a diminuir suavemente a medida que o valor do parâmetro e foi aumentado. Para um dado valor de e , o número de classes distintas e o número total de segmentos diminuiu à medida que o valor do parâmetro j foi aumentado. Considerando-se a segmentação de referência (45 segmentos), todos os valores de e e j produziram segmentações com excessivo número de segmentos, até mesmo as obtidas com valores elevados destes parâmetros.

O tempo de processamento requerido para produzir as segmentações foi praticamente o mesmo para todos os valores de e e um mesmo valor de j . Entretanto, o aumento do valor atribuído ao parâmetro j , para um mesmo valor de e , tendeu a aumentar o tempo de processamento requerido, principalmente para valores mais elevados.

Considerando-se os resultados da avaliação qualitativa e quantitativa da qualidade de todas as segmentações da imagem simulada real produzidas pelo RWSEG, a obtida com e igual a 4,57 e j igual a 8 foi eleita como a mais representativa da verdadeira.

Comparativamente ao obtido para a imagem simulada de 3 *looks* (e igual a 2,58 e j igual a 2), estes valores foram muito maiores. Esta diferença, a exemplo do comentado no caso do resultado obtido pelo MUM, pode ser devido a correlação espacial presente na imagem real, ao contraste entre as regiões e também pela maior complexidade em termos de número e distribuição espacial dos segmentos.

8.3.3 - COMPARAÇÃO DOS RESULTADOS OBTIDOS PELO MUM E RWSEG

A comparação foi feita a partir da segmentação mais representativa da verdadeira obtida pelo MUM (p igual a 14) e da obtida pelo RWSEG (e igual a 4,57 e j igual a 8) e do ponto de vista qualitativo, a partir da comparação visual com a segmentação de referência) e quantitativo, a partir da comparação das medidas de ajuste obtidas nestas segmentações.

A Figura 8.57 apresenta a imagem real e o mapa de bordas da segmentação de referência e das segmentações da imagem real eleitas como mais representativas da verdadeira obtidas pelo MUM e pelo RWSEG.

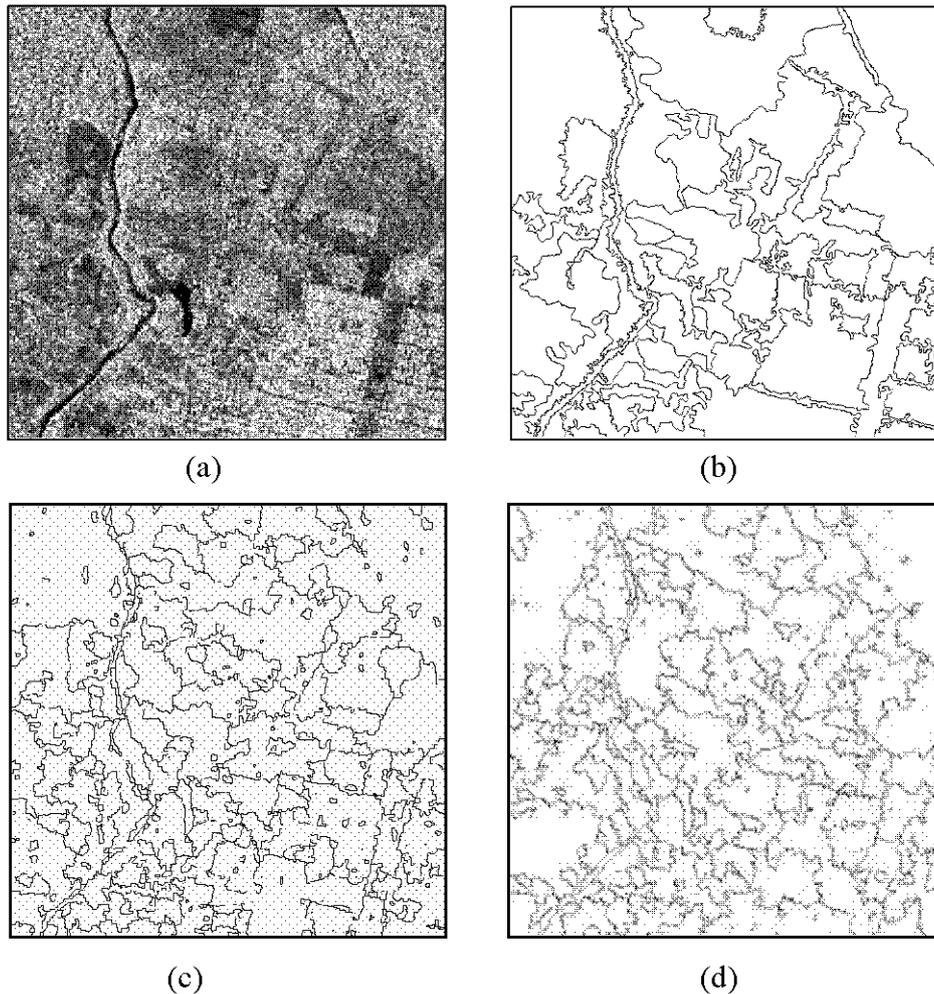


Fig. 8.57 - Imagem real (a), segmentação de referência (b) e segmentações da imagem real produzidas pelo MUM com $p=14$ (c) e RWSEG com $e=4,57$ e $j=8$ (d).

Da Figura 8.57 verificou-se visualmente que o MUM segmentou as regiões com características de extremamente heterogêneas (área urbana no quadrante inferior direito) com razoável correção de posição e forma. No entanto, as mesmas tenderam a ser subdivididas em um número maior de regiões. As com características heterogêneas (quadrantes superiores esquerdo e direito) foram segmentadas com boa correção em termos de posição e tamanho, porém com pouca correção em termos de forma. Também foi possível notar a presença de pequenas regiões internas. As regiões com características homogêneas (tons mais escuros) foram no geral muito subdivididas.

O RWSEG tendeu a supersegmentar as regiões com características heterogêneas, gerando segmentos com pouca correção em termos de tamanho e forma. As regiões com características extremamente heterogêneas foram segmentadas com boa correção de tamanho, forma e posição. As com características homogêneas foram segmentadas com boa correção de posição e tamanho.

A segmentação produzida pelo RWSEG foi mais limpa que a obtida pelo MUM, contrariamente aos resultados obtidos com as imagens simuladas, possivelmente devido a correlação espacial e maior complexidade da imagem real.

Os valores de Fit_{xy} , Fit_i , Fit_n , G_{forma} e a média e variância gerais obtidas da segmentação da imagem real produzida pelo MUM e da produzida pelo RWSEG são apresentadas na Tabela 8.31.

TABELA 8.31 - VALORES INDIVIDUAIS E MÉDIA E VARIÂNCIA GERAIS DAS MEDIDAS DE AJUSTE

	MUM		RWSEG	
	$\hat{\mu}_g$	$\hat{\sigma}_g^2$	$\hat{\mu}_g$	$\hat{\sigma}_g^2$
Fit_{xy}	0,9696	0,0006	0,9693	0,0007
Fit_i	0,9473	0,0056	0,9521	0,0038
Fit_n	0,6197	0,0827	0,6344	0,0871
G_{forma}	0,3488	0,0473	0,3650	0,0480
$\hat{\mu}_g$	0,7204	0,0085	0,7302	0,0087

Da Tabela 8.31 verificou-se que, do ponto de vista quantitativo, os dois algoritmos produziram segmentações com melhor correção em termos de posição e intensidade média que em termos de tamanho e forma. Comparativamente, a segmentação produzida

pelo RWSEG teve melhor correção em termos de intensidade média, tamanho e forma que a obtida pelo MUM, que por sua vez apresentou melhor correção em termos de posição. A média geral obtida pelo RWSEG também foi superior a obtida pelo MUM.

Comparando-se estes resultados com os obtidos para a imagem simulada de 3 *looks* no experimento Monte Carlo, verificou-se que em termos de ajustes de posição e intensidade média houve coincidência, mas em termos de ajustes de forma e de tamanho os resultados foram discordantes. Entretanto, considerando-se que os algoritmos foram equivalentes em termos de ajuste de tamanho no experimento Monte Carlo, o resultado obtido na imagem real em termos de ajuste de forma foi o mais discrepante. Com respeito a média geral, também não houve concordância entre os resultados, muito provavelmente causado pela diferença observada para a medida de ajuste da forma.

Entretanto, os valores de ajustes de posição, intensidade média, tamanho e forma obtidos da segmentação produzida pelo MUM e os da produzida pelo RWSEG foram estatisticamente iguais ao nível de significância de 5%. As médias gerais também foram estatisticamente iguais ao nível de significância de 5%. Além disto, cabe ressaltar que a comparação entre os dois algoritmos a partir de uma única imagem pode levar a conclusões equivocadas. Como observado no experimento Monte Carlo, muito embora a média amostral das médias gerais obtidas nas segmentações produzidas pelo MUM tenha sido estatisticamente maior ao nível de significância de 5%, houve casos em que segmentações obtidas pelo RWSEG tiveram maior média geral.

O efeito da variação dos valores dos parâmetros individuais de cada algoritmo na segmentação produzida da imagem real foram os mesmos observados para as imagens simuladas no tocante ao custo computacional e número de segmentos gerados.

O tempo de processamento e número de classes e de segmentos obtidos da segmentação da imagem real produzida pelo MUM e da produzida pelo RWSEG são apresentadas na Tabela 8.32.

TABELA 8.32 - TEMPO DE PROCESSAMENTO E NÚMERO DE CLASSES E DE SEGMENTOS

	Tempo	Classes	Segmentos
MUM	38:31.3	169	382
RWSEG	4:24.9	152	280

Da Tabela 8.32 verificou-se que o número de classes das duas segmentações foi muito próximo, mas o número de segmentos da produzida pelo RWSEG foi substancialmente menor. O custo computacional requerido pelo RWSEG para segmentar a imagem real foi cerca de 10,5% do requerido pelo MUM.

CAPÍTULO 9

CONCLUSÕES

O objetivo deste trabalho foi avaliar e comparar dois algoritmos de segmentação de imagens SAR presentes no *software* CAESAR, o MUM (*Merge Using Moments*, Cook et al., 1994) e o RWSEG (White, 1986), tomando por base a aplicação dos mesmos em estudos de uso e ocupação do solo e do ponto de vista da qualidade das segmentações produzidas, da capacidade de segmentar regiões de diferentes graus de homogeneidade, do custo computacional, e da simplicidade de operação.

De acordo com os critérios utilizados para a avaliação da qualidade (inspeção visual e medidas de ajustes de posição (*Fitxy*), intensidade média (*Fiti*), tamanho (*Fitn*), forma (*Gforma*) e média geral ($\hat{\mu}_g$) das segmentações produzidas de uma única imagem simulada de 3 *looks*, uma de 8 *looks* e da imagem real pode-se concluir que:

- ❖ o MUM e o RWSEG são capazes de produzir segmentações com qualidade satisfatória para serem utilizadas em aplicações de uso e ocupação do solo;
- ❖ a maioria dos valores selecionáveis dos parâmetros dos dois algoritmos produzem sub ou supersegmentação da imagem de entrada:
- ❖ das 17 segmentações possíveis que o MUM pode produzir de uma mesma imagem de entrada, 7 (41%) foram consideradas qualitativamente satisfatórias para a imagem simulada de 3 *looks*, 8 (47%) para a de 8 *looks* e 6 (35%) para a imagem real; e
- ❖ das 96 segmentações possíveis que o RWSEG pode produzir de uma mesma imagem de entrada, 12 (12,5%) foram consideradas qualitativamente satisfatórias para a imagem simulada de 3 *looks* e 15 (15,6%) para as de 8 *looks* e imagem real.

- ❖ a escolha dos valores dos parâmetros para obtenção do melhor resultado qualitativo e quantitativo é dependente do dado de entrada;
- ❖ a influência dos valores dos parâmetros no tempo de processamento, número de classes e de segmentos das segmentações obtidas pelos 2 algoritmos foi a mesma para as 3 imagens:
 - ❖ MUM: aumento do valor atribuído ao parâmetro p gerou segmentações com menor número de classes, menor número de segmentos e maior tempo de processamento; e
 - ❖ RWSEG: aumento do valor atribuído ao parâmetro e gerou segmentações com menor número de segmentos e pequeno aumento no tempo de processamento. O aumento do valor atribuído ao parâmetro j gerou segmentações com menor número de segmentos e maior tempo de processamento.

Estes resultados podem ser entendidos a partir da análise da estrutura dos algoritmos. No caso do MUM, uma vez que o valor do parâmetro p define quão diferentes duas regiões adjacentes devem de ser em termos de intensidade média para serem consideradas distintas entre si, o aumento do seu valor aumenta a probabilidade de duas regiões serem a mesma (provinda de um mesmo retroespalhamento) e assim regiões com “pequenas” diferenças de intensidade média são agrupadas e desta forma menos regiões distintas são produzidas.

No caso do RWSEG, o valor do parâmetro e define a probabilidade de detecção de bordas (em termos de números de desvio padrão), que é equivalente a uma certa probabilidade de falso alarme. O aumento do valor de e diminui a probabilidade de falso alarme, ocasionando uma diminuição do número de bordas criadas e resultando em segmentações com menor número de classes e de segmentos.

O valor do parâmetro j define a probabilidade de agrupamento de regiões (em termos de números de desvio padrão). Desta forma, quanto maior seu valor, maior a probabilidade de duas regiões vizinhas serem da mesma classe (provindas de um mesmo

retroespalhamento) e conseqüentemente agrupadas, resultando em segmentações com menor número de classes e de segmentos.

- ❖ os dois algoritmos produziram maior número de segmentações qualitativamente satisfatórias para a imagem de 8 *looks* que para as imagens de 3 *looks* e imagem real.

Este resultado se deve ao fato das variâncias nos dados das regiões da imagem de 8 *looks* serem menores que as da imagem de 3 *looks* e também pela maior redução do ruído *speckle* decorrente do processamento *multilook*.

De acordo com a média ($\hat{\mu}_e$) e a variância ($\hat{\sigma}_e^2$) amostrais das medidas de ajustes de posição, intensidade média, tamanho, forma e média geral obtidas para cada uma das segmentações produzidas pelos dois algoritmos das imagens simuladas replicadas de 3 e de 8 *looks* no experimento Monte Carlo pode-se concluir que:

- ❖ os dois algoritmos produziram segmentações com boa correção de posição, intensidade média, tamanho e forma dos segmentos gerados;
- ❖ o MUM produziu segmentações mais corretas que as do RWSEG em termos de posição e forma ao nível de significância de 1%;
- ❖ o RWSEG produziu segmentações mais corretas que as do MUM em termos de intensidade média ao nível de significância de 5% para as imagens de 3 *looks* e ao nível de significância de 1% para as de 8 *looks*;
- ❖ as segmentações produzidas pelos dois algoritmos foram equivalentes em termos de correção de tamanho ao nível de significância de 5%;
- ❖ para a maioria das segmentações das imagens replicadas, tanto de 3 quanto de 8 *looks*, a média geral obtida pelo MUM foi superior à obtida pelo RWSEG. Considerando-se a média amostral das médias gerais obtidas das 100 segmentações, a obtida pelo MUM foi superior à do RWSEG ao nível de significância de 1%;

- ❖ a média ($\hat{\mu}_e$) e a variância ($\hat{\sigma}_e^2$) amostrais das medidas de ajuste de posição, intensidade média, tamanho, forma e média geral obtidas para as segmentações das imagens replicadas de 8 *looks* obtidas tanto pelo MUM quanto pelo RWSEG foram superiores às obtidas para as de 3 *looks* ao nível de significância de 1%. Este resultado se deve ao fato das variâncias nos dados das regiões da imagem de 8 *looks* serem menores que as da imagem de 3 *looks* e também pela maior redução do ruído *speckle* decorrente do processamento *multilook*.

De acordo com os critérios utilizados para a avaliação da capacidade dos algoritmos para segmentar regiões com diferentes graus de homogeneidade (média e variância amostrais das medidas de ajuste de posição, intensidade média, tamanho, forma e média geral em função do tipo de região) obtidas das segmentações produzidas pelos dois algoritmos das imagens simuladas replicadas de 3 e de 8 *looks* no experimento Monte Carlo pode-se concluir que:

- ❖ os dois algoritmos tiveram desempenho satisfatório para segmentar os três tipos de regiões (homogêneas, heterogêneas e extremamente heterogêneas) nas imagens de 3 e de 8 *looks*;
- ❖ os dois algoritmos segmentaram os três tipos de regiões com melhor correção em termos de posição e intensidade média que em termos de tamanho e forma, tanto para as imagens de 3 quanto para as de 8 *looks*;
- ❖ a segmentação das regiões extremamente heterogêneas produzidas pelo MUM foi mais correta que as das homogêneas e heterogêneas em termos de posição, intensidade média, tamanho e forma ao nível de significância de 1%, tanto para as imagens de 3 quanto para as de 8 *looks*;
- ❖ a segmentação das regiões homogêneas produzidas pelo MUM foi mais correta que as das heterogêneas em termos de posição, intensidade média, tamanho e forma ao nível de significância de 1% para as imagens de 8 *looks* e em termos de posição e

forma ao nível de significância de 1% e tamanho ao nível de significância de 5% para as imagens de 3 *looks*;

- ❖ a segmentação das regiões extremamente heterogêneas produzidas pelo RWSEG foi mais correta que as das heterogêneas em termos de posição, intensidade média, tamanho e forma ao nível de significância de 1% tanto para as imagens de 3 quanto para as de 8 *looks*. Também foram mais corretas que as homogêneas em termos de posição, intensidade média, tamanho e forma ao nível de significância de 1% para as imagens de 8 *looks* e em termos de forma ao nível de significância de 1% e tamanho e intensidade média ao nível de significância de 5% para as imagens de 8 *looks*;
- ❖ a segmentação das regiões homogêneas produzidas pelo RWSEG foi mais correta que as das heterogêneas em termos de posição, tamanho e forma ao nível de significância de 1% e estatisticamente igual em termos de intensidade média ao nível de significância de 5%, tanto para as imagens de 3 quanto para as de 8 *looks*;
- ❖ o MUM e o RWSEG tiveram melhor desempenho para segmentar, respectivamente, as regiões extremamente heterogêneas, homogêneas e heterogêneas, ao nível de significância de 1%, tanto para as imagens de 3 quanto para as de 8 *looks*;
- ❖ o MUM foi melhor que o RWSEG para segmentar regiões heterogêneas e extremamente heterogêneas ao nível de significância de 1%, tanto para as imagens de 3 quanto para as de 8 *looks*;
- ❖ o MUM e o RWSEG tiveram o mesmo desempenho para segmentar regiões homogêneas das imagens de 8 *looks* ao nível de significância de 5%. Para as imagens de 3 *looks* o RWSEG teve melhor desempenho ao nível de significância de 1%.
- ❖ o desempenho dos algoritmos para segmentar os três tipos de regiões foi melhor em termos de posição, intensidade média, tamanho, forma e média geral nas imagens de 8 *looks*;

Os dois algoritmos tiveram melhor desempenho quantitativo para segmentar as regiões extremamente heterogêneas que para as homogêneas, embora os mesmos tenham sido desenvolvidos sob hipóteses distribucionais aplicáveis somente para regiões homogêneas. Uma possível explicação é que todas as regiões extremamente heterogêneas das imagens simuladas possuem valores médios de intensidade bem diferenciado dos das regiões vizinhas. O fato do MUM e do RWSEG utilizarem testes estatísticos baseados na comparação entre as médias dos valores de intensidade de regiões vizinhas possibilita uma maior precisão no processo de localização de bordas entre regiões de maior contraste, onde a diferença entre estas médias é maior.

Com respeito ao custo computacional pode-se concluir que:

- ❖ para segmentar uma mesma imagem, o tempo médio de processamento requerido pelo MUM é 11 vezes maior que o requerido pelo RWSEG.

Com respeito a adequação do MUM e do RWSEG para o tipo de aplicação proposto pode-se concluir que:

- ❖ os dois algoritmos mostraram-se adequados para emprego em estudo do uso e ocupação do solo, uma vez que:
 - ❖ produziram segmentações satisfatórias do ponto de vista qualitativo e quantitativo, tanto das imagens simuladas quanto da imagem real; e
 - ❖ foram capazes de segmentar com boa correção os três tipos distintos de regiões.

Do ponto de vista da simplicidade de operação dos algoritmos pode-se afirmar que o MUM é um algoritmo mais amigável que o RWSEG:

- ❖ o MUM necessita da seleção do valor de um único parâmetro, o qual possui 17 valores possíveis. Embora o valor do parâmetro l (especificação do número de *looks* da imagem de entrada) deva ser selecionado também, este valor é

geralmente conhecido pelo usuário. Além disto, o próprio algoritmo pode estimar este valor caso não seja selecionado; e

- ❖ o RWSEG necessita da seleção do valor de 2 parâmetros. A necessidade de seleção de valores para dois parâmetros, bem como o número de valores possíveis dos mesmos, dificulta a aplicação do RWSEG. Para decidir sobre quais valores são mais adequados para cada parâmetro, o usuário necessita de noções sobre a influência de cada um e de alguns testes para a tomada de decisão no momento da seleção. Por outro lado, essas possibilidades tem como vantagem a capacidade de gerar um número muito maior de segmentações distintas de uma mesma imagem, dando ao usuário mais opções de obter uma segmentação adequada para seu objetivo.

Para estudos de uso e ocupação do solo e dado que os dois algoritmos parecem ser adequados para tal aplicação, a decisão do emprego de um ou outro algoritmo deve ser balizada pelos critérios avaliados neste trabalho. Desta forma, se o fator mais importante for:

- ❖ a qualidade da segmentação: aconselha-se o uso do MUM, uma vez que o mesmo produz segmentações com melhor correção de forma e posição dos segmentos gerados. Deve-se considerar também o emprego de imagens com maior número de *looks*;
- ❖ o custo computacional: aconselha-se o uso do RWSEG, uma vez que o mesmo requer um tempo de processamento bem menor que o MUM para segmentar a mesma imagem;
- ❖ a simplicidade de operação: aconselha-se o uso do MUM;
- ❖ segmentar imagens contendo regiões homogêneas: aconselha-se o uso do RWSEG, uma vez que o mesmo é equivalente ao MUM para segmentar corretamente este tipo de região e pelo fato de exigir menor custo computacional;

- ❖ segmentar imagens contendo regiões heterogêneas: aconselha-se o uso do MUM;
- ❖ segmentar imagens contendo regiões extremamente heterogêneas: aconselha-se o uso do MUM;
- ❖ segmentar imagens contendo os três tipos de regiões: aconselha-se o uso do MUM.

O experimento Monte Carlo foi de vital importância para obtenção das conclusões deste trabalho. Isto porque a avaliação e comparação dos algoritmos com base nos resultados obtidos de uma única imagem pode levar a conclusões impróprias. Este fato pode ser constatado quando da análise das médias gerais obtidas das segmentações produzidas das imagens replicadas de 3 e 8 *looks*, na qual se observa uma alternância entre a média geral obtida pelo MUM e a obtida pelo RWSEG para as diferentes segmentações. Tais variações entre a melhor média geral deixa claro que uma única imagem não poderia permitir uma conclusão confiável.

Para realização de trabalhos futuros ligados à segmentação de imagens SAR pode-se apresentar as seguintes sugestões:

- ❖ desenvolver algoritmos adaptados para os diferentes tipos de regiões, ou seja, que não se limitem à suposição da modelagem do retroespalhamento como uma distribuição constante;
- ❖ desenvolver algoritmos que levem em consideração a existência de correlação espacial entre pixels;
- ❖ avaliar a adequação destes algoritmos para outros tipos de aplicações;
- ❖ avaliar os algoritmos a partir de imagens reais obtidas a partir de diferentes sensores e em diferentes configurações.

REFERÊNCIAS BIBLIOGRÁFICAS

- Bustos, O.H.; Frery, A.C. **Simulação estocástica: teoria e algoritmos**. Rio de Janeiro: IMPA, 1992.
- Bénié, G.B.; Thomsom, K.P.B.; Goldberg, M. A comparison of four segmentation algorithms in the context of agricultural remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 44, n. 1, p. 1-13, 1989.
- Caves, R.; Quegan, S.; White, R.G. Quantitative comparison of the performance of SAR segmentation algorithms. **IEEE Transactions IP**, 1996.
- Caves, R. **Automatic matching of features in synthetic aperture radar data to digital map data**, n. 15, p. 12-19, (PhD thesis) - University of Sheffield, 1993.
- Cook, R.; McConnell, I.; Oliver, C.J. MUM (Merge Using Moments) segmentation for SAR images. In: Proc. SPIE, 2316, 92-103, 1994.
- DeGroot, M.H. **Probability and statistics**. Menlo Park: Addison-Wesley, 1975.
- 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, 1992.
- Don, H.S.; Fu, K.S. A syntactic method for image segmentation and object recognition. **Pattern Recognition**, v. 18, n. 1, p. 73-87, 1985.
- Dutra, L.V.; Frery, A.C.; Krug, T.; Mascarenhas, N.D.A.; Sant'Anna, S.J.S.; Yanasse, C.C.F. Alguns aspectos de modelagem estatística de dados de sensoriamento remoto. In: Simpósio Brasileiro de Sensoriamento Remoto, 7., Curitiba, 10-14 maio 1993. **Anais**. São José dos Campos, INPE/SELPER/SBC, 1993. Tutorial 1.

ENVI 3.0 user's guide: the environment for visualizing images. version 3.0, December 1997 edition. Lafayette, Better Solutions Consulting, 1993–1997. Under contract of Research Systems Inc.

Frery, A.C. **Algumas ferramentas estatísticas na síntese, processamento e análise de imagens radar de abertura sintética.** Tese (Doutorado) – Instituto Nacional de Pesquisas Espaciais, 1993.

Frery, A.C.; Yanasse, C.C.F.; Sant'Anna, S.J.S. Statistical characterization of SAR data: the multiplicative model and extensions. In: Simpósio Latinoamericano de Percepción Remota, 7 : Sexta Reunión Nacional, SELPER, México, Puerto Vallarta, 5-10 nov 1995. **Memórias**, p. 502-515.

Frery, A.C.; Yanasse, C.C.F.; Sant'Anna, S.J.S. **Alternative distributions for the multiplicative model in SAR images.** São José dos Campos, INPE, 1995. (INPE-5624-PRE/1823).

Frery, A.C.; Müller, H.J.; Yanasse, C.C.F.; Sant'Anna, S.J.S. A model for extremely heterogeneous clutter. **IEEE Transactions of Geoscience and Remote Sensing**, v.35, n. 3, p. 1-12, 1997.

Frost, V.S.; Shanmugan, K.S.; Holtzman, J.C. Edge detection for synthetic aperture radar and other noisy images. In: IGARSS, WA-5, v. 2, p. 41-49, 1982.

Gerbrands, J.J.; Backer, E. Split-and-merge segmentation of Slar-imagery: segmentation consistency. IEEE International Conference on Pattern Recognition 7., V. 1, p. 284-286, Montreal, Canada, July 30 – Aug 2, 1984.

Gonzales, R.C.; Wintz, P. **Digital image processing.** New York: Addison-Wesley, 1987.

Haralick, R.M.; Shapiro, L.G. **Image segmentation techniques.** Machine Vision International: Ann Arbor, 1984.

- Jacobo-Berteles, J.; Mejail, M. Comunicação pessoal, 1998.
- James, B.R. **Probabilidade**: um curso em nível intermediário. Rio de Janeiro: IMPA, 1991.
- Le Moigne, J.; Tilton, J.C. Refining image segmentation by integration of edge and region data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 33, n. 3, p. 605-615, May, 1995.
- NASoftware. **Caesar**: user guide. Version 2.1. Liverpool, 1994.
- Oddy, C.J.; Rye, A.J. Segmentation of SAR images using a local similarity rule. **Pattern Recognition Letters**, v.1, p. 443-449, July, 1983.
- Quegan, S.; Rye, A.J.; Hendry, A.; Skingley, J.; Oddy, C.J. Automatic interpretation strategies for synthetic aperture radar images. **Philosophical Transactions of the Royal Society of London**. A 324, p. 409-421, 1988.
- Rosenfeld, A., Thurston, M. Edge detection for visual analysis. **IEEE Transactions on Computers**, V. C-20, n. 5, p. 562-565, May, 1971.
- Rosenfeld, A., Thurston, M.; Lee, Y.H. Edge and curve detection: further experiments. **IEEE Transactions on Computers**, v. C-21, n. 7, p. 677-715, July, 1972
- Sant'Anna, S.J.S. **Avaliação de desempenho de filtros redutores de speckle em imagens de radar de abertura sintética**. Dissertação (mestrado em Sensoriamento Remoto). São José dos Campos, INPE, 1995.
- Schoenmakers, R.P.H.M.; Wilkinson, G.G.; Schouten, Th.E. Segmentation of remotely-sensed images: a re-definition for operational applications. IGARSS'91, Espoo, Finland, v. 2, p. 1087-1090, 1991.

- Taylor, A.M.; Corr, D.G.; Gross, A.; Hogg, D.G.; Lawrence, D.H.; Mason, D.C.; Petrou, M.; Vango, R.D. Development of a knowledge-based segmentor for remotely sensed images. **Philosophical Transactions of the Royal Society of London**. A 324, p. 437-446, 1988.
- Touzi, R.; Lopes, A.; Bousquet, P. A statistical and geometrical edge detector for SAR images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 26, p. 764-773, 1988.
- Ulaby, F. T.; Moore, R. K.; Fung, A. K. **Microwave remote sensing: active and passive**. Norwood: Artech House, 1986. v. 3, p. 1097.
- Ulaby, F.T.; Dobson, M.C. **Handbook of radar scattering statistics for terrain**. Norwood, Artech House, 1989.
- White, R.G. **Low-Level segmentation of noise imagery.**, DRA, Royal Signal and Radar Establishment: Works, 1986. (Memorandum 3900).
- Vieira, P.R. **Desenvolvimento de classificadores de máxima verossimilhança e ICM para imagens SAR**. Dissertação (mestrado em Sensoriamento Remoto)-Instituto Nacional de Pesquisas Espaciais, 1996.
- Yanasse, C.C.F. **Statistical analysis of synthetic aperture radar images and its applications to system analysis and change detection**. PhD (Thesis), University of Sheffield, 1991.
- Yanasse, C.C.F; Frery, A.C.; Sant'Anna, S.J.S.; Hernandes, P.F.; Dutra, L.V. Statistical analysis of SAREX data over Tapajós-Brasil. In: Final Results Workshop for SAREX'92, Paris, 1993, p. 25-40.
- Yanasse, C.C.F.; Frery, A.C.; 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. (INPE-56630-NTC/318).

Zhang, Y.J. A survey on evaluation methods for image segmentation. **Pattern Recognition**, v. 29, n. 8, p. 1335-1346, 1996.

Zucker, S.W. Region growing: childhood and adolescence. **Computer Graphics and Image Processing**, v. 5, n. 2, p. 382-389, 1976.