



Ministério da
**Ciência, Tecnologia
e Inovação**



o sid.inpe.br/mtc-m19/2014/01.22.12.39-TDI

UM SEGMENTADOR MULTINÍVEL PARA IMAGENS SAR POLARIMÉTRICAS BASEADO NA DISTRIBUIÇÃO WISHART

Marcus Fabiano Silva Saldanha

Tese de Doutorado do Curso de Pós-Graduação em Computação Aplicada, orientada pelos Drs. Corina da Costa Freitas, e Sidnei João Siqueira Sant'Anna aprovada em 29 de novembro de 2013.

URL do documento original:

<<http://urlib.net/8JMKD3MGP7W/3FKAGTL>>

INPE
São José dos Campos
2013

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

Fax: (012) 3208-6919

E-mail: pubtc@sid.inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE (RE/DIR-204):

Presidente:

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

Membros:

Dr. Antonio Fernando Bertachini de Almeida Prado - Coordenação Engenharia e Tecnologia Espacial (ETE)

Dr^a Inez Staciarini Batista - Coordenação Ciências Espaciais e Atmosféricas (CEA)

Dr. Gerald Jean Francis Banon - Coordenação Observação da Terra (OBT)

Dr. Germano de Souza Kienbaum - Centro de Tecnologias Especiais (CTE)

Dr. Manoel Alonso Gan - Centro de Previsão de Tempo e Estudos Climáticos (CPT)

Dr^a Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação

Dr. Plínio Carlos Alvalá - Centro de Ciência do Sistema Terrestre (CST)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon - Coordenação de Observação da Terra (OBT)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

Yolanda Ribeiro da Silva Souza - Serviço de Informação e Documentação (SID)

EDITORAÇÃO ELETRÔNICA:

Maria Tereza Smith de Brito - Serviço de Informação e Documentação (SID)

André Luis Dias Fernandes - Serviço de Informação e Documentação (SID)



Ministério da
**Ciência, Tecnologia
e Inovação**



o sid.inpe.br/mtc-m19/2014/01.22.12.39-TDI

UM SEGMENTADOR MULTINÍVEL PARA IMAGENS SAR POLARIMÉTRICAS BASEADO NA DISTRIBUIÇÃO WISHART

Marcus Fabiano Silva Saldanha

Tese de Doutorado do Curso de Pós-Graduação em Computação Aplicada, orientada pelos Drs. Corina da Costa Freitas, e Sidnei João Siqueira Sant'Anna aprovada em 29 de novembro de 2013.

URL do documento original:

<http://urlib.net/8JMKD3MGP7W/3FKAGTL>

INPE
São José dos Campos
2013

Dados Internacionais de Catalogação na Publicação (CIP)

Saldanha, Marcus Fabiano Silva.

Sa31u Um segmentador multinível para imagens SAR polarimétricas baseado na distribuição Wishart / Marcus Fabiano Silva Saldanha. – São José dos Campos : INPE, 2013.
xxxvi + 289 p. ; (o sid.inpe.br/mtc-m19/2014/01.22.12.39-TDI)

Tese (Doutorado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2013.

Orientadores : Drs. Corina da Costa Freitas, e Sidnei João Siqueira Sant’Anna.

1. segmentação de imagens SAR. 2. RADAR. 3. SegSAR. 4. PolSeg. 5. modelagem estatística. I.Título.

CDU 004.932:528.854

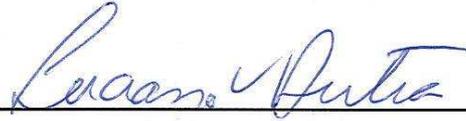


Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

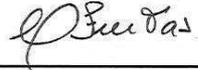
Aprovado (a) pela Banca Examinadora
em cumprimento ao requisito exigido para
obtenção do Título de **Doutor(a)** em
Computação Aplicada

Dr. Luciano Vieira Dutra



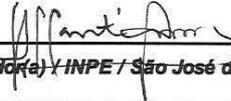
Presidente / INPE / SJCampos - SP

Dra. Corina da Costa Freitas



Orientador(a) / INPE / SJCampos - SP

Dr. Sidnei João Siqueira Sant'Anna



Orientador(a) / INPE / São José dos Campos - SP

Dra. Leila Maria Garcia Fonseca



Membro da Banca / INPE / SJCampos - SP

Dr. Antônio Henrique Correia



Convidado(a) / DSG/EB / Brasília - DF

Dr. Karlus Alexander Camara de Macedo



Convidado(a) / Orbisat / Campinas - SP

Este trabalho foi aprovado por:

maioria simples

unanimidade

Aluno (a): **Marcus Fabiano Silva Saldanha**

São José dos Campos, 29 de Novembro de 2013

“Terminando o jogo, o rei e o peão voltam à mesma caixa”

Provérbio Italiano

A meus pais.

AGRADECIMENTOS

À Diretoria de Serviço Geográfico (DSG), representada pelo seu antigo Diretor General de Divisão Carlos César Paiva de Sá, pela oportunidade que me foi dada.

Aos orientadores Dra. Corina da Costa Freitas e Dr. Sidnei João Siqueira Sant'Anna pela paciência, persistência e principalmente confiança no trabalho desenvolvido.

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

Aos docentes do Curso de Pós-Graduação em Computação Aplicada que realizaram a disseminação de conhecimentos para o desenvolvimento desta Tese.

Aos amigos da DSG e do INPE, que, em momentos difíceis, souberam prestar ajuda, apoio e incentivo para a conclusão deste trabalho.

A minha esposa e filha, pela compreensão nos momentos em que tive que me ausentar do convívio familiar.

RESUMO

A grande disponibilidade de imagens SAR polarimétricas complexas (PolSAR) e seu potencial de uso têm gerado a necessidade de desenvolvimento de técnicas automáticas de processamento para esses dados. Dentre estas se destaca a segmentação, responsável pela extração automática de feições a partir de uma cena para uma tarefa posterior. Para o desenvolvimento dos algoritmos de segmentação é comum adotar modelos estatísticos para explicar o comportamento dos dados. Para dados SAR, dependendo do tipo de dado e do grau de homogeneidade dos alvos imageados, diferentes distribuições podem ser adotadas para obter uma modelagem adequada. Dentro deste contexto, este trabalho tem por objetivo o desenvolvimento e implementação de um segmentador para imagens PolSAR. Tem ainda, como objetivo secundário investigar se o uso da informação polarimétrica permite melhor definição dos segmentos existentes na imagem SAR. O trabalho foi fundamentado sob duas hipóteses: que é possível desenvolver um algoritmo para segmentação de dados PolSAR usando a modelagem estatística adequada; e, que é possível obter melhor definição dos segmentos na segmentação de dados SAR usando as informações polarimétricas. Para atingir o objetivo traçado foi implementado em ambiente de programação IDL o algoritmo denominado de "PolSeg", que processa dados PolSAR e dados polarizados em intensidade. Para isso, foi adotada a distribuição Wishart complexa escalonada para modelar a matriz de covariância e fundamentar teoricamente os testes estatísticos usados durante o processo de segmentação. O algoritmo PolSeg é híbrido, pois faz uso de técnicas de crescimento e agrupamento de regiões, ajuste de bordas, teste de homogeneidade e teste de área mínima, integradas numa estrutura de compressão piramidal. Além disso, pode ser considerado ainda como hierárquico e multiníveis, e processa imagens mono ou multibandas. O algoritmo é inovador, pois associa a abordagem estatística apropriada para dados PolSAR à técnicas de segmentação e processamento de imagens multiníveis. A fim de constatar a eficiência da segmentação realizada pelo algoritmo PolSeg foram realizadas segmentações com dados simulados e reais. Adicionalmente foi realizado um estudo comparativo com o algoritmo SegSAR, o qual usa estrutura de processamento semelhante à do PolSeg para segmentar imagens SAR polarizadas em intensidade. Para avaliar quantitativamente o desempenho do algoritmo na segmentação dos dados PolSAR simulados foram utilizadas medidas que medem as propriedades de forma, dimensão, posição e intensidade dos segmentos, assim como o tempo computacional e o número regiões geradas na segmentação. Foi realizada também uma avaliação qualitativa do algoritmo de segmentação usando imagens PolSAR simuladas e reais. Para estas medidas, os resultados das segmentações dos dados polarimétricos simulados no PolSeg gerou valores, respectivamente, 0,6%, 0,4%, 2,0% e 2,6% superiores aos gerados com dados multivariados polarizados em intensidade. Para a comparação dos resultados usando dados simulados multivariados polarizados em intensidade no PolSeg e SegSAR, as medidas mostraram que o PolSeg gerou valores, respectivamente,

5,1%, 2,7%, 103,2% e 188,2% superiores aos gerados no SegSAR. O número de regiões e o tempo de processamento do PolSeg foram em média, respectivamente, 35 vezes menor que o gerado pelo SegSAR e 1,6 vezes maior que o tempo consumido pelo SegSAR.

A MULTILEVEL SEGMENTATION ALGORITHM FOR POLARIMETRIC SAR IMAGES BASED ON WISHART DISTRIBUTION

ABSTRACT

The great availability of polarimetric SAR data and its potential use has generated the need for developing automated techniques processing and analysis for these images. Among these can be highlight the segmentation, used for the automatic extraction of features from a scene for a future task. The developments of segmentation algorithms are usually based on statistical models to explain the behavior of the data. For SAR data, depending on the data type and the degree of homogeneity of the targets imaged, different distributions can be adopted to obtain an adequate modeling. Within this context, this paper aims to present the development and implementation of an algorithm to segment images PolSAR. It also has secondary objective, investigate if the use of polarimetric information allows a better definition of segments in the SAR image. This work was based on two hypothesizes: that it is possible to develop an algorithm for segmentation PolSAR data using appropriate statistical model, and that it is possible to obtain better definition of the segments in the segmentation of SAR data using the polarimetric information. To achieve the objective was implemented an algorithm in IDL programming language, called "PolSeg", which processes PolSAR data and polarized intensity data. For this, was adopted the scaled complex Wishart distribution to model the covariance matrix and theoretically substantiate the statistical tests used during the segmentation process. The PolSeg algorithm is hybrid, because it makes use of techniques of region growing, merging, adjust of borders, homogeneity test, segmentation of heterogeneous regions and minimum area test, integrated into a pyramidal structure compression. Moreover, it can still be considered as hierarchical and multi-level and process image in single or multi-band. The algorithm is groundbreaking because it combines the appropriate statistical approach to data PolSAR with segmentation techniques and processing of multilevel images. In order to verify the efficiency of segmentation with PolSeg several processing with real and simulated data were conducted. In addition, was performed a comparative study with SegSAR algorithm, which uses a processing structure similar to that adopted by PolSeg to process polarized intensity SAR data. To quantitatively evaluate the performance of the algorithm in the segmentation of the simulated PolSAR data, were used measures that quantify the properties of shape, size, position and intensity of the segments, as well as the computational time and the number of regions generated in the segmentation. A qualitative assessment of the

segmentation algorithm using simulated and real PolSAR images was also performed. For these measures, the results of segmentation of simulated polarimetric data in PolSeg generated values, respectively, 0.6%, 0.4%, 2.0% and 2.6% higher than those generated with multivariate polarized intensity data. To compare the results using multivariate simulated polarized intensity data in PolSeg and SegSAR, the measurements showed that the PolSeg generated values, respectively, 5.1%, 2.7%, 103.2% and 188.2% greater than those generated in SegSAR. The number of regions and processing time with the PolSeg were averaged, respectively, 35 times lower and 1.6 times greater than that obtained by SegSAR.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 - Regiões X e Y representadas nas componentes real (\Re) e imaginária (\Im) de uma imagem SAR complexa.	19
Figura 4.1 - Fluxograma da metodologia de trabalho.	47
Figura 4.2 - Imagem real em 1-look do sensor R99B usada na geração dos dados PolSAR simulados.	50
Figura 4.3 - Imagem simulada e imagem de referência, com os contornos e as médias em intensidade das regiões nas polarizações: (a) hh , (b) hv e (c) vv	50
Figura 4.4 - Imagem PolSAR do sensor SIR-C banda L, em intensidade na composição colorida $hh(R)$, $hv(G)$, $vv(B)$	52
Figura 4.5 - Imagem PolSAR do sensor R99B banda L, em intensidade na composição colorida $hh(R)$, $hv(G)$, $vv(B)$	53
Figura 5.1 - Estrutura de processamento do PolSeg.	65
Figura 5.2 - Interface de entrada de dados e parâmetros do PolSeg.	66
Figura 5.3 - Processo de compressão de uma imagem usando o critério de pirâmides hierárquicas até o nível de compressão igual a três de uma imagem com dimensão em linha e coluna de 16 <i>pixels</i>	73
Figura 5.4 - Descompressão em um nível de uma imagem comprimida conforme o critério de pirâmides hierárquicas.	83
Figura 5.5 - Definição dos pixels de borda para análise: (a) faixa de fronteira de uma região analisada (faixa de <i>pixels</i> delimitada por linha cheia); (b) <i>pixels</i> de borda da região analisada (cor vermelha); e, (c) <i>pixels</i> de borda das regiões vizinhas (cores azul e verde).	86

Figura 5.6 - Vinculação entre pixels de borda da região analisada (<i>ps</i>) e das regiões vizinhas (<i>pv</i>) e situações onde um <i>pixel</i> pode possuir mais que uma vinculação (índice lexicográfico sublinhado).	87
Figura 5.7 - Regiões analisada e vizinha com <i>pixels</i> de borda adjacentes.	87
Figura 5.8 - Exemplo do Caso 1 onde <i>pixels</i> de fronteira da região analisada se encontram vinculados a <i>pixel</i> de fronteira de regiões vizinhas na relação de um para um.....	91
Figura 5.9 - Exemplo do Caso 2 onde um <i>pixel</i> de fronteira da região analisada se encontra vinculado a dois <i>pixels</i> de fronteira de uma região vizinha (relação de um para dois).	93
Figura 5.10 - Exemplo do Caso 3 onde um <i>pixel</i> de fronteira da região analisada se encontra vinculado a dois <i>pixels</i> de fronteira pertencentes a regiões vizinhas distintas (relação de um para dois).	95
Figura 5.11 - Exemplos de desconexão de pixels decorrente da análise de bordas, onde o pixel de borda (destacado), da região analisada representada pelo <i>Id</i> igual a 1 (cor vermelha), se encontrava anteriormente em contato com: (a) dois pixels de borda pertencentes a uma única região vizinha representada pelo <i>Id</i> igual a 2 (cor azul); e, (b) dois pixels de borda pertencentes a regiões vizinhas distintas representadas pelos <i>Id</i> 's iguais a 2 e 3 (cores azul e verde).....	99
Figura 5.12 - Exemplo de geração de região desconectada de sua região original devido ao processo de análise de bordas: (a) imagem inicial; (b) imagem após um ciclo de processamento da segunda etapa; e, (c) imagem após dois ciclos de processamento da segunda etapa.....	100
Figura 5.13 - Geração de nova região a partir de <i>pixels</i> isolados de sua região original devido ao processo de análise de bordas: (a) imagem inicial; e, (b) imagem após um ciclo de processamento da segunda etapa com nova região gerada.....	100

Figura 5.14 - Limitação do processo de crescimento de regiões no módulo de segmentação de regiões heterogêneas: (a) imagem de Id 's com região heterogênea de Id igual a 3 destacada (delimitada por linha cheia); (b) atribuição de zeros a área da região heterogênea; e, (c) geração de novas regiões de Id 's iguais a 6, 7 e 8 na área correspondente a região heterogênea submetida a segmentação por crescimento de regiões....	104
Figura 5.15 - Situações de contexto para regiões representadas por somente um <i>pixel</i> : região representada como <i>pixel</i> isolado (Id igual a 10 e 12) e região representada por um <i>pixel</i> adjacente a outras regiões (Id igual 11 e 13).....	107
Figura 5.16 - Interface de do módulo interação com o usuário.	109
Figura 6.1 - (a) imagem simulada na polarização <i>hh</i> e (b) Imagem de referência, com os contornos e as médias em intensidade das 29 regiões.	117
Figura 6.2 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a quantidade de regiões geradas nas segmentações das imagens simuladas com polarização <i>hh</i>	118
Figura 6.3 - Desempenho do (a) PolSeg e (b) SegSAR, segundo o tempo de processamento das segmentações das imagens simuladas com polarização <i>hh</i>	118
Figura 6.4 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de intensidade (M_{val}) das imagens simuladas com polarização <i>hh</i>	119
Figura 6.5 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de posição (M_{pos}) das imagens simuladas com polarização <i>hh</i> . .	119
Figura 6.6 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de dimensão (M_{dim}) das imagens simuladas com polarização <i>hh</i>	119

Figura 6.7 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de forma (M_{for}) das imagens simuladas com polarização hh	120
Figura 6.8 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste geral (M_{geral}) das imagens simuladas com polarização hh	120
Figura 6.9 - (a) Imagem simulada na polarização hv e (b) Imagem de referência, com os contornos e as médias em intensidade das 29 regiões.	125
Figura 6.10 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a quantidade de regiões geradas na segmentação das imagens simuladas com polarização hv	125
Figura 6.11 - Desempenho do (a) PolSeg e (b) SegSAR, segundo o tempo de processamento das imagens simuladas com polarização hv	126
Figura 6.12 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de intensidade (M_{val}) das imagens simuladas com polarização hv	127
Figura 6.13 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de posição (M_{pos}) das imagens simuladas com polarização hv . .	127
Figura 6.14 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de dimensão (M_{dim}) das imagens simuladas com polarização hv	127
Figura 6.15 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de forma (M_{for}) das imagens simuladas com polarização hv	128
Figura 6.16 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste geral (M_{geral}) das imagens simuladas com polarização hv	128
Figura 6.17 - (a) Imagem simulada na polarização vv e (b) Imagem de referência, com os contornos e as médias em intensidade das 29 regiões.	131

Figura 6.18 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a quantidade de regiões geradas nas segmentações das imagens simuladas com polarização vv.....	132
Figura 6.19 - Desempenho do (a) PolSeg e (b) SegSAR, segundo o tempo de processamento das imagens simuladas com polarização vv.	132
Figura 6.20 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de intensidade (M_{val}) das imagens simuladas com polarização vv.	133
Figura 6.21 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de posição (M_{pos}) das imagens simuladas com polarização vv...	133
Figura 6.22 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de dimensão (M_{dim}) das imagens simuladas com polarização vv.	133
Figura 6.23 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de forma (M_{for}) das imagens simuladas com polarização vv.....	134
Figura 6.24 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste geral (M_{geral}) das imagens simuladas com polarização vv.....	134
Figura 6.25 - Resultados de segmentações obtidas pelo PolSeg com as imagens nas polarizações (a) <i>hh</i> , (b) <i>hv</i> e (c) <i>vv</i> usando os parâmetros que apresentaram melhores resultados para a medida de ajuste geral (M_{geral}).....	139
Figura 6.26 - Quantidade de regiões geradas para imagem simulada com as polarizações <i>hh</i> , <i>hv</i> e <i>vv</i> a cada nível de compressão pelos módulos de processamentos do PolSeg.	141
Figura 6.27 - Tempo de processamento gasto para realizar a segmentação das polarizações <i>hh</i> , <i>hv</i> e <i>vv</i> da imagem simulada a cada nível de compressão pelos módulos de processamentos do PolSeg.	143

Figura 6.28 - Resultados de segmentação de uma imagem simulada: (a) SegSAR - polarização <i>hh</i> ; (b) imagem original - polarização <i>hh</i> ; (c) PolSeg - polarização <i>hh</i> ; (d) SegSAR - polarização <i>hv</i> ; (e) imagem original - polarização <i>hv</i> ; (f) PolSeg - polarização <i>hv</i> ; (g) SegSAR - polarização <i>vv</i> ; (h) imagem original – polarização <i>vv</i> ; e (i) PolSeg - polarização <i>vv</i> . Todas representadas em intensidade.....	146
Figura 6.29 - Desempenho do PolSeg na segmentação dos dados PolSAR, segundo (a) a quantidade de regiões geradas e (b) tempo de processamento.	148
Figura 6.30 - Desempenho do PolSeg na segmentação dos dados PolSAR, segundo: (a) medida de ajuste de intensidade M_{val} ; (b) medida de ajuste de posição M_{pos} ; (c) medida de ajuste de dimensão M_{dim} ; (d) medida de ajuste de forma M_{for} ; e, (e) medida de ajuste geral M_{geral}	149
Figura 6.31 - Resultado obtido, a cada descompressão, no processo de segmentação realizado pelo PolSeg de uma imagem simulada polarimétrica formada com três polarizações, usando nível de compressão igual a sete, nível de confiança igual a 90,0% e área mínima de 15 <i>pixels</i>	151
Figura 6.32 - Quantidade de regiões geradas na segmentação de uma imagem simulada polarimétrica com as três polarizações, a cada nível de compressão pelos módulos de processamentos do PolSeg, usando nível de compressão igual a sete, nível de confiança igual a 90,0% e área mínima de 15 <i>pixels</i>	152
Figura 6.33 - Quantidade de regiões geradas na segmentação de uma imagem simulada com três bandas nas polarizações <i>hh-hv-vv</i> e na segmentação da mesma imagem simulada para cada polarização individualmente, com os parâmetros que apresentaram os melhores resultados para a medida de ajuste geral, a cada nível de compressão pelos módulos de processamentos do PolSeg.	155

- Figura 6.34 - Desempenho do PolSeg na segmentação dos dados polarimétricos com duas polarizações: (a) quantidade de regiões geradas e (b) o tempo de processamento, com par de polarizações *hh-hv*; (c) quantidade de regiões geradas e (d) o tempo de processamento, com par de polarizações *hh-vv*; (e) quantidade de regiões geradas e (f) o tempo de processamento, com par de polarizações *hv-vv*. 159
- Figura 6.35 - Desempenho do PolSeg, segundo as medidas de ajuste de (a) intensidade M_{val} , (b) posição M_{pos} , (c) dimensão M_{dim} , (d) forma M_{for} e (e) geral M_{geral} , na segmentação das imagens simuladas com duas bandas nas polarizações *hh-hv*. 160
- Figura 6.36 - Desempenho do PolSeg, segundo as medidas de ajuste de (a) intensidade M_{val} , (b) posição M_{pos} , (c) dimensão M_{dim} , (d) forma M_{for} e (e) geral M_{geral} , das imagens simuladas com duas bandas nas polarizações *hh-vv*. 161
- Figura 6.37 - Desempenho do PolSeg, segundo as medidas de ajuste de (a) intensidade M_{val} , (b) posição M_{pos} , (c) dimensão M_{dim} , (d) forma M_{for} e (e) geral M_{geral} , na segmentação das imagens simuladas com duas bandas nas polarizações *hv-vv*. 162
- Figura 6.38 – Resultados de processamento obtidos com o PolSeg: (a) imagem polarimétrica simulada com o par de polarizações *hh-hv* e respectiva (b) imagem segmentada, representada em intensidade na composição colorida *hh(R)*, *hv(G)*, *hh(B)*; e, (c) imagem polarimétrica com três polarizações e respectiva imagem segmentada, representada em intensidade na composição colorida *hh(R)*, *hv(G)*, *vv(B)*. 163
- Figura 6.39 – Exemplo de (a) imagem simulada polarimétrica com três polarizações, com os contornos das regiões, submetida a segmentação e resultados da segmentação no PolSeg (b) usando os dados PolSAR, e (c) usando dados polarizados em intensidade, com parâmetros de nível de compressão igual a sete, nível de confiança de 90,0% e área mínima de 15 pixels. 167

- Figura 6.40 - Quantidade de regiões geradas, a cada nível de compressão pelos módulos de processamentos do PolSeg, na segmentação da imagem simulada polarimétrica e imagem polarizada em intensidade, ambas com três polarizações, usando nível de compressão igual a 7, nível de confiança de 90,0% e área mínima de 15 *pixels*. 168
- Figura 6.41 - Desempenho do SegSAR na segmentação das imagens simuladas polarizadas em intensidade, segundo (a) a quantidade de regiões geradas e (b) tempo de processamento. 171
- Figura 6.42 - Desempenho do SegSAR na segmentação das imagens polarizadas em intensidade, segundo: (a) medida de ajuste de intensidade M_{val} ; (b) medida de ajuste de posição M_{pos} ; (c) medida de ajuste de dimensão M_{dim} ; (d) medida de ajuste de forma M_{for} ; e, (e) medida de ajuste geral M_{geral} 173
- Figura 6.43 - Resultado obtido na segmentação com o SegSAR de uma imagem multivariada polarizada em intensidade, com nível de compressão igual a cinco, nível de confiança de 95,0% e área mínima de 15 *pixels*: (a) imagem segmentada; e, (b) a imagem original submetida a segmentação, ambas em intensidade e representadas na composição colorida R(*hh*), G(*hv*), B(*hh*). 174
- Figura 6.44 - Quantidade de regiões geradas a cada nível de compressão pelos módulos de processamentos do SegSAR, na segmentação de uma imagem simulada multivariada em intensidade (*hh-hv-vv*) e imagens univariadas polarizadas em intensidade (polarizações *hh*, *hv* e *vv*), usando os parâmetros que apresentaram os melhores valores para a medida de ajuste geral. 175
- Figura 6.45 – Tempo de processamento demandado a cada nível de compressão pelos módulos de processamentos do SegSAR, na segmentação de uma imagem simulada multivariada em intensidade (*hh-hv-vv*) e imagens univariadas polarizadas em intensidade (polarizações

hh , hv e vv), usando os parâmetros que apresentaram os melhores valores para a medida de ajuste geral.	176
Figura 6.46 – Exemplo de (a) imagem simulada multivariada em intensidade com os contornos das regiões e segmentações geradas com os algoritmo (b) PolSeg e (c) SegSAR, todas representadas na composição colorida $hh(R)$, $hv(G)$, $vv(B)$	179
Figura 6.47 - Síntese dos resultados das segmentações realizadas com o PolSeg e SegSAR.....	180
Figura 7.1 - Resultados da segmentação da (a) imagem PolSAR do sensor SIR-C, banda L, obtidos com: (b) PolSeg, usando as imagens PolSAR; (c) PolSeg, usando as imagens polarizadas em intensidade; e , (d) SegSAR, usando as imagens em intensidade. Todos representados em intensidade na composição colorida $hh(R)$, $hv(G)$, $vv(B)$	184
Figura 7.2 - Resultados da segmentação da (a) imagem PolSAR do sensor R99B, banda L, obtidos com: (b) PolSeg, usando as imagens PolSAR; (c) PolSeg, usando as imagens polarizadas em intensidade; e , (d) SegSAR, usando as imagens polarizadas em intensidade; e , (d) SegSAR, usando as imagens em intensidade. Todos representados em intensidade na composição colorida $hh(R)$, $hv(G)$, $vv(B)$	187
Figura B.1 – Criação do Projeto no ambiente IDL.	270
Figura B.2 – Lista de projetos no ambiente IDL.	270
Figura B.3 – Interface de importação de projeto do IDL.....	271
Figura B.4 – Interface de importação de projeto do IDL.....	272
Figura B.5 – Ícone para a execução do projeto no ambiente IDL.....	273
Figura B.6 - Interface de principal do PolSeg.....	274
Figura B.7 - Interface padrão do <i>Windows</i> usado pelo PolSeg na seleção de arquivos.	276

Figura B.8 - Estrutura do arquivo ENVI para carregamento do vetor de espalhamento (<i>Scattering vector</i>) e dados multivariados em intensidade (<i>Intensity data</i>).	277
Figura B.9 - Estrutura do arquivo ENVI para carregamento da matriz de covariância (<i>Covariance matrix</i>).....	277
Figura B.10 - Interface de seleção de pasta para a gravação de resultados de processamento.	281
Figura B.11 - Interface principal de do módulo interação com o usuário.....	282
Figura B.12 - Modos de apresentação de resultados disponíveis na interface do módulo interação com o usuário: (a) canais de intensidade da imagem original; (b) canais de intensidade da imagem original com contornos obtidos a partir dos segmentos; (c) intensidade média dos segmentos gerados; e, (d) intensidade média dos segmentos com a sobreposição dos contornos.	285
Figura B.13 - Interface do relatório intermediário de processamento.....	286
Figura B.14 - Interface de alteração de parâmetros de segmentação.....	286

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 2.1 - Valores mínimos de $N1L1$, em função da dimensão da matriz, para aplicação do teste de igualdade de matrizes de covariância.	23
Tabela 4.1 - Matrizes de covariância complexas médias calculadas a partir das cinco amostras de cada classe retiradas da imagem do sensor R99B....	51
Tabela 4.2 - Informações da imagem PolSAR SIR-C e da área de estudo.....	52
Tabela 4.3 - Quadro resumo dos processamentos realizados com dados simulados para avaliar quantitativamente e qualitativamente o desempenho do segmentador PolSeg e SegSAR.	55
Tabela 5.1 - Principais diferenças entre os algoritmos PolSeg e SegSAR.....	63
Tabela 5.2 - Exemplo ajustamento de dimensões de número de colunas e linhas conforme o nível selecionado para compressão, para atender o critério de compressão por pirâmides hierárquicas.....	71
Tabela 6.1 - Valor da estatística Z e valor-p (bilateral) do teste de igualdade da medida de ajuste de intensidade (M_{val}) dos segmentadores PolSeg e SegSAR, calculadas na segmentação das imagens simuladas na polarização hh	123
Tabela 6.2 – Valor da estatística Z e valor-p (bilateral) do teste de igualdade da medida de ajuste de posição (M_{pos}) dos segmentadores PolSeg e SegSAR, calculadas na segmentação das imagens simuladas na polarização hh	124
Tabela 6.3 – Valor da estatística Z e valor-p (bilateral) do teste de igualdade da medida de ajuste intensidade (M_{val}) dos segmentadores PolSeg e SegSAR, calculadas na segmentação das imagens simuladas na polarização hv	130

Tabela 6.4 – Valor da estatística Z e valor-p (bilateral) do teste de igualdade da medida de ajuste de posição (M_{pos}) dos segmentadores PolSeg e SegSAR, calculadas na segmentação das imagens simuladas na polarização hv	131
Tabela 6.5 - Valor da estatística Z e valor-p (bilateral) do teste de igualdade da medida de ajuste geral (M_{geral}) dos segmentadores PolSeg e SegSAR, calculadas na segmentação das imagens simuladas na polarização vv	136
Tabela 6.6 - Parâmetros de segmentação usados na segmentação com o PolSeg das imagens simuladas nas polarizações hh , hv e vv que apresentaram melhores resultados para a medida de ajuste geral.	138
Tabela 6.7 - Intensidade Média das Classes nas polarizações hh , hv e vv . ..	141
Tabela 6.8 - Parâmetros de segmentação usados na segmentação com o SegSAR das imagens simuladas nas polarizações hh , hv e vv que apresentaram melhores resultados para a medida de ajuste geral (M_{geral}).	144
Tabela 6.9 - Tempo de processamento gasto, a cada nível de compressão pelos módulos de processamentos do PolSeg, para realizar a segmentação da imagem polarimétrica com três polarizações, com parâmetros de nível de compressão igual a sete, nível de confiança de 90,0% e área mínima de 15 <i>pixels</i>	153
Tabela 6.10 - Tempo de processamento gasto, a cada nível de compressão pelos módulos de processamentos do PolSeg, para realizar a segmentação da imagem PolSAR formada com três polarizações e imagens univariadas polarizadas em intensidade com polarizações hh , hv e vv , com parâmetros de nível de compressão igual a sete, nível de confiança de 90,0% e área mínima de 15 <i>pixels</i>	156
Tabela 6.11 - Parâmetros de segmentação do PolSeg usados na geração do melhor resultado para a medida de ajuste geral M_{geral} , no processamento	

das imagens PolSAR simuladas com os pares de polarização <i>hh-hv</i> , <i>hh-vv</i> e <i>hv-vv</i>	158
Tabela 6.12 - Valores das medidas de ajuste obtidos na segmentação das imagens PolSAR com as polarizações <i>hh-hv</i> e <i>hh-hv-vv</i> , usando os parâmetros que geraram os valores mais elevados para a medida de ajuste geral.	164
Tabela 6.13 - Valores para as medidas de ajuste de intensidade M_{val} , de posição M_{pos} , M_{dim} , de forma M_{for} e geral M_{geral} obtidos a partir dos resultados da segmentação no PolSeg das imagens PolSAR simuladas e imagens polarizadas em intensidade, usando sete níveis de compressão, nível de confiança de 90,0% e área mínima de 15 <i>pixels</i>	165
Tabela 6.14 - Valores da estatística Z e valor-p para as medidas de ajuste de intensidade M_{val} , de posição M_{pos} , de dimensão M_{dim} , de forma M_{for} e geral M_{geral} obtidas a partir dos resultados da segmentação no PolSeg dos dados PolSAR, e dados polarizados em intensidade, usando os parâmetros sete níveis de compressão, nível de confiança de 90,0% e área mínima de 15 <i>pixels</i>	166
Tabela 6.15 - Tempo de processamento demandado a cada nível de compressão pelos módulos de processamentos do PolSeg, para realizar a segmentação da imagem PolSAR e multivariada polarizada em intensidade, ambas com três polarizações, com nível de compressão igual a sete, nível de confiança de 90,0% e área mínima de 15 <i>pixels</i>	170
Tabela 6.16 – Melhores valores obtidos para as medidas de ajuste de intensidade M_{val} , de posição M_{pos} , M_{dim} , de forma M_{for} e geral M_{geral} gerados a partir dos resultados da segmentação no PolSeg e no SegSAR das imagens simuladas polarizadas em intensidade, variando os valores de níveis máximos de compressão e níveis de significância.	177
Tabela 6.17 - Valores da estatística Z e valor-p para as medidas de ajuste de intensidade M_{val} , de posição M_{pos} , de dimensão M_{dim} , de forma M_{for} e	

geral M_{geral} obtidas a partir dos resultados da segmentação no PolSeg e no SegSAR das imagens polarizadas em intensidade. 178

Tabela A.1 - Valores da estatística Z para as medidas de avaliação obtidas na segmentação pelo PolSeg da imagem simulada na polarização hh variando níveis de compressão de três a sete: (a) medida de intensidade M_{val} , (b) medida de posição M_{pos} , (c) medida de dimensão M_{dim} , (d) medida de forma M_{for} , e (e) geral M_{geral} 213

Tabela A.2 - Valores da estatística Z para as medidas de avaliação obtidas na segmentação pelo SegSAR das imagens simuladas na polarização hh variando níveis de compressão de três a sete: (a) medida de intensidade M_{val} , (b) medida de posição M_{pos} , (c) medida de dimensão M_{dim} , (d) medida de forma M_{for} , e (e) geral M_{geral} 215

Tabela A.3 - Valores da estatística Z para as medidas de avaliação obtidas na segmentação pelo PolSeg da imagem simulada na polarização hv variando níveis de compressão de três a sete: (a) medida de intensidade M_{val} , (b) medida de posição M_{pos} , (c) medida de dimensão M_{dim} , (d) medida de forma M_{for} , e (e) geral M_{geral} 217

Tabela A.4 - Valores da estatística Z para as medidas de avaliação obtidas na segmentação pelo SegSAR das imagens simuladas na polarização hv variando níveis de compressão de três a sete: (a) medida de intensidade M_{val} , (b) medida de posição M_{pos} , (c) medida de dimensão M_{dim} , (d) medida de forma M_{for} , e (e) geral M_{geral} 219

Tabela A. 5 - Valores da estatística Z para as medidas de avaliação obtidas na segmentação pelo PolSeg da imagem simulada na polarização vv variando níveis de compressão de 2 a 7: (a) medida de intensidade M_{val} , (b) medida de posição M_{pos} , (c) medida de dimensão M_{dim} , (d) medida de forma M_{for} , e (e) geral M_{geral} 221

Tabela A.6 - Valores da estatística Z para as medidas de avaliação obtidas na segmentação pelo SegSAR das imagens simuladas na polarização vv

variando níveis de compressão de 2 a 7: (a) medida de intensidade M_{val} , (b) medida de posição M_{pos} , (c) medida de dimensão M_{dim} , (d) medida de forma M_{for} , e (e) geral M_{geral} 223

Tabela A.7 - Valores da estatística Z para as medidas de avaliação obtidas na segmentação pelo PolSeg da imagem simulada com três bandas nas polarizações $hh-hv-vv$ variando níveis de compressão de 4 a 7: (a) medida de intensidade M_{val} , (b) medida de posição M_{pos} , (c) medida de dimensão M_{dim} , (d) medida de forma M_{for} , e (e) geral M_{geral} 225

Tabela A.8 - Valores da estatística Z para as medidas de avaliação obtidas na segmentação pelo SegSAR da imagem simulada com três bandas nas polarizações $hh-hv-vv$ variando níveis de compressão de 4 a 7: (a) medida de intensidade M_{val} , (b) medida de posição M_{pos} , (c) medida de dimensão M_{dim} , (d) medida de forma M_{for} , e (e) geral M_{geral} 227

Tabela A.9 - Valores da estatística Z para as medidas de avaliação obtidas na segmentação pelo PolSeg da imagem simulada com duas bandas nas polarizações $hh-hv$ variando níveis de compressão de 2 a 7: (a) medida de intensidade M_{val} , (b) medida de posição M_{pos} , (c) medida de dimensão M_{dim} , (d) medida de forma M_{for} , e (e) geral M_{geral} 229

Tabela A.10 - Valores da estatística Z para as medidas de avaliação obtidas na segmentação pelo PolSeg da imagem simulada com duas bandas nas polarizações $hh-vv$ variando níveis de compressão de 2 a 7: (a) medida de intensidade M_{val} , (b) medida de posição M_{pos} , (c) medida de dimensão M_{dim} , (d) medida de forma M_{for} , e (e) geral M_{geral} 231

Tabela A.11 - Valores da estatística Z para as medidas de avaliação obtidas na segmentação pelo PolSeg da imagem simulada com duas bandas nas polarizações $hv-vv$ variando níveis de compressão de quatro a sete: (a) medida de intensidade M_{val} , (b) medida de posição M_{pos} , (c) medida de dimensão M_{dim} , (d) medida de forma M_{for} , e (e) geral M_{geral} 233

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO.....	1
1.1. Contextualização	1
1.2. Objetivos e hipóteses.....	5
1.3. Contribuição da Tese.....	7
1.4. Organização do trabalho.....	8
2. DADOS POLSAR	11
2.1. Representação de dados PolSAR	11
2.2. Modelagem estatística de dados PolSAR.....	13
2.2.1. Modelo multiplicativo	14
2.2.2. Distribuição <i>Wishart</i>	15
2.2.3. Distribuição <i>Wishart</i> escalonada	16
2.2.4. Distribuição <i>Gama</i>	17
2.3. Testes estatísticos para dados SAR polarimétricos.....	18
2.3.1. Teste de igualdade de médias de intensidades	18
2.3.2. Teste de igualdade de matrizes de covariâncias complexas	21
3. SEGMENTAÇÃO DE IMAGENS	25
3.1. Definição e conceitos.....	25
3.2. Segmentação de imagens SAR.....	28
3.2.1. Segmentação de imagens SAR monocanais e multicanais em amplitude ou intensidade.....	29
3.2.2. Segmentação de imagens PolSAR	36
3.2.3. Síntese dos segmentadores para imagens SAR.....	41
3.3. Avaliação de segmentação de imagens SAR	42

3.3.1. Medidas de avaliação por discrepância	43
4. METODOLOGIA	47
4.1. Fluxograma de trabalho	47
4.2. Desenvolvimento do algoritmo PolSeg	48
4.3. Obtenção das imagens PolSAR simuladas	49
4.4. Obtenção de imagens PolSAR reais.....	51
4.5. Segmentações realizadas.....	53
4.5.1. Dados PolSAR simulados	54
4.5.2. Dados PolSAR reais.....	55
4.6. Implementação de algoritmo de avaliação.....	56
4.7. Análise de resultados.....	56
5. O ALGORITMO POLSEG	59
5.1. Concepção.....	59
5.2. Desenvolvimento e funcionamento	64
5.2.1. Primeira etapa de processamento	65
5.2.1.1. Entrada de dados e parâmetros.....	65
5.2.1.1.1. Dados de Entrada	66
5.2.1.1.2. Parâmetros de processamento	68
5.2.1.1.3. Opções de saída	69
5.2.1.2. Carregamento da imagem	69
5.2.1.3. Geração da matriz de covariância	71
5.2.1.4. Compressão em níveis	72
5.2.1.5. Segmentação por crescimento de regiões.....	75
5.2.1.5.1. Fase de preparo	75
5.2.1.5.2. Fase de segmentação	76

5.2.2.	Segunda etapa de processamento	81
5.2.2.1.	Descompressão em um nível.....	82
5.2.2.2.	Análise de bordas	84
5.2.2.3.	Análise de homogeneidade.....	101
5.2.2.4.	Segmentação de regiões heterogêneas	103
5.2.2.5.	Agrupamento de regiões.....	104
5.2.2.6.	Agrupamento de <i>pixels</i> isolados	106
5.2.2.7.	Interação com o usuário.....	108
5.2.2.8.	Descomprime para o nível zero	109
5.2.3.	Terceira etapa de processamento.....	111
5.2.3.1.	Verificação de área mínima	111
5.2.3.2.	Saída de dados.....	113
6.	AVALIAÇÃO DO ALGORITMO POLSEG COM IMAGENS SIMULADAS	115
6.1.	Resultados obtidos na segmentação de dados univariados em intensidade	116
6.1.1.	Imagens na polarização <i>hh</i>	117
6.1.1.1.	Análise comparativa do desempenho dos algoritmos PolSeg e SegSAR para a polarização <i>hh</i>	122
6.1.2.	Imagens na polarização <i>hv</i>	125
6.1.2.1.	Análise comparativa do desempenho dos algoritmos PolSeg e SegSAR para a polarização <i>hv</i>	129
6.1.3.	Imagens na polarização <i>vv</i>	131
6.1.3.1.	Análise comparativa do desempenho dos algoritmos PolSeg e SegSAR para a polarização <i>vv</i>	135

6.1.4. Análise visual comparativa da segmentação no PolSeg e SegSAR de uma imagem simulada.....	137
6.1.4.1. Resultados obtidos com o PolSeg.....	137
6.1.4.2. Resultados obtidos com o SegSAR.....	144
6.2. Avaliação dos resultados obtidos na segmentação de dados PolSAR e de dados multivariados polarizados em intensidade.....	147
6.2.1. Dados PolSAR.....	147
6.2.1.1. Dados PolSAR com três polarizações.....	147
6.2.1.1.1. Exemplo detalhado de processamento com o PolSeg.....	150
6.2.1.1.2. Comparação de resultados do PolSeg: dados polsar versus dados univariados polarizados em intensidade.....	154
6.2.1.2. Dados PolSAR com par de polarizações.....	157
6.2.1.2.1. Comparação de resultados do PolSeg: dados polsar com três polarizações versus par de polarizações.....	162
6.2.2. Dados multivariados polarizados em intensidade.....	164
6.2.2.1. Comparação de resultados do PolSeg: dados PolSAR versus dados multivariados polarizados em intensidade.....	165
6.2.2.2. Resultados obtidos com o SegSAR.....	171
6.2.2.2.1. Exemplo detalhado de processamento com o SegSAR.....	173
6.2.2.3. Comparação de resultados obtidos com o PolSeg e o SegSAR....	177
6.3. Síntese dos resultados obtidos na segmentação dos dados SAR simulados.....	180
7. AVALIAÇÃO DO ALGORITMO POLSEG COM IMAGENS POLSAR REAIS.....	183
7.1. Processamento da imagem do sensor SIR-C - banda L.....	183
7.2. Processamento da imagem do sensor R99B - banda L.....	186

8. CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS.....	189
8.1. Conclusões	189
8.2. Sugestões para trabalhos futuros	199
REFERÊNCIAS BIBLIOGRÁFICAS	203
APÊNDICE A - TABELAS DE TESTE Z	213
APÊNDICE B - VALORES OBTIDOS PARA AS MEDIDAS DE AJUSTE	235
APÊNDICE C - SEGMENTADOR PARA DADOS POLSAR (POLSEG) - GUIA DE USO	269
ANEXO - ARTIGOS GERADOS	289

1 INTRODUÇÃO

1.1. Contextualização

Atualmente as principais fontes de informações para a obtenção de dados espaciais da superfície terrestre têm origem em técnicas de Sensoriamento Remoto (SR). A forma como os dados são obtidos por meio destas técnicas envolvem o emprego de sensores, que têm por finalidade capturar a energia eletromagnética refletida e ou emitida pelos alvos. Esses sensores se dividem basicamente em dois tipos: sensores passivos e ativos. Os sensores passivos, que dependem de uma fonte externa de iluminação dos alvos, tradicionalmente têm sido os mais utilizados para a geração de imagens da superfície da Terra, a partir das quais se extraem informações de interesse para as atividades humanas. Tais sensores incluem as câmaras aéreas empregadas nos processos de aerofotogrametria e sensores embarcados em plataformas orbitais tais, como os da série SPOT, QUICKBIRD, IKONOS e outros.

Com relação aos sensores ativos, que possuem a sua própria fonte de iluminação dos alvos, dois deles se destacam: o LIDAR, do termo em inglês *Light Detection And Ranging* e o SAR, do termo em inglês *Synthetic Aperture Radar*. O LIDAR é uma tecnologia de sensor remoto óptico que mede propriedades da luz refletida (10 a 250 nm) para obter a distância ou outra informação de um objeto ou superfície (MEASURES, 1992). Por sua vez, o sensor SAR obtém a informação de uma superfície por meio da emissão de pulsos de micro-ondas, a intervalos regulares, sobre a região de interesse e da recuperação dos sinais de retorno (ecos) provenientes desta região, à medida que o sensor se desloca (DUTRA et al., 2003).

O sensor SAR, quando comparado com outros usados para geração de imagens, possui algumas características que o tornam único para uso em SR. Uma destas é a sua capacidade de gerar imagens em praticamente qualquer condição meteorológica. Esta característica, quando se considera a posição geográfica do Brasil, que possui grande parte do território em regiões tropicais,

as quais têm alta probabilidade de ocorrência de nuvens, permite posicionar esse tipo de sensor em lugar de destaque, à frente dos sensores ópticos.

Outra vantagem, tão importante quanto a anterior, é que a informação contida nos dados provenientes de sistemas SAR polarimétricos, ou simplesmente PolSAR (abreviação dos termos em inglês *Polarimetric SAR*), que contêm a informação da amplitude e fase do sinal medido pelo radar, permite a decomposição e a identificação de diferentes mecanismos elementares de espalhamento contidos nos alvos da superfície terrestre (CORREIA, 2009). Este tipo de informação tem contribuído, cada vez mais, para um melhor entendimento dos mecanismos de espalhamento dos alvos terrestres na faixa das micro-ondas, tornando mais confiável o uso das imagens provenientes dos sistemas SAR.

Por apresentar estas características, as imagens PolSAR, aliadas a uma crescente disponibilidade e potencial de uso para aplicações nas atividades humanas, têm despertado grande interesse dos usuários de SR. Este interesse tem se fundamentado nas aplicações das imagens para agricultura (discriminação de diferentes culturas), mapeamento florestal (estimação de biomassa), geologia (discriminação de estruturas geológicas), hidrologia (estimação da rugosidade e umidade da superfície), entre outras. Com o aumento da utilização de dados PolSAR, faz-se necessário, portanto, o desenvolvimento de técnicas automáticas de processamento visando à extração de informações, para tornar operacional o uso desse tipo de imagem.

Conforme observado por Gonzalez e Woods (1987), a importância da extração de informações reside no fato desta ser uma etapa fundamental entre o processamento e a análise de imagens. Esta para ser executada geralmente exige informações obtidas a partir de uma simplificação da imagem digital original. Esta simplificação pode ser entendida como a consolidação das informações contidas na imagem em várias regiões com características homogêneas, em relação a uma propriedade tomada como referência. Desse

modo, os objetos contidos em uma cena podem ser individualizados, permitindo, conseqüentemente, uma análise mais apropriada da imagem quanto ao seu conteúdo.

Esta abordagem consiste no problema da segmentação, que pode ser modelado de diversas formas dentro da área de Processamento Digital de Imagens (PDI). A segmentação é considerada como uma operação importante para o processo de análise de imagens digitais, pois geralmente se atribui a ela a responsabilidade pela extração automática de feições contidas nas imagens para uma tarefa posterior.

No que diz respeito à segmentação de dados SAR, diversos trabalhos, aplicando diferentes técnicas, podem ser encontrados na literatura (SMITH, 1996; FJØRTOFT et al., 1997; LEE e JURKEVICH, 1989; CAVES et al., 1998; ZAART et al., 1999; WEISENSEEL et al., 1998; LEE et al., 1999; FJØRTOFT et al., 1999; DE GRANDI et al., 2001; SKRIVER et al., 2002; LOMBARDO; OLIVER, 2002; SCHOU et al., 2003; PELLIZZERI et al., 2003; BEAULIEU; TOUZI, 2004; SHI et al., 2004; OLIVER; QUEGAN, 2004; ORBANZ; BUHMANN, 2005; SOUSA JUNIOR, 2005; AYED et al., 2005; BENBOUDJEMA et al., 2007; XU et al., 2007; LI; CHEN, 2007; SHUAI et al., 2007; DELON et al., 2007; CAO et al., 2007; YANG et al., 2008; HÄNSCH et al., 2008; WANG et al., 2010; ERSAHIN et al., 2010; DABBOR et al., 2010; BOMBRUN et al., 2011; HOEKMAN et al., 2011; AKBARI et al., 2013). Percebe-se, com estes trabalhos, que os algoritmos de segmentação de imagens SAR tornam-se cada vez mais precisos, quando os resultados por eles obtidos são comparados a verdades terrestres. A melhora dos algoritmos, quando a abordagem usada por estes é a estatística, está vinculada, entre outros fatores, a uma modelagem mais adequada aos dados SAR.

Esta situação fica explícita quando se analisa o algoritmo SegSAR, desenvolvido por Sousa Junior (2005). Neste algoritmo, o uso da distribuição Gaussiana associada à distribuição *Gama*, esta última mais apropriada para

representar dados SAR em intensidade considerando que os alvos que compõe a imagem são homogêneos, foi usada para a realização de testes estatísticos visando à obtenção da segmentação. Os resultados obtidos com o uso desse algoritmo, na segmentação de dados SAR reais e simulados, mostraram a vantagem da adoção de um modelo estatístico adequado à natureza do dado processado.

Entretanto, boa parte dos algoritmos existentes, dentre eles o próprio SegSAR, não processam dados PolSAR (representados pela matriz de covariância), ou seja, trabalham somente com dados em intensidade ou em amplitude, denominados neste trabalho por dados polarizados. Este fato faz com que informações importantes como a fase do sinal de retorno seja ignorada por estes algoritmos. Dessa forma, a melhora dos resultados das segmentações de imagens PolSAR fica limitada ao processamento de dados polarizados que não possibilitam o uso da informação polarimétrica.

Sendo assim, começam a aumentar os estudos voltados para o processamento de dados PolSAR, que fornecem a possibilidade de obtenção de uma quantidade bem maior de informações da superfície imageada. Tal aumento de informação se deve ao fato da obtenção de várias componentes em amplitudes, em diferentes polarizações de transmissão e de recepção do sinal, bem como a informação de fase do sinal de retorno (WOODHOUSE, 2006).

Tendo em mente que a melhoria dos resultados dos processamentos de segmentação de imagens SAR pode estar ligada a um aumento da quantidade de informação existente nos dados, está sendo ampliado, no meio científico alguns estudos voltados para a segmentação de imagens PolSAR (AKBARI et al., 2013; HOEKMAN et al., 2011; DABBOOR et al., 2010; ERSAHIN et al., 2010; BOMBRUM et al., 2009; HÄNSCH et al., 2008; YANG et al., 2008, SKRIVER et al., 2002).

Uma das maneiras mais apropriadas para representar este tipo de dado, de forma a permitir o uso completo das informações geradas pelos sistemas

PolSAR, é através da matriz de covariância complexa. Esta matriz possui embutido em seus elementos, informações referentes às intensidades, amplitudes e fases de retorno do sinal dos alvos medido pelo sistema PolSAR.

Uma vantagem ao se usar a matriz de covariância para representar as informações polarimétricas fornecidas pelo SAR é que, sob certas condições, esta matriz pode ser modelada pela distribuição *Wishart* complexa. Esta distribuição tem sido usada em diversos trabalhos de processamento de imagens SAR, os quais têm apresentado bons resultados (AKBARI et al., 2013; SILVA, 2013; SILVA et al., 2013; BEAULIEU e TOUZI, 2003; CONRADSEN et al., 2003; FERRO-FAMIL et al., 2001; SCHOU et al., 2003; CONRADSEN et al., 2001; LEE et al., 1999; LEE et al., 1994).

Sendo assim, as possibilidades de pesquisa com dados polarimétricos, associadas à quantidade crescente de trabalhos desenvolvidos nesta área de pesquisa e a relevância do processo de segmentação de imagens PolSAR, nas atividades de extração e interpretação de imagens, faz com que tipo de processamento se torne de grande importância para a comunidade de SR. Desse modo, a perspectiva de desenvolvimento de algoritmos que realizem a extração de informações, a partir da segmentação de imagens PolSAR, para serem usadas em atividades de análise, tornam-se cada vez mais necessárias, sendo por isso o foco deste trabalho.

1.2. Objetivos e hipóteses

Dentro do contexto apresentado anteriormente, associado à escassez de trabalhos no país relacionados à segmentação de imagens PolSAR usando modelagem estatística adequada para este tipo de dado, o objetivo central deste trabalho é o desenvolvimento, implementação e avaliação de um novo segmentador para imagens PolSAR, denominado PolSeg. Além disso, devido ao uso da informação polarimétrica na segmentação de imagens SAR, também tem por objetivo investigar se esta informação permite obter uma melhor definição dos segmentos.

Com base nos objetivos propostos, foram formuladas duas hipóteses básicas: 1) é possível desenvolver um algoritmo híbrido com abordagem estatística, que integre em um único sistema diversas técnicas de segmentação e processamento de imagens, para segmentar imagens PolSAR; e 2) é possível obter melhores resultados na segmentação de imagens SAR usando as informações polarimétricas e modelagens estatísticas adequadas a este tipo de informação.

Para atingir estes objetivos, o PolSeg foi concebido de forma a trabalhar com dados polarimétricos representados pela matriz de covariância complexa, a qual foi modelada pela distribuição de *Wishart* escalonada para fins de aplicação dos testes estatísticos usados durante o processo de segmentação. Quando a matriz de covariância é formada por um único elemento, a modelagem dos dados é baseada na distribuição *Gama*. Além disso, o algoritmo foi concebido de forma a fazer uso de técnicas de crescimento e agrupamento de regiões, ajuste de bordas, teste de homogeneidade e teste de área mínima, integradas numa estrutura de compressão piramidal. Esta última característica permite considerá-lo como hierárquico e multi-níveis. Por fim, cabe mencionar que o PolSeg além de processar imagens PolSAR, também processa imagens mono ou multi-bandas polarizadas em intensidade. Para este último caso, supõe-se que os dados do vetor de espalhamento são estatisticamente independentes.

A avaliação do segmentador PolSeg foi realizada utilizando imagens PolSAR simuladas e reais. Estes resultados foram comparados com os resultados obtidos com o segmentador SegSAR. Este algoritmo possui estrutura de processamento similar a adotada para o PolSeg e serviu de referência para o desenvolvimento deste último.

Com base nas hipóteses formuladas e nos objetivos gerais descritos anteriormente, foram definidos os seguintes objetivos específicos, como metas intermediárias a serem alcançadas no decorrer deste trabalho:

- Avaliar se a modelagem estatística rigorosa adotada para o PolSeg na segmentação dos dados univariados polarizados em intensidade produz resultados de segmentação melhores que aqueles gerados pela modelagem estatística adotada pelo SegSAR;
- Avaliar se a modelagem estatística adotada pelo PolSeg para a segmentação de dados PolSAR gera melhores resultados, quando comparados com os resultados obtidos na segmentação, com o mesmo algoritmo, de dados multivariados polarizados em intensidade;
- Avaliar se os resultados obtidos com o PolSeg na segmentação dos dados multivariados polarizados em intensidade podem ser considerados superiores aos resultados obtidos com o SegSAR;
- Avaliar qual o par de polarizações das imagens PolSAR gera os melhores resultados de segmentação no PolSeg;
- Avaliar se o melhor resultado obtido com o uso de imagem PolSAR formada por par de polarização é capaz de gerar resultados similares aos obtidos com a segmentação de imagem PolSAR formadas por três polarizações;
- Analisar o desempenho do algoritmo PolSeg na segmentação de imagens reais.

1.3. Contribuição da Tese

A principal contribuição desta tese é a concepção, equacionamento, implementação e teste de um novo algoritmo para realizar a segmentação de imagens PolSAR.

O algoritmo PolSeg é inovador, pois integra uma abordagem estatística apropriada para dados PolSAR com técnicas de segmentação e processamento de imagens multi-níveis. Tem-se ainda que o algoritmo, em comparação com os algoritmos existentes, faz uso de uma modelagem estatística baseada em distribuições apropriadas para os dados SAR contidos na matriz de covariância complexa.

Adicionalmente, a isso também pode ser destacada a funcionalidade do algoritmo por permitir o processamento de diferentes formatos de dados SAR.

1.4. Organização do trabalho

Para atingir os objetivos propostos, este trabalho foi estruturado, além do presente capítulo, em sete capítulos adicionais, de forma a cobrir os diversos assuntos relacionados ao tema abordado.

O Capítulo 2 foi dividido em duas partes, sendo que na primeira é apresentada uma breve revisão dos conceitos envolvidos na formação dos dados PolSAR. Na segunda parte, por sua vez, faz-se uma descrição de como os dados SAR podem ser modelados estatisticamente e as principais modelagens adotadas para fundamentar os testes estatísticos usados pelo algoritmo de segmentação desenvolvido.

O Capítulo 3, também está dividido em duas partes. Na primeira parte são apresentados alguns conceitos relacionados à segmentação de imagens e é feita uma breve descrição de diversos algoritmos de segmentação de imagens SAR encontrados na literatura. Na segunda parte são apresentados aspectos relacionados à avaliação da segmentação e as métricas utilizadas para avaliar o algoritmo desenvolvido neste trabalho.

No Capítulo 4 é apresentada a metodologia empregada para atingir os objetivos propostos no trabalho e são descritos os procedimentos para a

execução dos processamentos dos dados PolSAR e para as análises usadas na avaliação do desempenho do algoritmo implementado.

No Capítulo 5 é descrito detalhadamente o algoritmo desenvolvido. Este capítulo está dividido em duas partes. Na primeira parte descrevem-se os aspectos envolvidos na concepção do algoritmo, onde é apresentada a estrutura de processamento de dados utilizada e uma ideia geral do funcionamento do algoritmo. Na segunda parte é realizada uma descrição pormenorizada do funcionamento das fases e dos módulos de processamento desenvolvidos para realizar a segmentação das imagens PolSAR.

A análise dos resultados obtidos na aplicação do algoritmo são apresentadas nos Capítulos 6 e 7, com o intuito de avaliar o desempenho do algoritmo nas segmentações de imagens SAR simuladas e reais. São apresentadas ainda algumas análises comparativas entre os resultados obtidos com os segmentadores PolSeg e SegSAR, utilizando dados univariados e multivariados em intensidade.

O Capítulo 8 trata das conclusões, onde são apresentadas algumas considerações a respeito do uso do algoritmo desenvolvido, é discutido seu potencial de uso em algumas aplicações nas atividades de SR e sugeridos trabalhos futuros que podem ser realizados para dar continuidade às pesquisas sobre o tema tratado neste trabalho.

2 DADOS POLSAR

Neste capítulo é apresentada uma revisão dos principais temas envolvidos com o presente trabalho a fim de fundamentar teoricamente o seu desenvolvimento. Para isso, a apresentação dos temas foi dividida em três seções. Na primeira é apresentada uma breve revisão da representação dos dados PolSAR. Na segunda seção descreve-se a modelagem estatística deste tipo de dado. Por fim, os testes estatísticos usados no processo de segmentação do algoritmo implementado são abordados na terceira seção.

2.1. Representação de dados PolSAR

Para gerar a imagem de uma área, um sistema SAR convencional é embarcado em uma plataforma que se desloca geralmente ao longo de uma trajetória linear e transmite, em visada lateral, pulsos de energia na faixa das micro-ondas com polarização horizontal (h) ou vertical (v) em direção à Terra. Estes pulsos ao atingirem a superfície da Terra interagem com os alvos, onde parte da energia retorna ao ponto de transmissão. A energia de retorno é então gravada em uma das duas polarizações e posteriormente processada para formar a imagem SAR. Uma descrição mais detalhada do processamento SAR para a formação de uma imagem pode ser encontrada em Mura (2000) e Fernandes (1993).

Como o sensor SAR é ativo, tanto a configuração da polarização do pulso de energia transmitido pela antena quanto a polarização da energia de retorno pode ser controlada. Esta característica permite que os sistemas PolSAR realizem a medição da amplitude e da fase relativa de todas as configurações das antenas de transmissão e recepção (hh , vv , vh e hv), para todos os elementos de resolução (*pixel*) de uma imagem digital. O conjunto destas quatro informações geralmente é representado pela matriz de espalhamento complexa [S] dada por:

$$[\mathbf{S}] = \begin{bmatrix} S_{hh} & S_{hv} \\ S_{vh} & S_{vv} \end{bmatrix} \quad (2.1)$$

Na matriz $[\mathbf{S}]$ os elementos que formam a diagonal principal representam o sinal de retorno nas polarizações lineares paralelas ou *co-polarized*, hh e vv , enquanto os demais representam o sinal de retorno nas polarizações cruzadas ou *cross-polarized*, hv e vh .

Quando se considera a configuração de sistema SAR monoestático, onde a mesma antena alterna-se nas tarefas de emissão e recepção dos sinais eletromagnéticos e se leva em conta a reciprocidade, a matriz de espalhamento $[\mathbf{S}]$ passa a ser simétrica, com $S_{hv} = S_{vh}$. Isto reduz os elementos desta matriz, a qual pode ser representada na forma lexicográfica por um vetor de espalhamento complexo \mathbf{K}_B constituído por três elementos, representado por:

$$\mathbf{K}_B = \begin{bmatrix} S_{hh} \\ S_{hv} \\ S_{vv} \end{bmatrix} \quad (2.2)$$

A partir do vetor de espalhamento complexo pode-se deduzir uma matriz de grande importância quando se trata de dados polarimétricos, que é a matriz de covariância complexa $[\mathbf{C}_3]$ dada por (VAN ZYL et al., 1987)

$$[\mathbf{C}_3] = \mathbf{K}_B \cdot \mathbf{K}_B^{*T} = \begin{bmatrix} S_{hh}S_{hh}^* & S_{hh}S_{hv}^* & S_{hh}S_{vv}^* \\ S_{hv}S_{hh}^* & S_{hv}S_{hv}^* & S_{hv}S_{vv}^* \\ S_{vv}S_{hh}^* & S_{vv}S_{hv}^* & S_{vv}S_{vv}^* \end{bmatrix} \quad (2.3)$$

onde, $S_i S_i^* \in \mathfrak{R}_+$ e $S_i S_j^* \in \mathbb{C} (i, j \in \{hh, hv, vv\})$, e o sobrescrito $*T$ denota o complexo conjugado transposto.

Os dados PolSAR são frequentemente processados em *multi-look* (múltiplas visadas) a fim de reduzir o efeito do ruído *speckle*, o que requer a média de várias matrizes de covariância de *1-look* independentes (Lee, et al., 1994a).

Assim, a partir da variável aleatória representada pelo vetor \mathbf{K}_{B_k} , que constitui a k -ésima amostra de 1-look, pode-se obter a variável aleatória denominada matriz de covariância para L -looks, dada por

$$[\mathbf{Z}] = \frac{1}{L} \sum_{k=1}^L \mathbf{K}_{B_k} \cdot \mathbf{K}_{B_k}^{*T} = \begin{bmatrix} \langle S_{hh} S_{hh}^* \rangle & \langle S_{hh} S_{hv}^* \rangle & \langle S_{hh} S_{vv}^* \rangle \\ \langle S_{hv} S_{hh}^* \rangle & \langle S_{hv} S_{hv}^* \rangle & \langle S_{hv} S_{vv}^* \rangle \\ \langle S_{vv} S_{hh}^* \rangle & \langle S_{vv} S_{hv}^* \rangle & \langle S_{vv} S_{vv}^* \rangle \end{bmatrix} \quad (2.4)$$

onde L é o número de looks e $\langle \cdot \rangle$ denota a média espacial dos dados.

A matriz $[\mathbf{Z}]$ é Hermitiana positiva semidefinida, o que significa que seus autovalores são reais e maiores ou iguais a zero (HELLMAN, 2001). Os elementos de sua diagonal principal possuem polarização paralela e representam dados em intensidade enquanto que os demais elementos representam dados complexos que contém as informações dos produtos entre as amplitudes das componentes polarimétricas e respectivas diferenças de fase.

Por fim cabe mencionar, que a partir do vetor de espalhamento \mathbf{K}_B outras matrizes podem ser obtidas para representar e descrever o comportamento dos alvos contidos nas imagens polarimétricas geradas pelo sistema SAR. Dentre essas destacam-se, além da Matriz de Covariância, a matriz de Stokes, a matriz de Stokes modificada e a matriz de Muller. Neste trabalho será visto somente a matriz de covariância complexa, pelo fato da mesma ser usada para representar os dados polarimétricos no segmentador desenvolvido. Maiores informações a respeito das outras representações podem ser encontradas em Lee e Pottier (2009).

2.2. Modelagem estatística de dados PolSAR

O conhecimento preciso das propriedades estatísticas dos dados PolSAR desempenha um papel fundamental para o processamento, análise e entendimento das imagens usadas no sensoriamento remoto. Diferentes

distribuições estatísticas podem ser usadas para modelar os dados SAR. A adoção da distribuição mais apropriada para modelar estes dados depende diretamente do tipo de representação, do número de *looks* e do grau de homogeneidade dos alvos contidos na imagem. Devido aos objetivos estabelecidos neste trabalho serão vistas com mais detalhes somente as distribuições associadas diretamente às informações contidas na matriz de covariância complexa. Maiores detalhes sobre as demais distribuições estatísticas usadas para modelar dados SAR podem ser encontradas em Yanasse (1991), Caves (1993), Yanasse et al. (1995), Frery et al. (1997), Freitas et al. (2005), Mejail et al. (2003), Oliver e Quegan (2004) e Gao (2010).

2.2.1. Modelo multiplicativo

O modelo multiplicativo é comumente adotado na explicação do comportamento estatístico de dados obtidos por fontes de radiação coerente tais como o sistema SAR. Este modelo toma por base a suposição que, sob certas circunstâncias (TUR et al., 1982), o valor observado em cada célula de resolução é a ocorrência de uma variável aleatória V dada por,

$$V = B \cdot S \quad (2.5)$$

onde B é a variável aleatória que modela a componente da informação retroespalhada pelos alvos, comumente denominada por *backscatter*, e S é a variável aleatória que modela o ruído *speckle*, que é inerente ao processo de interação da radiação de micro-ondas com os alvos.

Para dados monocanal, dependendo dos diferentes tipos de detecção (imagem em amplitude ou intensidade) e do grau de homogeneidade das diferentes regiões imageadas, as distribuições associadas à modelagem de B variam, produzindo diferentes distribuições para representar V (FRERY et al., 1997).

Quando se trabalha com dados PolSAR com várias visadas, como é o caso deste trabalho, os estudos realizados (SRIVASTAVA, 1963; GOODMAN, 1963)

mostram que o *speckle*, modelado a partir da matriz de covariância complexa, pode apresentar uma distribuição *Wishart*. Por sua vez, dependendo do grau de homogeneidade dos alvos contidos na imagem, assim como acontece com dados monocanal, a modelagem do *backscatter* pode assumir diferentes distribuições. A consequência direta dessa situação é a que a distribuição associada ao retorno V também irá variar.

Neste trabalho, a modelagem estatística dos dados SAR será baseada na suposição que os alvos contidos na imagem são homogêneos. Decorrente desta suposição, da mesma forma como é feito para dados monocanal, o *backscatter* (B) é modelado por um valor constante e desconhecido, e conseqüentemente, o retorno V também apresenta uma distribuição *Wishart*.

Para o caso dos dados em intensidade processados com várias visadas, será adotada uma distribuição *Gama* $\Gamma(L, \beta)$ para modelar a variável aleatória S . A seguir são apresentadas as distribuições estatísticas adotadas neste trabalho, para modelar os dados SAR polarimétricos e fundamentar os testes necessários para realizar a segmentação das imagens.

2.2.2. Distribuição *Wishart*

Segundo Goodman (1963), o vetor de espalhamento apresentado na Equação (2.2), pode, sob certas condições, ser modelado por uma distribuição Gaussiana complexa multivariada, isto é $\mathbf{K}_B \sim N_c(0, \mathbf{\Sigma})$ cuja função densidade de probabilidade é dada por

$$f(\mathbf{k}_B) = \frac{1}{\pi^3 |\mathbf{\Sigma}|} e^{-\mathbf{k}_B^* \mathbf{\Sigma}^{-1} \mathbf{k}_B} \quad (2.6)$$

onde $\mathbf{\Sigma} = E[\mathbf{k} \cdot \mathbf{k}^{*T}]$ é a variável aleatória que representa a matriz de covariância complexa de \mathbf{K}_B , $|\cdot|$ denota o determinante de uma matriz, o sobrescrito -1 denota a inversa de uma matriz e $E[\cdot]$ denota a esperança de uma variável aleatória.

Segundo Srivastava (1963) e Goodman (1963), se a matriz $[\mathbf{Z}]$ definida na Equação (2.4), tem L números de *looks*, então a matriz Hermitiana $[\mathbf{H}] = L[\mathbf{Z}]$ possui uma distribuição *Wishart* complexa multivariada denotada por $[\mathbf{H}] \sim W_c(L, \mathbf{\Sigma})$ com uma matriz de covariância média $\mathbf{\Sigma}$ e função densidade de probabilidade dada por (LEE et al., 1994)

$$f(h) = \frac{|h|^{L-p}}{\Gamma_p(L) \cdot |\mathbf{\Sigma}|^L} \cdot e^{-tr(\mathbf{\Sigma}^{-1}h)} \quad (2.7)$$

onde, $tr(\cdot)$ denota o traço de uma matriz, p é a ordem da matriz e $\Gamma_p(L)$ é a função gama dada por

$$\Gamma_p(L) = \pi^{(1/2)p(p-1)} \cdot \prod_{j=1}^L \Gamma(L-j+1). \quad (2.8)$$

A distribuição *Wishart* tem sido usada como a base para modelar dados PolSAR em diversos algoritmos de classificação e segmentação (BEAULIEU e TOUZI, 2003; CONRADSEN et al., 2003; FERRO-FAMIL et al., 2001; LEE et al., 1999; LEE et al., 1994), técnicas de detecção de bordas (SCHOU et al., 2003) e técnicas de detecção de mudanças de alvos (CONRADSEN et al., 2001).

2.2.3. Distribuição *Wishart* escalonada

Nascimento (2012) em seu trabalho sobre distâncias estocásticas apresenta a distribuição de $[\mathbf{Z}]$, que representa o retorno V , denominada distribuição *Wishart* complexa escalonada. Considerando L e $\mathbf{\Sigma}$ os seus parâmetros, tal distribuição, denotada por $[\mathbf{Z}] \sim W_E(L, \mathbf{\Sigma})$, é caracterizada pela seguinte função densidade de probabilidade

$$f(z) = \frac{L^p |z|^{L-p}}{\Gamma_p(L) \cdot |\mathbf{\Sigma}|^L} \cdot e^{tr(-L\mathbf{\Sigma}^{-1}z)} \quad (2.9)$$

Cabe observar que, embora $[\mathbf{Z}]$ e Σ sejam denominadas de matriz de covariância, a primeira trata-se de uma variável aleatória, enquanto que a segunda é um parâmetro da distribuição, podendo este último ser estimado.

Dessa forma, o estimador do parâmetro Σ para uma região com N pixels representados por $[\mathbf{Z}_k]$ para $k = 1, \dots, N$, pode ser dado por

$$\hat{\Sigma} = \frac{1}{N} \sum_{k=1}^N [\mathbf{Z}_k] \quad (2.10)$$

2.2.4. Distribuição Gama

Os elementos da diagonal principal da matriz de covariância complexa representam dados em intensidade. Dessa forma, uma matriz de covariância com ordem unitária ($p = 1$) é constituída por um único canal com dados representados em intensidade. Neste caso, a distribuição *Wishart* escalonada degenera para a distribuição *Gama*. Representando um elemento da diagonal principal da matriz de covariância pela variável aleatória X , pode-se afirmar que, sob as condições acima, esta variável aleatória possuirá uma distribuição *Gama* com parâmetros L e β , denotada por $\Gamma(L, \beta)$, cuja função densidade de probabilidade é dada por:

$$f(x) = \frac{L^L}{\Gamma(L)\beta^L} \cdot x^{L-1} e^{-\frac{L}{\beta}x}, \text{ para todo, } x \in \Re_+ \quad (2.11)$$

onde, $\Gamma(\cdot)$ é a função gama de Euler e β está relacionada ao valor médio dos dados em intensidade. Para esta distribuição tem-se que a média e a variância são dadas, respectivamente por

$$E(X) = \beta \text{ e } Var(X) = \frac{\beta^2}{L} \quad (2.12)$$

Cabe mencionar que nas distribuições apresentadas L pode representar tanto o real número de *looks*, quando os dados são independentes, ou o número equivalente de *looks* (nel), quando constatado dependência nos dados (YANASSE et al., 1995).

2.3. Testes estatísticos para dados SAR polarimétricos

A seguir são descritos os dois testes estatísticos adotados neste trabalho para realizar a segmentação de imagens PolSAR representadas pela matriz de covariância complexa. As aplicações destes testes serão vistos com mais detalhes no Capítulo 5.

2.3.1. Teste de igualdade de médias de intensidades

O teste supõe que se deseja comprovar a igualdade da intensidade média de duas regiões homogêneas, \mathbf{X} e \mathbf{Y} , pertencente a uma imagem SAR representada por matriz de covariância com ordem igual a um. Para isso, são estabelecidas as seguintes hipóteses:

$$H_0 : \mu_y = \mu_x = \mu \quad (2.13)$$

$$H_1 : \mu_y \neq \mu_x$$

Considere duas regiões \mathbf{X} e \mathbf{Y} , com respectivamente N_1 e N_2 *pixels*, em uma imagem complexa com 1-*look* (Figura 2.1).

Tem-se que os *pixels* destas regiões podem ser representados homologamente nas componentes real (\Re) e imaginária (\Im) por

$$x_1^{\Re}, \dots, x_{N_1}^{\Re} \text{ e } x_1^{\Im}, \dots, x_{N_1}^{\Im} \quad (2.14)$$

$$y_1^{\Re}, \dots, y_{N_2}^{\Re} \text{ e } y_1^{\Im}, \dots, y_{N_2}^{\Im} \quad (2.15)$$

Supondo que as regiões sejam homogêneas, tem-se que as variáveis aleatórias representando estes *pixels* independentes e identicamente distribuídos, com distribuição Gaussiana com média zero e variâncias σ_X^2 e σ_Y^2 para as regiões **X** e **Y**, isto é

$$x_i^{\Re}, x_i^{\Im} \sim N(0, \sigma_X^2) \quad (2.16)$$

$$y_i^{\Re}, y_i^{\Im} \sim N(0, \sigma_Y^2) \quad (2.17)$$

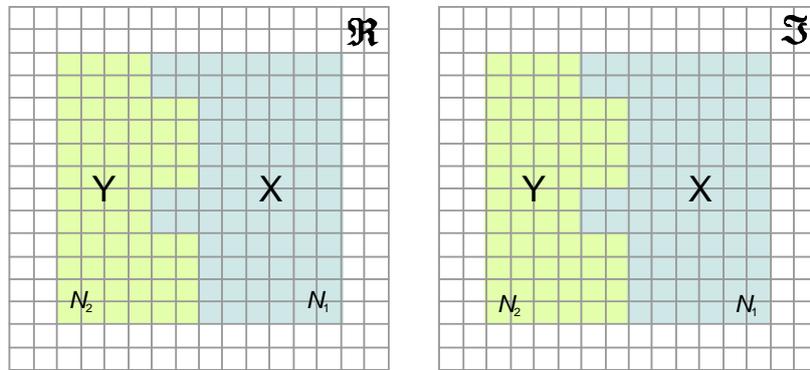


Figura 2.1 - Regiões **X** e **Y** representadas nas componentes real (\Re) e imaginária (\Im) de uma imagem SAR complexa.

Sabe-se que, sob estas condições, as variáveis aleatórias representando as intensidades dos *pixels* i e j das regiões **X** e **Y**, representadas por $X_i = (X_i^{\Re})^2 + (X_i^{\Im})^2$ e $Y_j = (Y_j^{\Re})^2 + (Y_j^{\Im})^2$ possuem distribuição *Gama* ($\Gamma(L, \beta)$) com médias $2\sigma_X^2$ e $2\sigma_Y^2$, respectivamente. Portanto, o teste de hipótese da Equação (2.13) é equivalente a

$$H_0: \sigma_X^2 = \sigma_Y^2 = \sigma^2 \quad (2.18)$$

$$H_1: \sigma_X^2 \neq \sigma_Y^2$$

Os estimadores de σ_X^2 e σ_Y^2 podem ser calculados respectivamente por

$$s_{\mathbf{X}}^2 = \frac{\sum_{i=1}^{N_1} (x_i^{\Re})^2 + \sum_{i=1}^{N_1} (x_i^{\Im})^2}{2 \cdot N_1} = \frac{\sum_{i=1}^{N_1} x_i}{2 \cdot N_1} = \frac{\bar{\mathbf{X}}}{2} \quad (2.19)$$

$$s_{\mathbf{Y}}^2 = \frac{\sum_{i=1}^{N_2} (y_i^{\Re})^2 + \sum_{i=1}^{N_2} (y_i^{\Im})^2}{2 \cdot N_2} = \frac{\sum_{i=1}^{N_2} y_i}{2 \cdot N_2} = \frac{\bar{\mathbf{Y}}}{2} \quad (2.20)$$

onde x_i e y_i representam respectivamente a intensidade do i -ésimo *pixel* das regiões \mathbf{X} e \mathbf{Y} , e $\bar{\mathbf{X}}$ e $\bar{\mathbf{Y}}$ representam respectivamente suas intensidades médias.

Sabe-se que

$$2N_1 \frac{s_{\mathbf{X}}^2}{\sigma_{\mathbf{X}}^2} \sim \chi_{2N_1}^2 \quad (2.21)$$

$$2N_2 \frac{s_{\mathbf{Y}}^2}{\sigma_{\mathbf{Y}}^2} \sim \chi_{2N_2}^2 \quad (2.22)$$

Desse modo tem-se que

$$F = \frac{\frac{2N_2 \cdot s_{\mathbf{Y}}^2}{2N_2 \cdot \sigma_{\mathbf{Y}}^2}}{\frac{2N_1 \cdot s_{\mathbf{X}}^2}{2N_1 \cdot \sigma_{\mathbf{X}}^2}} = \frac{s_{\mathbf{Y}}^2 \sigma_{\mathbf{X}}^2}{s_{\mathbf{X}}^2 \sigma_{\mathbf{Y}}^2} \sim F(2N_2, 2N_1) \quad (2.23)$$

Sob H_0 , tem-se que

$$F^* = \frac{s_{\mathbf{Y}}^2}{s_{\mathbf{X}}^2} = \frac{\bar{\mathbf{Y}}}{\bar{\mathbf{X}}} \sim F(2N_2, 2N_1) \quad (2.24)$$

Portanto, rejeita-se H_0 se $F^* \leq d_1$ ou $F^* \geq d_2$, onde d_1 e d_2 são obtidos pelos centis da distribuição F com graus de liberdade $2N_2, 2N_1$.

O teste apresentado acima, por ter sido desenvolvido a partir das imagens complexas, considera implicitamente que cada pixel da região possui 1-look.

Em geral, as imagens SAR em intensidade são processadas usando vários *looks* e possuem dados correlacionados. Tal fato faz com que esta condição deva ser considerada na execução do teste estatístico. Dessa forma, denominando n e m como os números de *pixels* independentes respectivamente das regiões \mathbf{X} e \mathbf{Y} tem-se que

$$F = \frac{s_y^2 \sigma_x^2}{s_x^2 \sigma_y^2} \sim F = \frac{s_Y^2 \sigma_X^2}{s_X^2 \sigma_Y^2} \sim F(2m, 2n) \quad (2.25)$$

Sob H_0 a estatística de teste será,

$$F^* = \frac{\bar{\mathbf{Y}}}{\bar{\mathbf{X}}} \sim F(2m, 2n) \quad (2.26)$$

Cabe ressaltar que a estatística de teste F^* é a mesma apresentada na Equação (2.24), alterando-se somente os graus de liberdade da distribuição. Desse modo rejeita-se H_0 se $F^* \leq d_1$ ou $F^* \geq d_2$, onde d_1 e d_2 são obtidos pelos centis da distribuição F com graus de liberdade $2m$ e $2n$.

2.3.2. Teste de igualdade de matrizes de covariâncias complexas

O desenvolvimento de testes de hipóteses baseados na distribuição estatística da matriz de covariância tem sido o foco de diversos trabalhos, tais como aqueles desenvolvidos por Shou et al. (2003), Conradsen et al. (2003), Nascimento et al. (2011), dentre outros. Dentro deste contexto, Nascimento (2012), apresenta uma estatística de teste da razão de verossimilhança baseado na distribuição *Wishart* complexa escalonada, a qual é adotada neste trabalho para realizar a segmentação de dados PolSAR. Este teste é similar ao apresentado por Conradsen et al. (2003), o qual utiliza a distribuição *Wishart* não escalonada e considera conhecido o número equivalente de *looks*.

Considere duas regiões \mathbf{X} e \mathbf{Y} , com respectivamente N_1 e N_2 *pixels*, possuindo distribuições *Wishart* complexas escalonadas, representadas respectivamente

por $W_E(L_1, \Sigma_1)$ e $W_E(L_2, \Sigma_2)$, onde L_i e Σ_i representam respectivamente os parâmetros número de *looks* e matriz de covariância das distribuições. Nascimento (2012) estabeleceu para estas regiões o teste de razão de máxima verossimilhança de igualdade dos parâmetros de suas distribuições, o qual é formulado pelas hipóteses:

$$H_0 : (L_1, \Sigma_1) = (L_2, \Sigma_2) \quad (2.27)$$

$$H_1 : (L_1, \Sigma_1) \neq (L_2, \Sigma_2)$$

A razão de verossimilhança $\lambda_{W_E(L, \Sigma)}$ é calculada em função dos estimadores $\bar{\mathbf{X}}$ e $\bar{\mathbf{Y}}$ das matrizes de covariância das regiões, os quais são obtidos a partir do cálculo da média das matrizes de covariância que representam os valores dos *pixels* contidos em cada região. Sob a suposição de que os números de *looks* são conhecidos, a razão de verossimilhança é dada por

$$\lambda_{W_E(L, \Sigma)} = \frac{|\bar{\mathbf{X}}|^{N_1 \cdot L_1} |\bar{\mathbf{Y}}|^{N_2 \cdot L_2}}{|\bar{\mathbf{Z}}|^{N_1 \cdot L_1 + N_2 \cdot L_2}} \quad (2.28)$$

onde $|\cdot|$ denota o determinante de uma matriz, L_1 e L_2 são respectivamente os números de *looks* das regiões \mathbf{X} e \mathbf{Y} , e $\bar{\mathbf{Z}}$ é o estimador da matriz de covariância sob H_0 , dado por:

$$\bar{\mathbf{Z}} = \frac{N_1 \cdot \bar{\mathbf{X}} + N_2 \cdot \bar{\mathbf{Y}}}{N_1 + N_2} \quad (2.29)$$

O valor de $\lambda_{W_E(L, \Sigma)}$ é limitado ao intervalo $[0, 1]$. Em Conradsen et al. (2003), é mostrado que a estatística M dada por

$$M = -2\rho \ln(\lambda_{W_E(L, \Sigma)}) \quad (2.30)$$

com

$$\rho = 1 - \frac{2p^2 - 1}{6p} \cdot \left(\frac{1}{N_1 \cdot L_1} + \frac{1}{N_2 \cdot L_2} - \frac{1}{(N_1 \cdot L_1 + N_2 \cdot L_2)} \right) \quad (2.31)$$

possui função distribuição assintótica dada por

$$P\{M \leq \ell\} \cong P\{\chi^2(p^2) \leq \ell\} + \varpi_2 [P\{\chi^2(p^2 + 4) \leq \ell\} - P\{\chi^2(p^2) \leq \ell\}] \quad (2.32)$$

onde p é a ordem da matriz, $\chi^2(\gamma)$ denota uma variável aleatória com distribuição χ^2 com γ graus de liberdade, e ϖ_2 é definido por (CONRADSEN et al., 2003)

$$\varpi_2 = -\frac{p^2}{4} \left(1 - \frac{1}{\rho}\right)^2 + \frac{p^2(p^2 - 1)}{24\rho^2} \cdot \left(\frac{1}{(N_1 \cdot L_1)^2} + \frac{1}{(N_2 \cdot L_2)^2} - \frac{1}{(N_1 \cdot L_1 + N_2 \cdot L_2)^2} \right) \quad (2.33)$$

Convém observar que, por se tratar de um resultado assintótico, a Equação (2.32) pode apresentar, na prática, problemas numéricos para valores relativamente pequenos de N_1L_1 e N_2L_2 . Isto se deve porque o valor de ρ , usado no cálculo da estatística de teste M , pode para $p \geq 2$ resultar em valores negativos. Este fato faz com que a probabilidade dada pela Equação (2.32) também apresente valores negativos o que inviabiliza o uso do teste de hipóteses. A Tabela 2.1 apresenta os valores mínimos considerando $N_1L_1 = N_2L_2$, para diferentes dimensões de matriz de covariância, para que não ocorram problemas numéricos durante a aplicação do teste.

Tabela 2.1 - Valores mínimos de N_1L_1 , em função da dimensão da matriz, para aplicação do teste de igualdade de matrizes de covariância.

Dimensão da matriz de covariância	N_1L_1
2x2	1,125
3x3	1,583
4x4	2,063
5x5	2,550
6x6	3,042
7x7	3,536
8x8	4,031
9x9	4,528

3 SEGMENTAÇÃO DE IMAGENS

Este capítulo apresenta em sua primeira seção alguns conceitos de segmentação de imagens e uma breve descrição de diversos algoritmos de segmentação de imagens SAR encontrados na literatura. Na segunda e terceira seções são abordados, respectivamente, alguns aspectos envolvidos na avaliação de resultados de segmentação de imagens e a metodologia adotada para avaliar o algoritmo desenvolvido.

3.1. Definição e conceitos

A obtenção de informações confiáveis a partir da análise de uma imagem está intimamente ligada à qualidade desta imagem e aos processos e técnicas usados para realizar a extração das informações. Esta extração, quando usadas imagens digitais, é feita com a aplicação de algoritmos que têm como objetivo realçar características e estruturas das feições presentes na imagem, para auxiliar o processo de reconhecimento, entendimento e mensuração.

Segundo Gonzalez e Woods (1987), as técnicas de extração de informações a partir de imagens pertencem à área do processamento referida como análise. Nesta visão a segmentação, como ferramenta de extração de informações, está intimamente ligada à análise. Este fato posiciona a segmentação como operação no limiar entre o processamento de imagem de baixo nível e a análise de imagem de alto nível. De forma geral, isto se deve porque enquanto no processamento de imagem tem-se como entrada uma imagem bruta e como saída uma imagem tratada, a análise de imagem envolve a redução de informações contidas na imagem e alguma extração de conhecimento.

Estando a segmentação mais ligada à análise que ao processamento de imagens sua definição geralmente se encontra vinculada à área onde ela é aplicada. Por exemplo, dentro da área de visão computacional, a segmentação refere-se ao processo de decomposição de uma imagem digital em vários segmentos (regiões) que a formam (JAIN, 1989). Já para a área de

processamento digital de imagens de sensoriamento remoto, a segmentação de imagem é a parte da análise de imagem que trata da definição de objetos geográficos ou regiões em uma imagem (MOIK, 1980). Dessa forma, quando os objetos numa imagem forem grandes e não possuírem superfícies muito detalhadas, a segmentação é imaginada como a divisão da imagem em um número não definido de regiões, cada uma com um elevado grau de uniformidade em relação a alguns parâmetros, tais como brilho, cor, textura, ou até mesmo movimento (DAVIES, 2004).

De qualquer forma, independentemente da definição adotada, a segmentação de imagens possuirá basicamente dois objetivos: (i) decompor a imagem em partes para posterior análise, e (ii) realizar uma mudança de representação (SHAPIRO e STOCKMAN, 2001). Dentro desta ótica, pode-se dizer que o objetivo da segmentação é simplificar e ou alterar a representação de uma imagem para algo que seja mais significativo e mais fácil de ser analisado.

Sendo assim, o resultado final esperado de um processo de segmentação é um número finito de regiões homogêneas, que individualizam as diferentes regiões contidas numa imagem. A imagem então passa a ser formada por um conjunto de regiões, conectadas pelas suas bordas e que não se sobrepõe, de tal forma que cada *pixel* da imagem pertence unicamente a uma determinada região (ACHARYA e RAY, 2005). Em outras palavras, após a segmentação, é possível saber a qual região cada *pixel* pertence, bem como, a partir do conhecimento das discontinuidades, obter a vizinhança de cada região contida na imagem. Para fins práticos, isto significa a possibilidade de executar a mensuração das regiões ou mesmo estabelecer relações de vizinhança entre regiões adjacentes, permitindo o uso dessas informações para diversas aplicações.

Para estar de acordo com o que foi apresentado, esta tese adota a formulação básica apresentada por Fu e Mui (1981). Segundo essa formulação, se considerarmos Λ o suporte de uma imagem de Nl linhas e Nc colunas, sua

segmentação será dada pela decomposição de Λ em N regiões $\Lambda_1, \Lambda_2, \dots, \Lambda_N$ de forma que:

a) $\cup_{i=1}^N \Lambda_i = \Lambda$;

b) Λ_i é conectada para todo $i=1, 2, \dots, N$;

c) $\Lambda_i \cap \Lambda_j = \emptyset$, para todo $i \neq j$;

d) $Pu(\Lambda_i) = \textit{verdadeiro}$, para todo i ;

e) $Pu(\Lambda_i \cup \Lambda_j) = \textit{falso}$, para todo $i \neq j$, com Λ_i e Λ_j adjacentes;

onde Pu é o predicado de uniformidade adotado para caracterizar a homogeneidade das regiões.

O conceito de segmentação da forma com que é apresentado idealiza o mundo real de forma conveniente para diversas aplicações práticas. Entretanto, cabe lembrar que é uma abstração da mente humana e que embora seja uma boa abordagem para materializar soluções para trabalhos de análise de imagens, pode em algumas situações levar a resultados insatisfatórios (DAVIES, 2004). Isto ocorre porque a segmentação de imagem é basicamente um problema de percepção psicofísica, e, portanto, não susceptível de uma solução puramente analítica (NIKHIL e SANKAR, 1993).

O que se procura fazer para obter a segmentação, a partir de imagens digitais, é traduzir para o computador um processo cognitivo extremamente sofisticado realizado pelo cérebro através da visão humana. Sendo assim, para gerar um resultado satisfatório, qualquer algoritmo de segmentação, não importando o modelo matemático adotado, deve ser complementado por heurísticas que envolvam tanto informação semântica como conhecimento *a priori* sobre as imagens que estão sendo processadas (YONG et al., 2004). Esta característica faz com que a elaboração de algoritmos visando à automatização de processos de extração de informações a partir de imagens por meio da segmentação se

torne uma tarefa de difícil solução. Isto por sua vez, permite que diversas técnicas usando as mais variadas abordagens sejam usadas na segmentação de imagens.

3.2. Segmentação de imagens SAR

Uma das principais aplicações do sistema PolSAR no âmbito do SR é a classificação de diferentes coberturas do solo. A classificação dos dados pode ser baseada em *pixels* ou baseada em segmentos. Neste último caso a imagem antes de ser classificada passa por um processo de segmentação que reduz a quantidade de informação e individualiza as feições contidas em uma imagem, deixando-a pronta para a fase de classificação. Para as imagens SAR, que, devido à sua natureza, apresentam o efeito do ruído *speckle*, este procedimento apresenta vantagens significativas quando comparado com os processos de classificação que simplesmente atribuem a cada *pixel* um número identificador da classe a que pertence.

Segundo Gonzalez e Woods (1987), normalmente, a segmentação é feita tomando por base as características de descontinuidade e similaridade encontradas nas imagens. Decorrentes disso, os métodos de segmentação procuram detectar estas características a fim de individualizar as feições de interesse na imagem. Esta mesma abordagem é usada para o desenvolvimento dos algoritmos destinados a realizar a segmentação de imagens SAR.

Entretanto, para as imagens SAR as características de descontinuidade e similaridade sofrem maior influência devido ao ruído. Este fato faz com que abordagens determinísticas usadas na segmentação de imagens ópticas com bom desempenho não tenham o mesmo rendimento ao serem aplicadas sobre imagens SAR. Esta situação e a possibilidade de modelar adequadamente o comportamento do ruído *speckle*, conforme abordado anteriormente, acaba implicando no uso de modelos probabilísticos específicos para imagens SAR para obtenção de melhores resultados. Dessa forma, a maior parte das

abordagens para fundamentar o desenvolvimento dos algoritmos de segmentação de imagens SAR, leva em consideração, além das características de descontinuidade e similaridade que fundamentam a segmentação de imagens, a modelagem estatística do *speckle* e do *backscatter*.

Cabe mencionar ainda, que a disponibilização de dados PolSAR tem feito com que novas abordagens sejam adotadas para realizar a segmentação, as quais devem ser capazes de explorar a informação adicional que esses dados contêm. Este fato, aliado à dificuldade já encontrada de segmentar adequadamente os dados dos sensores SAR, abre uma vasta área para pesquisas e tem dado origem ao desenvolvimento de diferentes algoritmos usando as mais variadas abordagens disponíveis na atualidade. A seguir são citados alguns trabalhos realizados para segmentar dados SAR em intensidade, amplitude e polarimétricos, com o intuito de ilustrar a diversidade de abordagens e ressaltar a importância da segmentação desses dados no contexto do Sensoriamento Remoto.

3.2.1. Segmentação de imagens SAR monocanais e multicanais em amplitude ou intensidade

A fim de fundamentar o desenvolvimento de algoritmos de segmentação de imagens SAR, Oliver e Quegan (2004) definiram dois modelos: o *cartoon*, que supõe que as imagens são compostas por regiões, separadas por bordas, dentro das quais o *backscatter* possui um valor constante; e o *texture* (textura) que supõe uma variação interna no *backscatter* dentro de cada região.

Oliver e Quegan (2004) tomando por base o modelo *cartoon*, apresentaram dois algoritmos, que servem de inspiração para diversos outros e são citados com frequência na literatura, o *Merge Using Moments* (MUM) e o *Iterative Edge Detection and Segment Growing* (RWSEG). O MUM (OLIVER e QUEGAN, 2004) explora mais diretamente o modelo *cartoon* e tenta obter grandes regiões uniformes, por meio do agrupamento de pequenas regiões (que pode incluir apenas um único *pixel*). O algoritmo básico proposto por Cook et al. (1994)

trabalha com imagens SAR em intensidade, em um único canal. O algoritmo tem início com a divisão da imagem em pequenas regiões quadradas com dimensões de $N \times N$ *pixels*, onde o valor de N depende geralmente da resolução desejada para o resultado a ser gerado na segmentação e do esforço computacional. Estes pequenos segmentos iniciais são então agrupados tomando por base suas propriedades estatísticas. O algoritmo define as regiões na imagem por meio de um processo iterativo de seleção aleatória de *pixels* inicial para segmentação e crescimento de regiões por agrupamento. A seleção é realizada porque a ordem do agrupamento de regiões afeta o resultado final. O agrupamento realizado no algoritmo original se fundamenta no teste t de *Student*, o qual é apropriado para dados com distribuição Gaussiana, e inapropriado para dados SAR.

Conforme mencionado em Oliver e Quegan (2004), uma melhora no resultado da segmentação pode ser obtida por meio da aplicação dos testes estatísticos apropriados para dados no formato de intensidade, com distribuição *Gama* para imagens SAR em um único canal.

O RWSEG por sua vez trabalha com a detecção de bordas, a qual é usada para limitar o crescimento. Este algoritmo, proposto por White (1986), usa uma janela de tamanho adaptável para detecção de bordas. O processo de detecção de bordas é sucessivo e no final deste é realizado o agrupamento das regiões para gerar a segmentação. A cada iteração é calculado o contraste médio das regiões. O processo é finalizado quando a variação dos valores dos contrastes entre duas iterações for pequena.

Cabe lembrar aqui que tanto o MUM como o RWSEG foram originalmente desenvolvidos para trabalhar com dados em um único canal, sendo ambos posteriormente transformados para lidar com dados SAR multicanal no formato de intensidade. A estratégia usada para transformar esses algoritmos é descrita em Caves et al. (1998).

Outro algoritmo que pode adotar tanto o modelo *cartoon*, como o modelo *texture*, para realizar a segmentação é o SegSAR, desenvolvido por Sousa Junior (2005). O SegSAR é descrito como um segmentador híbrido por fazer uso das técnicas de crescimento de regiões, agrupamento de regiões, ajuste de bordas e separação de regiões não homogêneas. Além disso, é considerado multinível (trabalha com pirâmides hierárquicas), multibandas (permite várias imagens como entrada) e hierárquico (usa a informação de um nível para a segmentação em outro nível). O processamento das imagens de radar é feito no formato de intensidade, embora as imagens de entrada possam estar nos formatos de amplitude, intensidade ou dB. Para a segmentação de imagens SAR no modelo *cartoon* o algoritmo inicia o processo de crescimento de regiões através de um limiar de similaridade (em dB) e de testes t de Student. O segmentador também faz uso das propriedades da distribuição *Gama*, usando como critério para testar a homogeneidade de uma região o coeficiente de variação crítico, o qual é obtido por simulação Monte Carlo sobre amostras com distribuição *Gama* com parâmetro nel e nel/μ e denotada por $(\Gamma(nel, nel/\mu))$ para diferentes níveis de significância.

Adotando a abordagem baseada em histograma, Lee e Jurkevich (1989) investigaram a viabilidade de realizar a segmentação de imagens SAR tomando por base a técnica de limiarização de histograma a partir da modelagem estatística do *speckle*. Os testes realizados envolveram o uso de imagens simuladas e reais no formato de amplitude oriunda do sensor SIR-B de polarização única (*hh*), processadas em 1-look e múltiplas visadas. Os pesquisadores chegaram à conclusão que a técnica é inadequada para a segmentação de imagens SAR de 1-look no formato de intensidade. Por sua vez, verificaram ao aplicar a técnica para imagens SAR de 1-look no formato de amplitude, que os resultados de segmentação foram tão bons quanto aos resultados obtidos usando imagens SAR de múltiplas visadas no formato de intensidade. Seguindo a mesma linha de trabalho, Smith (1996) apresentou um

método para redução do *speckle* e segmentação baseado na técnica de limiarização de histograma.

Por sua vez, Zaart et al. (1999) desenvolveram um algoritmo para segmentação de imagens SAR baseado em limiarização de histograma, para ser usado com dados monocanal (polarização *hh*) do sensor RADARSAT-1. Neste algoritmo é feita a suposição que o histograma é formado por uma mistura de distribuições *Gama*. Os parâmetros do histograma são estimados por máxima verossimilhança, enquanto os limiares são obtidos pela minimização do erro de discriminação entre as classes dos *pixels* na imagem. Estes limiares são então usados sobre o histograma multimodal para a discriminação das classes.

Orbanz e Buhmann (2005) também desenvolveram um algoritmo de segmentação baseado em histograma usando grupos de modelos de mistura de Gaussianas e algoritmo EM (*Expectation-Maximization*) adaptado. O algoritmo foi desenvolvido para usar imagens SAR monocanal no formato de intensidade, embora, conforme comentado pelos pesquisadores possa ser facilmente adaptado para trabalhar com mais canais em intensidade.

Delon et al. (2007) apresentaram um amplo panorama de algoritmos de segmentação baseados em histograma. Entre eles estão os algoritmos de segmentação paramétricos, nos quais se supõe que o conjunto de dados pode ser considerado como mistura de k variáveis aleatórias de distribuições dadas, como nos modelos de mistura de Gaussiana (DUDA et al., 2000), e os algoritmos não paramétricos que não exigem qualquer suposição sobre a função densidade dos dados subjacentes, tais como métodos de limiarização de dois níveis e multinível (CHENG e SUN, 2000).

Dabor et al. (2010), seguindo esta linha, apresentaram um método para segmentação de dados PolSAR baseado no comportamento do espalhamento e histogramas. O método é composto por uma nova metodologia de segmentação hierárquica divisível multinível baseada na separação do

mecanismo de espalhamento produzido por métodos de decomposição polarimétricos tais como o de Pauli e o de Freeman-Durden. A metodologia é específica ao segmento, isto é, vários níveis de segmentação podem ser criados para os segmentos selecionados pelo usuário. No primeiro e segundo níveis, a segmentação é realizada com base no mecanismo de espalhamento dominante e no segundo no mecanismo de dispersão mais significativo. Nos níveis subsequentes, os dados são segmentados usando um algoritmo de segmentação não paramétrico baseado em histograma. A metodologia foi aplicada sobre dados PolSAR do sensor orbital ALOS (*Satellite Advanced Land Observing*) e apresenta como vantagem o fato de poder ser ajustada às necessidades do usuário e ao conhecimento existente da área que se pretende segmentar.

Seguindo a abordagem baseada em agrupamento, conhecida por *clustering*, Li e Chen (2007) desenvolveram um algoritmo híbrido baseado em agrupamento hierárquico que não requer a entrada de parâmetros, o qual foi usado para processar imagens SAR do sensor RADARSAT-1. O processamento tem início com a aplicação do filtro de Touzi (2002) sobre a imagem original para reduzir o efeito do *speckle* e gerar uma imagem de gradiente. Esta é processada usando a técnica de detecção de bacias (*watershed*), que gera os segmentos iniciais. A imagem transformada pelo *watershed* é por sua vez submetida ao algoritmo *k*-médias para obter os agrupamentos iniciais, que são então reduzidos pelo método de agrupamento definido por Cihlar et al. (1999).

A abordagem de segmentação baseada na técnica de agrupamento *k*-médias também foi discutida em Lee et al. (1999), onde os dados são inicialmente segmentados em oito classes com base no plano H (entropia)/ α (ângulo-alfa). O agrupamento *Wishart k*-médias é aplicado às matrizes de coerência das classes iniciais para otimizar a inicialização.

Outra abordagem de segmentação usando a técnica de agrupamento *k*-médias foi investigada em Cao et al. (2007). A abordagem é baseada em uma

segmentação inicial dos dados polarimétricos em 48 agrupamentos utilizando o espaço SPAN/entropia/ângulo-alfa/anisotropia. Os agrupamentos são otimizados através da aplicação do algoritmo de agrupamento *Wishart k*-médias para as matrizes de coerência dos dados. Em seguida, através de uma abordagem de agrupamento, os agrupamentos considerados similares são fundidos em um número pré-definido de classes com base na estrutura interna dos dados.

Adotando a abordagem baseada em *wavelet*, Shi et al. (2004), desenvolveram um algoritmo híbrido usando feições de níveis de cinza, feições de bordas e *clustering* (*Fuzzy C* médias). O algoritmo desenvolvido trabalha com imagens em um único canal tendo sido testado com dados SAR simulados. Por sua vez, De Grandi et al. (2001) propuseram um método de segmentação e classificação de dados polarimétricos com base em uma estrutura *wavelet* que funciona como um operador diferencial e gera aproximações suaves por partes das imagens em intensidade da matriz de covariância.

Adotando abordagens relacionadas às técnicas de contornos ativos, Shuai et al. (2007) desenvolveram um algoritmo de segmentação de imagens SAR por método variacional baseado em evolução de curvas e *level set*. Este algoritmo foi desenvolvido para usar imagens SAR monocanais em intensidade, sendo testado em imagens simuladas de três *looks* e imagens reais do sensor MSTAR. O algoritmo emprega o modelo *level set* modificado, proposto por Chan e Vese (2001).

Dentro da mesma linha, Ayed et al. (2005) propuseram um algoritmo para segmentação baseado no uso de contornos ativos e *level set* para individualizar em imagens SAR regiões homogêneas baseadas na distribuição *Gama*. O algoritmo desenvolvido trabalha com dados SAR monocanal em intensidade.

Por sua vez, adotando a abordagem da teoria de grafos, Xu et al. (2007) apresentam um algoritmo de segmentação para imagens SAR monocanal,

baseado em grafos e informação de medida de similaridade. O algoritmo desenvolvido é baseado na suposição que um conjunto de pontos em um espaço de atributos arbitrário pode ser representado como um grafo não direcionado ponderado, onde os vértices são os pontos no espaço de atributos e uma aresta é formada entre cada par de vértices. Sobre este grafo é então aplicada a noção de *graph cut* (poda), usando-se as medidas de similaridades.

Fjørtoft et al. (1997) também já haviam examinado o efeito da combinação de detecção de bordas e crescimento de regiões na segmentação de imagens SAR, o qual foi usado para o desenvolvimento de um algoritmo para processar dados monocal no formato de intensidade do sensor ERS-1. Neste algoritmo a detecção por bordas foi desenvolvida tomando por base o operador de razão de médias ponderadas exponencialmente ou simplesmente ROEWA, do termo em inglês *Ratio Of Exponentially Weighted Averages* (BOVIK, 1988; TOUZI et al., 1988). O ROEWA é uma versão modificada não linear do detector de bordas proposto por Shen e Castan (1992) para imagens ópticas. A modificação feita neste detector de bordas consiste na substituição da diferença entre duas médias ponderadas exponencialmente, calculadas sobre cada lado da janela que envolve o *pixel* central, por uma razão normalizada entre estas médias. O crescimento de regiões é realizado por processo de agrupamento a partir da imagem super segmentada, obtida com o operador ROEWA e detecção de bacias. O critério de razão de verossimilhança, adotado para realizar o agrupamento entre duas regiões adjacentes, é dado pela razão da probabilidade das duas regiões terem a mesma refletividade pela probabilidade de terem refletividades diferentes, sendo a estatística do *speckle* modelada por distribuição *Gama*.

A abordagem por campo aleatório de Markov (*Markov Random Field* - MRF) foi explorada por Weisenseel et al. (1998), que desenvolveram um algoritmo de segmentação para imagens SAR monocal, baseado em campo aleatório de Markov alterado para trabalhar com o método de *cluster* de Monte Carlo

(WANG e SWENDSEN, 1990), a fim de diminuir o número de iterações exigidas.

Na mesma linha, Benboudjema et al. (2007) propuseram uma abordagem para a segmentação de imagens SAR monocanal, baseada em campo de Markov triplo não estacionário e distribuição de Fisher. A abordagem foi usada no desenvolvimento de um segmentador, usado para processar dados SAR monocanal.

3.2.2. Segmentação de imagens PolSAR

Ersahin et al. (2010) propuseram uma nova abordagem para a segmentação e classificação de dados PolSAR com base no particionamento gráfico espectral (*spectral graph partitioning*), introduzido por Shi e Malik (2000). A segmentação é realizada utilizando informação baseada no contorno com auxílio da proximidade espacial para a definição das regiões. A segmentação é seguida por um passo de classificação por meio de particionamento gráfico realizada com base na semelhança das matrizes de coerência médias obtidas para cada segmento. Nesta fase os segmentos são agrupados em classes tomando por base a distância Simétrica Revisada de *Wishart*. O algoritmo foi testado com dados reais do sensor aerotransportado Convair-580 (Banda C) e AIRSAR (Banda L). Os autores mostram que a abordagem usada apresentou resultados superiores ao classificador *Wishart*. Além disso, sugerem uma nova forma de acomodar diferentes representações de dados polarimétricos e combiná-los com outras fontes de informações, tais como, imagens ópticas e modelos digitais de elevação.

Adotando a abordagem de detecção de bordas, Schou et al. (2003) desenvolveram o algoritmo CFAR (do termo em inglês *Constant False-Alarm Rate*) usado para detecção de bordas em dados PolSAR. O algoritmo foi desenvolvido tomando por base o teste de igualdade de matrizes de covariância desenvolvido por Conradsen et al. (2003). O CFAR aplica o teste a

partir de um *pixel* central sobre o seus vizinhos, quando a igualdade não é comprovada a borda é detectada.

Além deste trabalho, Fjørtoft et al. (1999) desenvolveram um critério para a detecção e localização de bordas em imagens PolSAR simuladas monocanais em 1-look do sensor ERS-1. Este critério foi usado para o desenvolvimento de um algoritmo estruturado em dois estágios: primeiro a detecção da borda é realizada por meio do uso de janelas multi-direcionais e limiarização dinâmica de borda, em seguida a borda é localizada tomando por base o campo aleatório de Gibbs ou contornos ativos.

Wang et al. (2010) apresentaram um método de segmentação para os dados PolSAR por combinação da análise de agrupamento no espaço tensor e estrutura Markoviana. O método parte do pressuposto que os dados PolSAR representados pela matriz de covariância podem ser representados como uma diversidade Riemanniana, onde cada matriz representa um tensor. Para isso, primeiro, o algoritmo de deslocamento médio (*Mean Shift* – MS), apresentado por Comaniciu e Meer (2002) é estendido para a diversidade Riemanniana para possibilitar o agrupamento de tais tensores. Em seguida, o método de segmentação baseado em campo aleatório de Markov empregando análise de cluster é usado. Neste são computados sobre a estrutura Riemanniana os graus de pertinência de cada partição de todas as matrizes de covariância em todos os clusters e as taxas de sobreposição entre cada dois clusters, as quais são usadas para definir os termos de dado e de suavização na estrutura do campo aleatório de Markov. A energia total é minimizada usando a otimização baseada em poda de grafo para encontrar a segmentação final. A eficácia do método foi verificada utilizando dados PolSAR do sensor E-SAR aerotransportado (Banda L) e imagens sintéticas.

Usando uma abordagem baseada em algoritmo híbrido, que incorpora várias técnicas de processamento de imagens, Yang et al. (2008) desenvolveram um algoritmo para segmentação de imagens PolSAR por meio de detecção de

bordas e crescimento de regiões usando informações da matriz de coerência complexa, que foi testado com dados do sensor aerotransportado JPL AIRSAR. Antes de iniciar a segmentação é realizada a decomposição do retroespalhamento a partir da imagem de coerência (CLOUDE e POTTIER, 1995) para obter as imagens de entropia e de ângulo alfa. O processamento do algoritmo é iniciado com a filtragem das imagens de entropia e de ângulo alfa por meio de aplicação de um filtro de média com janela 3x3, para eliminar o efeito do *speckle*. A detecção de bordas é iniciada submetendo individualmente estas imagens a um filtro de realce de bordas. As imagens realçadas são então processadas separadamente usando-se o detector de bordas de Canny, gerando dois resultados, que são combinados para obter a imagem final com as bordas detectadas. O crescimento de regiões é realizado da mesma forma como ocorre no RWSEG (OLIVER e QUEGAN, 2004), ajustando-se discos de diferentes diâmetros dentro das áreas onde nenhuma borda foi detectada. A diferença é que enquanto no RWSEG os discos são ajustados em ordem decrescente de tamanho, no algoritmo desenvolvido a ordem de ajuste é crescente. O agrupamento de regiões é realizado entre duas regiões adjacentes baseado na distância entre suas matrizes de coerências. Os *pixels* pertencentes às bordas são incorporados às regiões por meio da avaliação dos valores das distâncias *pixel*-regiões calculadas pela distância de *Wishart* (FERRO-FAMIL et al., 2001). Cada *pixel* de borda é agrupado à região com menor distância *pixel*-região.

Adotando uma abordagem determinística, Hänsch et al. (2008) desenvolveram e testaram um algoritmo de agrupamento baseado em *Annealing* determinístico proposto por Rose (1998), para obter segmentos a partir de imagens PolSAR do sensor aerotransportado E-SAR. O algoritmo foi desenvolvido tomando por base a medida de distância de *Wishart* desenvolvida por Lee et al. (1994).

Beaulieu e Touzi (2004) apresentam um algoritmo de segmentação hierárquica baseado na otimização passo a passo, usando aproximação por verossimilhança para imagens PolSAR. Neste trabalho o critério de

agrupamento dos segmentos por verossimilhança foi derivado usando a Gaussiana complexa multivariada, a distribuição de *Wishart* e a distribuição *K*, com o intuito de avaliar o desempenho sobre modelos de imagens homogêneas (*cartoon*) e textura (*texture*). O algoritmo foi usado para segmentar imagens PolSAR do sensor aerotransportado Convair-580.

Pellizzeri et al. (2003) comparou duas técnicas de segmentação de imagens PolSAR baseados na abordagem de máxima verossimilhança generalizada e no modelo de distribuição de *Wishart*. A primeira técnica, com o nome de segmentação polarimétrica *annealing* (POLSEGANN), baseia-se numa abordagem de probabilidade global e maximização da técnica de *simulated annealing*, a segunda técnica, denominada *Merge Using Moments* Polarimétrico (POL MUM), baseado no teste de *split-merge* de máxima verossimilhança entre regiões adjacentes e um esquema de crescimento de regiões. Ambas as técnicas exploram as propriedades da matriz de covariância dos dados, mas elas procedem com abordagens muito diferentes para identificar os maiores segmentos homogêneos possíveis. POLSEGANN mostrou ser apropriado para identificação de regiões pequenas e o POL MUM teve melhor performance em grandes regiões homogêneas.

Em Lombardo e Oliver (2002), é discutida uma técnica de segmentação baseada em uma abordagem de máxima verossimilhança generalizada. A função de verossimilhança generalizada de uma área homogênea é derivada, e a função conjunta logarítmica de verossimilhança de uma imagem com N regiões homogêneas é calculada. A função calculada é usada como função objetivo para ser maximizada em uma técnica de maximização.

Skriver et al. (2002) apresentam um algoritmo baseado na abordagem adotada pelo MUM para segmentar dados PolSAR representados pela matriz de covariância. O algoritmo usa o teste de igualdade de matrizes de covariância baseado na distribuição *Wishart* descrito em Conradsen et al. (2003), o qual também foi usado em aplicações de detecção de mudanças de cobertura do

solo. O algoritmo foi testado com imagens do sensor aerotransportado EMISAR e teve seu desempenho avaliado em Skriver et al. (2003).

Bombrun et al. (2011) apresentaram um algoritmo hierárquico de segmentação de imagens PolSAR usando modelos confusão heterogêneos para descrever os dados. O algoritmo é baseado na maximização de log-verossimilhança da função de estimação de Vetores Randômico Esfericamente Invariantes (SIRV), a partir do qual são extraídos o parâmetro escalar da textura e a matriz de covariância normalizada. A estimação do parâmetro de textura é feita por uma distribuição de Fisher, a partir da qual, segundo o desenvolvimento apresentado, leva a uma distribuição KummerU para o vetor de espalhamento. Esta distribuição foi usada na implementação do algoritmo, que foi testado com dados PolSAR simulados e de alta resolução dos sensores aerotransportados E-SAR (Banda L) e RAMSES (Banda X).

Além dos algoritmos de segmentação citados, alguns trabalhos desenvolvidos considerando ferramentas da Teoria da Informação, devem ser mencionados por apresentar resultados promissores e prováveis usos no processamento de imagens PolSAR. Seguindo esta linha, Nascimento et al. (2010) propuseram testes de hipóteses para duas amostras de dados SAR monocanais. Nesse trabalho são derivadas, a partir da distribuição G_0 apresentada por Frery et al. (1997) e Freitas et al. (2005) oito distâncias estocásticas (Kullback-Leiber, Rényi, Hellinger, Bhattacharyya, Jensen-Shannon, Aritmética-geométrica, Triangular e Harmônica-média), as quais foram comparadas e tiveram avaliado o desempenho de seus testes de hipóteses. Os resultados apresentados, de acordo com os autores, permitem esclarecer o tipo de distância mais apropriada para aplicações como, por exemplo, a seleção de atributos, classificação de imagens, detecção de bordas, e identificação de alvos. Dando continuidade no trabalho, Frery et al. (2011) estenderam os resultados obtidos para dados PolSAR, derivando a partir da matriz de covariância complexa cinco novas distâncias estocásticas (Chi-quadrada (χ^2), Kullback-Leiber, Rényi de ordem β , Bhattacharyya e Hellinger), as quais foram aplicadas na detecção de

bordas por Nascimento et al. (2011). Estas pesquisas evidenciam que o uso de distâncias estocásticas deve abrir um caminho promissor para o futuro desenvolvimento de algoritmos de segmentação.

3.2.3. Síntese dos segmentadores para imagens SAR

Após analisar os algoritmos de segmentação apresentados se constata que boa parte dos algoritmos abordados trabalha somente com dados SAR em intensidade ou em amplitude, seja em um único canal ou multicanal, como é o caso do SegSAR, do MUM, do RWSEG dentre outros. Tais algoritmos usam somente dados em amplitude ou intensidade e, portanto, não fazem uso da informação polarimétrica completa que os dados SAR podem fornecer. Pode-se constatar ainda, que os algoritmos que utilizam dados PolSAR são de data mais recente, o que evidencia o direcionamento atual das pesquisas nesta área. Ao se levar em conta que estes dados permitem a obtenção de mais informações a respeito da superfície imageada e que a disponibilidade dos mesmos vem crescendo a cada ano, fica nítida a necessidade de desenvolver pesquisas na área de segmentação para imagens PolSAR.

Verifica-se ainda que o desenvolvimento de algoritmos híbridos para realizar a segmentação de dados SAR ainda é pouco explorada. De todos os trabalhos analisados somente dois adotam esta abordagem, o SegSAR (Sousa Junior, 2005) e o algoritmo desenvolvido por Yang et al. (2008). Cabe ressaltar que dentre estes dois trabalhos somente o último processa dados PolSAR. O desenvolvimento de algoritmos usando esta abordagem permite aliar o que há de melhor em diversas técnicas de processamento de imagens e pode ajudar a contornar diversos problemas encontrados na segmentação de imagens SAR. Dessa forma, pesquisas voltadas para o desenvolvimento de algoritmos híbridos ainda podem contribuir de forma significativa para uma boa segmentação de dados PolSAR.

Outra observação que pode ser apontada da análise dos algoritmos verificados na literatura é a grande quantidade de algoritmos que usam a abordagem

baseada na modelagem estatística dos dados SAR. Os trabalhos analisados mostram que os resultados obtidos com esta abordagem têm apresentado bons resultados, e em vários casos, resultados superiores, quando comparados com os obtidos com as demais abordagens. Isto mostra que o desenvolvimento de algoritmos baseados em modelagens estatísticas adequadas dos dados SAR, embora bem explorada, é uma alternativa que pode trazer resultados promissores para a área de segmentação de imagens polarimétricas.

O desenvolvimento do algoritmo proposto nesta tese se encaixa dentro deste contexto e procura unir as características comentadas acima em um único aplicativo. Sendo assim, a contribuição deste trabalho para o meio científico e tecnológico pode ser resumida na criação e disponibilização de um novo segmentador para dados PolSAR, que incorpora em um único algoritmo diversas técnicas de segmentação e processamento de imagens e se fundamenta na modelagem estatística apropriada para representar os dados. Dessa forma, o algoritmo pode ser classificado como polarimétrico, híbrido e estatístico. Além disso, pode ser considerado multinível, multibandas e hierárquico, conforme será visto no Capítulo 5.

3.3. Avaliação de segmentação de imagens SAR

Conforme apresentado, diversas abordagens que empregam diferentes métodos de segmentação são usadas para imagens SAR. Isto demonstra a importância da segmentação e ilustra a complexidade que envolve este tipo de processamento. De forma similar, existem diversas formas de medir e avaliar o resultado obtido com o uso de um segmentador, conforme pode ser visto em Marpu, et al. (2010), Marçal, et al. (2010), Marçal e Rodrigues (2009), Meinel, et al. (2004), Caves et al. (1998), Zhang (1996), Delves et al. (1992) e Quegan et al. (1988).

Segundo Zhang (1996), os algoritmos de segmentação podem ser avaliados de forma analítica ou empírica. A primeira forma consiste em analisar as

propriedades do algoritmo. A segunda consiste em aplicar o algoritmo em imagens e medir a qualidade, analisando os resultados obtidos. Dentre essas formas a última geralmente é considerada mais satisfatória.

A avaliação empírica pode ser classificada, ainda segundo Zhang (1996), como sendo de qualidade e de discrepância. 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. Por sua vez, os métodos empíricos de discrepância comparam os resultados obtidos pelo algoritmo com uma imagem de referência, sendo as diferenças encontradas (discrepâncias) medidas e avaliadas. A imagem de referência é uma imagem que possui o resultado ideal do processo de segmentação, sendo por este motivo, usada como meio de comparação para determinar as discrepâncias encontradas nas imagens segmentadas.

Os métodos empíricos de discrepância podem ser usados para avaliar algoritmos distintos, já que a análise nestes métodos é feita somente sobre as imagens de referência e as segmentações produzidas. Além disso, estes métodos possuem a capacidade de serem aplicáveis para estudos de diferentes propriedades da segmentação (LUCCA, 1998). Devido a estas características, nesta tese, o método empírico de discrepância baseado nas medidas descritas em Delves et al. (1992) será adotado para avaliar o segmentador proposto PolSeg.

3.3.1. Medidas de avaliação por discrepância

Segundo Delves et al. (1992), o coeficiente de ajuste entre as regiões da segmentação de referência e suas respectivas regiões segmentadas pode ser calculado por critérios de posição, valor médio dos *pixels* da região, que no caso do algoritmo desenvolvido representa valor médio da matriz de covariância, dimensão e forma. Sendo assim, considere R e S as imagens de referência e segmentada, compostas por N_l linhas e N_c colunas, particionadas

respectivamente em J e K regiões. Sejam ainda as regiões de R denotadas por $r_j, j = 1, \dots, J$, assim como as regiões de S por $s_k, k = 1, \dots, K$. O ajuste entre as regiões da imagem de referencia e a imagem segmentada é realizado selecionando para cada região da imagem de referencia uma região da imagem segmentada que melhor a represente. Para isso, são definidas inicialmente, para todos os pares de regiões $(r_j, s_k) j = 1, \dots, J$ e $k = 1, \dots, K$, as seguintes medidas entre regiões:

$$\alpha(r_j, s_k) = \frac{|\mu_x(r_j) - \mu_x(s_k)|}{Nl} \quad (3.1)$$

$$\beta(r_j, s_k) = \frac{|\mu_y(r_j) - \mu_y(s_k)|}{Nc} \quad (3.2)$$

$$\gamma(r_j, s_k) = \frac{|d(r_j) - d(s_k)|}{|d(r_j) + d(s_k)|} \quad (3.3)$$

$$\phi(r_j, s_k) = \frac{|\mu_v(r_j) - \mu_v(s_k)|}{|\mu_v(r_j) + \mu_v(s_k)|} \quad (3.4)$$

onde $d(t)$ é a quantidade de *pixels* de uma dada região t , $\mu_x(t)$ e $\mu_y(t)$ representam, respectivamente, a média das abcissas e a média das ordenadas desta região (centro geométrico), e $\mu_v(t)$ representa a média calculada a partir do valores dos *pixels* da região t .

Sobre estas medidas, são definidas as matrizes:

$$G = (g_{j,k})_{J,K} : g_{j,k} = \frac{d(r_j \cap s_k)}{d(r_j \cup s_k)} \quad (3.5)$$

$$F = (f_{j,k})_{J,K} : f_{j,k} = \frac{\alpha(r_j, s_k) + \beta(r_j, s_k) + 0,5[\gamma(r_j, s_k) + \phi(r_j, s_k)]}{g_{j,k}} \quad (3.6)$$

A matriz G relaciona os pares de regiões com *pixels* comuns, determinados entre a imagem segmentada e de referência. Além disso, 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 um 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 (LUCCA, 1998). Já a matriz F fornece a medida de ajuste entre regiões, considerando o tamanho, posição, forma e valor do nível de cinza das mesmas. Para cada região r_j da imagem de referência R , existe uma região s_k^* em S cujo valor $f_{j,k}$ é mínimo, denominada região ajustada.

Depois de identificadas as regiões ajustadas s , correspondentes a todas as regiões da imagem de referência, a qualidade da segmentação pode ser computada a partir das seguintes medidas de ajuste:

$$M_{val}(r_j, s_j^*) = 1 - \phi(r_j, s_j^*) \quad (3.7)$$

$$M_{pos}(r_j, s_j^*) = 1 - \frac{\alpha(r_j, s_j^*) + \beta(r_j, s_j^*)}{2} \quad (3.8)$$

$$M_{dim}(r_j, s_j^*) = 1 - \gamma(r_j, s_j^*) \quad (3.9)$$

$$M_{for}(r_j, s_j^*) = g_{j,j^*} \quad (3.10)$$

Estas medidas quantificam o ajuste individual de cada região $j(j = 1, \dots, J)$. Para mensurar o ajuste de uma imagem segmentada, é computada, para cada uma das medidas de ajuste, a média aritmética sobre todas as J regiões de modo a obter um valor global para cada medida. Assim, são obtidas as medidas \bar{M}_{val} , \bar{M}_{pos} , \bar{M}_{dim} , e \bar{M}_{for} , que quantificam respectivamente os ajustes de posição, de nível de cinza, de dimensão e de forma das regiões. Estas medidas estão contidas no intervalo $[0;1]$, sendo zero o pior nível de ajuste e um o melhor. É possível ainda definir uma medida geral de ajuste das regiões, computando a média das citadas medidas:

$$M_{geral} = \frac{\bar{M}_{pos} + \bar{M}_{val} + \bar{M}_{dim} + \bar{M}_{for}}{4} \quad (3.11)$$

4 METODOLOGIA

Neste capítulo é apresentada a metodologia de trabalho empregada para obter os resultados descritos nos Capítulos 6 e 7, enfocando os principais aspectos envolvidos na fase de desenvolvimento, segmentação dos dados SAR e as avaliações que foram objetos de estudo deste trabalho.

4.1. Fluxograma de trabalho

Para atingir os resultados de interesse deste trabalho, em concordância com os objetivos propostos no Capítulo 1, foi desenvolvida uma metodologia de trabalho baseada no fluxograma apresentado na Figura 4.1.

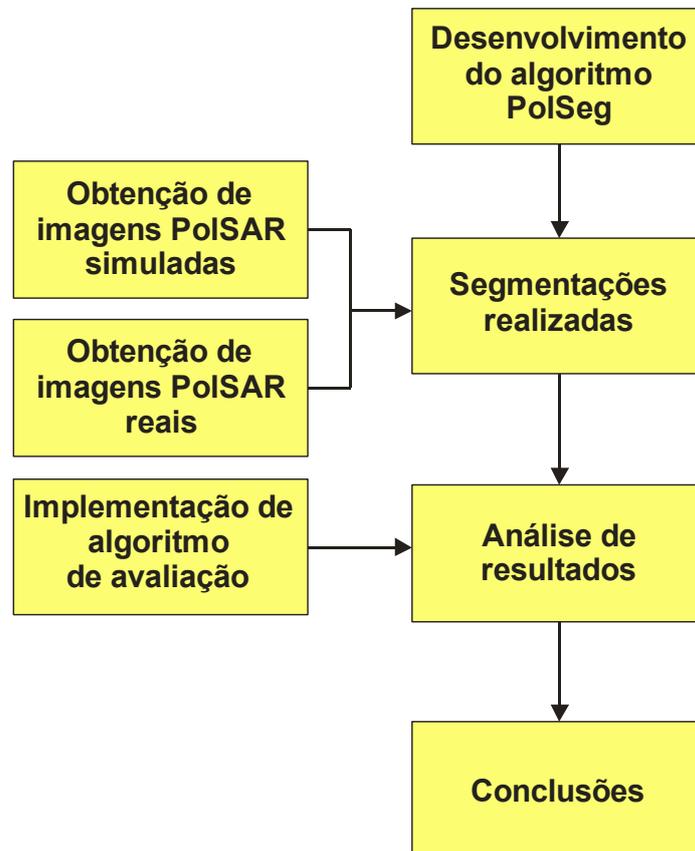


Figura 4.1 - Fluxograma da metodologia de trabalho.

A seguir, é feita uma breve descrição das diferentes fases ilustradas na Figura 4.1 que foram empregadas no desenvolvimento deste trabalho.

4.2. Desenvolvimento do algoritmo PolSeg

A viabilidade de desenvolver um novo algoritmo de segmentação de dados PolSAR, tomando base testes estatísticos apropriados para este tipo de dado, foi verificada após a realização do estudo dos algoritmos pesquisados na literatura e comentados no Capítulo 3. Na concepção do algoritmo foram levados em consideração os conhecimentos abordados no Capítulo 2, relativos à representação matemática dos dados polarimétricos e em intensidade e suas respectivas modelagens estatísticas.

A partir destes conhecimentos foram levantados na literatura os testes estatísticos que poderiam ser empregados para realizar os processos de segmentação por crescimento de regiões, agrupamento de regiões e análise de homogeneidade de regiões. De posse destas informações foi possível, adotando como referência a estrutura de processamento híbrida adotada pelo SegSAR (SOUSA JUNIOR, 2005), implementar os módulos de processamento necessários para realizar a segmentação dos dados PolSAR e polarizados em intensidade.

Dessa forma, foi concebido e implementado um algoritmo, denominado PolSeg, o qual é descrito detalhadamente no Capítulo 5. Este algoritmo usa como parâmetros para realizar a segmentação os parâmetros: nível de compressão máximo desejado, empregado para comprimir a imagem original antes de ser submetida ao processo de segmentação por crescimento de regiões; tipo de conectividade, que define o tipo de conectividade de *pixel* será adota na segmentação; níveis de confiança, a serem adotados para os testes estatísticos realizados nos processos de crescimento e agrupamento de regiões; número máximo de ciclos para o crescimento e agrupamento de regiões, onde o primeiro limita a quantidade de crescimento das regiões no processo de segmentação e o segundo limita a quantidade de agrupamento de regiões durante a execução deste processamento; e, área mínima, usado para definir a dimensão mínima em pixels aceita para as regiões no resultado final da segmentação.

4.3. Obtenção das imagens PolSAR simuladas

O uso de imagens simuladas permite a condução de experimentos controlados, isto é, experimentos cujo comportamento dos alvos é conhecido a priori, além de permitir a realização de avaliações sem a influência das características de uma imagem em particular.

Para a geração do conjunto constituído por 100 imagens simuladas foram criadas as geometrias de 29 regiões em uma imagem com dimensão pré-definida de 240 colunas por 240 linhas. Os dados PolSAR simulados usados para preencher estas regiões foram gerados sob a suposição que a parte real e imaginária de cada componente de um vetor de espalhamento complexo segue uma distribuição gaussiana (GOODMAN, 1963).

A simulação executada teve por objetivo a obtenção das realizações de matrizes de covariância complexas aleatórias que seguem a distribuição de *Wishart*. Para isso, foram simulados dados polarimétricos de *1-look*, representados por um vetor aleatório gaussiano, segundo a abordagem apresentada em Barreto et al. (2013).

O processo de simulação foi usado para produzir imagens contendo seis diferentes classes, as quais tiveram suas matrizes de covariância estimadas a partir de dados PolSAR reais. Os dados usados para este fim foram retirados de uma imagem SAR polarimétrica em *1-look*, constituída por um vetor de espalhamento complexo nas polarizações *hh*, *hv* e *vv*, da região de Paulínea no estado de São Paulo, obtida pelo sensor R99B da Força Aérea Brasileira (FAB), banda L (23,9 cm de comprimento de onda ou 1,27 GHz), em 27 de junho de 2007. A Figura 4.2 apresenta os locais da imagem real a partir dos quais foram retiradas as amostras de seis classes distintas usadas para a simulação dos dados.

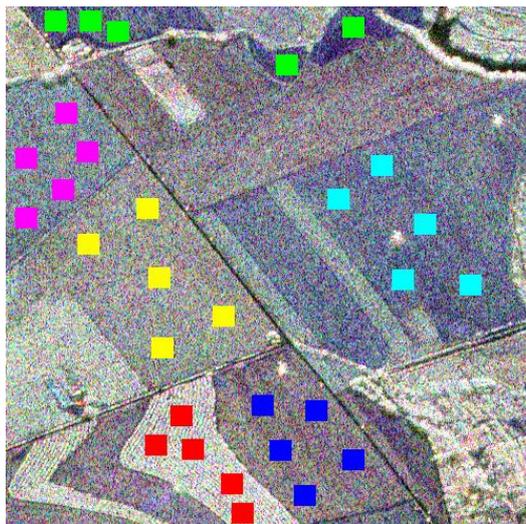


Figura 4.2 - Imagem real em 1-look do sensor R99B usada na geração dos dados PolSAR simulados.

A Tabela 4.1 apresenta os valores reais e imaginários dos elementos da matriz de covariância média calculada a partir das cinco amostras retiradas para cada classe da imagem real em 1-look do sensor R99B. Um exemplo de imagem simulada nestas condições é apresentado na Figura 4.3.

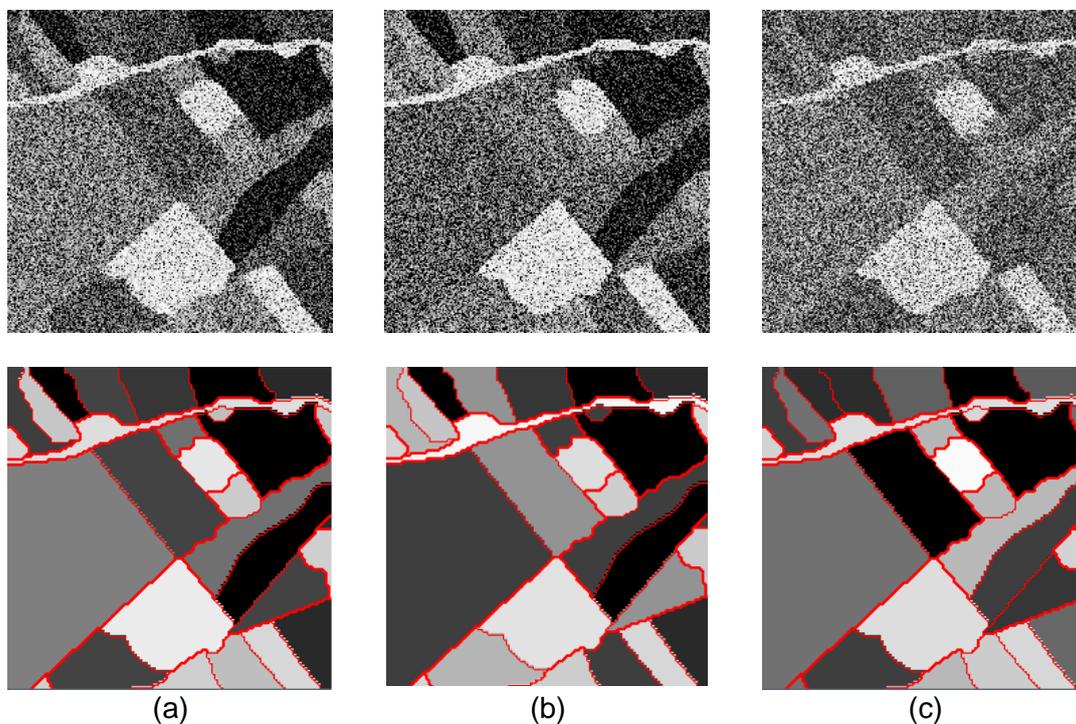


Figura 4.3 - Imagem simulada e imagem de referência, com os contornos e as médias em intensidade das regiões nas polarizações: (a) hh , (b) hv e (c) vv .

Tabela 4.1 - Matrizes de covariância complexas médias calculadas a partir das cinco amostras de cada classe retiradas da imagem do sensor R99B.

Cor	Matriz de covariância complexa média
ciano	$\begin{bmatrix} (0,000761; 0,00000) & (-7,49e-05;-0,000229) & (0,000138; 0,000839) \\ (-7,49e-05; 0,00022) & (0,002485; 0,000000) & (-0,000590;-4,50e-05) \\ (0,000138;-0,00083) & (-0,000590; 4,50e-05) & (0,003227; 0,000000) \end{bmatrix}$
vermelho	$\begin{bmatrix} (0,012859; 0,000000) & (0,001219;-0,00071) & (0,003911; 0,001879) \\ (0,001219; 0,000712) & (0,033695; 0,00000) & (-0,000849;-0,001182) \\ (0,003911;-0,001879) & (-0,00084; 0,00118) & (0,015434; 0,000000) \end{bmatrix}$
amarelo	$\begin{bmatrix} (0,002963; 0,000000) & (0,000486;0,000155) & (0,000341; 0,000143) \\ (0,000486;-0,000155) & (0,008689;0,000000) & (-0,000203;-0,000824) \\ (0,000341;-0,000143) & (-0,000203;0,000824) & (0,004335; 0,000000) \end{bmatrix}$
magenta	$\begin{bmatrix} (0,001405; 0,00000) & (-2,57e-05;-0,00014) & (0,000436; 0,000941) \\ (-2,57e-05; 0,00014) & (0,006056; 0,00000) & (-0,000492;-0,000216) \\ (0,000436;-0,00094) & (-0,000492; 0,00021) & (0,004237; 0,000000) \end{bmatrix}$
verde	$\begin{bmatrix} (0,000489; 0,000000) & (-5,22e-05;-6,27e-05) & (0,000138; 0,000529) \\ (-5,22e-05; 6,27e-05) & (0,001211; 0,000000) & (-0,000330;-8,58e-05) \\ (0,000138;-0,000529) & (-0,000330; 8,58e-05) & (0,002567; 0,000000) \end{bmatrix}$
azul	$\begin{bmatrix} (0,001870; 0,000000) & (8,12e-005;-0,000172) & (0,000126; 0,000608) \\ (8,12e-05; 0,000172) & (0,0032809; 0,000000) & (-0,000301;-0,000167) \\ (0,000126;-0,000608) & (-0,0003016; 0,000167) & (0,002586; 0,000000) \end{bmatrix}$

4.4. Obtenção de imagens PolSAR reais

Para verificar o desempenho do algoritmo desenvolvido para fins de aplicação nas atividades de sensoriamento remoto, foram utilizadas duas imagens polarimétricas processadas em múltiplas visadas (*hh*, *hv* e *vv*) de dois sensores distintos. A primeira imagem foi obtida na missão de imageamento da superfície da Terra realizada em 1994 com o uso do sensor SIR-C/X-SAR, na banda L. A área de estudo abrangida pela imagem está localizada a aproximadamente 40 km à nordeste da cidade de Petrolina, no Estado de Pernambuco e é caracterizada por cultivo agrícola. A Tabela 4.2 apresenta informações sobre a localização da área de estudo e as características básicas da imagem PolSAR SIRC.

Tabela 4.2 - Informações da imagem PolSAR SIR-C e da área de estudo.

Data de aquisição	14/04/1994
Localização da área de estudo	Projeto de Irrigação de Bebedouro, situado na região do Sub-médio São Francisco (09°07' S, 40°18' W), cerca de 40 Km à nordeste do município de Petrolina-PE.
Tamanho da imagem	407x370 pixels
Frequência	Banda L - 1,254 GHz
Polarização	HH, HV e VV
Ângulo de incidência	49,496°
Altitude da plataforma	216,14 Km
Direção da órbita	Descendente
Tipo do produto	<i>Multi-Look</i> Complexo (MLC)
Número de <i>looks</i> nominal	4,7854018
Representação geométrica	<i>Ground range</i>
Espaçamento do pixel	<i>range</i> = 12,5m / <i>azimute</i> = 12,5m

Fonte: Correia (1999).

Na Figura 4.4 é apresentada a composição colorida com as componentes $hh(R)$, $hv(G)$ e $vv(B)$, todas em intensidade, na banda L, da imagem SIR-C/X-SAR da área de estudo.

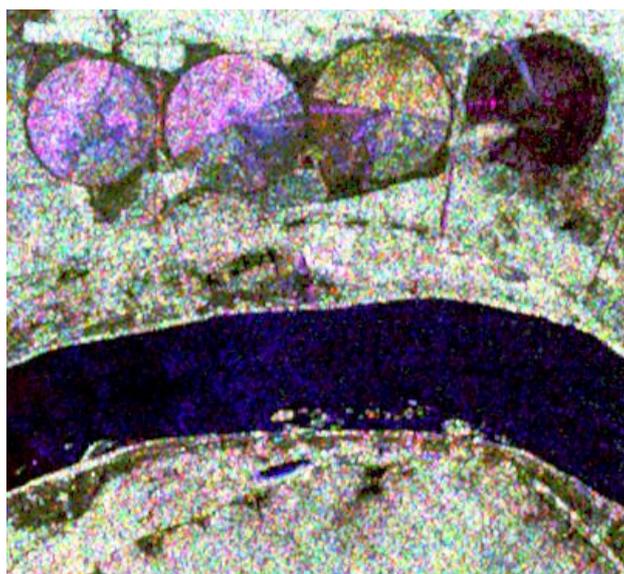


Figura 4.4 - Imagem PolSAR do sensor SIR-C banda L, em intensidade na composição colorida $hh(R)$, $hv(G)$, $vv(B)$.

Além da imagem do sensor SIR-C também foi usado na avaliação do algoritmo os dados reais de uma imagem processada em múltiplas visadas do sensor SAR polarimétrico embarcado na aeronave R99B (SIVAM-CENSIPAM) da Força Aérea Brasileira. Esta corresponde a parte do município de Paulínea, no estado de São Paulo, que foi adquirida em 2007 e também é caracterizada por campos de agricultura (Figura 4.5).

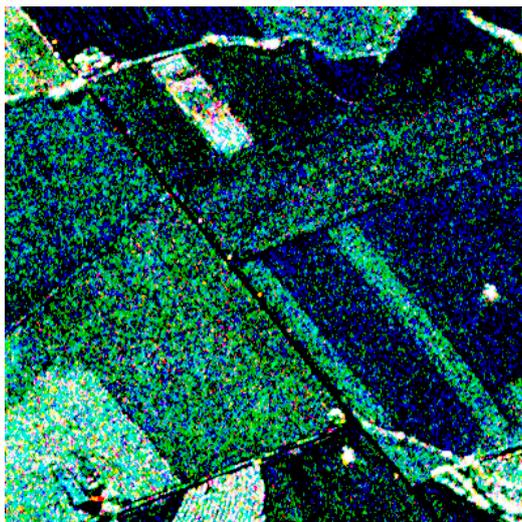


Figura 4.5 - Imagem PolSAR do sensor R99B banda L, em intensidade na composição colorida $hh(R)$, $hv(G)$, $vv(B)$.

4.5. Segmentações realizadas

Os processamentos realizados para obter a segmentação das imagens PolSAR aplicando o PolSeg foram feitos em duas partes. Na primeira parte foram segmentadas as imagens simuladas e na segunda parte as imagens reais do sensor SIR-C e R99B. Adicionalmente, foram executados os processamentos com o SegSAR a fim gerar resultados para realizar uma comparação entre o desempenho obtidos com os dois algoritmos. Os processamentos com dados simulados foram realizadas variando-se dois parâmetros de segmentação encontrados em ambos os algoritmos, a saber níveis de compressão e níveis de confiança para os testes estatísticos, os quais serão vistos com mais detalhes na descrição do PolSeg (Capítulo 5).

4.5.1. Dados PolSAR simulados

Para a avaliação do desempenho da segmentação tomando por base as imagens PolSAR simuladas foram realizadas as segmentações do conjunto das 100 imagens usando uma, três e duas bandas. Estas segmentações foram processadas variando o número de níveis de compressão de dois a sete (total de seis níveis), o nível de confiança de 80% a 99,9% (total de sete níveis) e adotando-se como área mínima 15 *pixels*. Os parâmetros “ciclos de crescimento” e “ciclos de agrupamento”, disponíveis no PolSeg, foram desabilitados de forma a deixar o processamento do algoritmo semelhante ao executado no SegSAR. Além disso, a fim de verificar a potencialidade do algoritmo na definição de bordas, foi habilitado no PolSeg para serem executados no nível de compressão igual a zero o módulo de ajuste de borda.

Inicialmente foram realizadas com o PolSeg as segmentações das imagens simuladas complexas com uma e três bandas. Para esta série de processamento as bandas das imagens simuladas, representadas pelos vetores de espalhamentos complexos, foram carregadas diretamente no algoritmo. Na sequência foram realizadas as segmentações com o SegSAR, também usando uma e três bandas, a fim de obter dados para realizar a análise comparativa dos algoritmos. Os dados em intensidade, necessários para realizar a série de processamento neste algoritmo, foram obtidos a partir da matriz de covariância complexa gerada no PolSeg.

Após a segmentação no PolSeg das imagens PolSAR e a identificação dos parâmetros que geraram os melhores resultados para as medidas de ajuste computadas para a série de segmentação com três bandas, realizou-se nova série de processamento. Nesta série tais parâmetros foram usados para obter a segmentação das imagens polarizadas em intensidade, ou seja, as imagens representadas pelas matrizes de covariâncias supondo a independência dos dados. Estas segmentações foram realizadas para gerar resultados que permitissem investigar o comportamento do PolSeg no processamento de dados PolSAR e dados polarizados em intensidade.

A última série de processamento usando dados PolSAR simulados foi feita combinando duas bandas do vetor de espalhamento complexo. Esta série de processamento foi executada somente no PolSeg e teve por finalidade, gerar resultados que permitissem investigar a combinação de bandas mais adequada para segmentação dos dados PolSAR simulados. Além disso, também teve por finalidade gerar resultados para serem comparados aos obtidos com três bandas da imagem PolSAR, a fim de analisar se o uso de somente duas bandas poderia gerar segmentos similares aos obtidos com três.

A Tabela 4.3 apresenta um quadro resumo dos processamentos realizados com os dados SAR simulados para gerar os resultados usados na análise do desempenho do algoritmo PolSeg e SegSAR.

Tabela 4.3 - Quadro resumo dos processamentos realizados com dados simulados para avaliar quantitativamente e qualitativamente o desempenho do segmentador PolSeg e SegSAR.

Nº de bandas	Polarização	Tipo de dado	Algoritmo usado	Quant. de segmentações
1	<i>hh</i>	em intensidade	PolSeg e SegSAR	8.400
	<i>hv</i>			8.400
	<i>vv</i>			8.400
3	<i>hh-hv-vv</i>	em intensidade	SegSAR	4.200
		complexo	PolSeg	4.200
		em intensidade		100
2	<i>hh-hv</i>	complexo	PolSeg	4.200
	<i>hh-vv</i>			4.200
	<i>hv-vv</i>			4.200

4.5.2. Dados PolSAR reais

Para a avaliação do desempenho da segmentação tomando por base os dados PolSAR reais foram realizadas segmentações usando a matriz de covariância com as três polarizações (*hh-hv-vv*) da imagem do sensor SIR-C e R99B. Os parâmetros de segmentação adotados para ambos os algoritmos foram aqueles que resultaram nos melhores valores de medida de ajuste para as imagens simuladas. Além disso, foi adotado para o SegSAR o valor igual a 0,8 *dB* para o parâmetro similaridade. Cabe citar ainda, que os parâmetros “ciclos

de crescimento” e “ciclos de agrupamento” de regiões encontrados no PolSeg permaneceram desabilitados no PolSeg para tornar o processamento deste algoritmo semelhante ao executado no SegSAR.

Em um primeiro momento foram realizadas com o PolSeg as segmentações da matriz de covariância complexa e da matriz de covariância diagonal a fim de obter dados para realizar a análise comparativa dos resultados obtidos com esse algoritmo. Em um segundo momento foi realizado a segmentação dos dados em intensidade no SegSAR, a partir do qual foram gerados os dados para analisar o desempenho entre os dois segmentadores.

Também foram registrados para cada segmentação realizada, para uma dada configuração de parâmetros, o tempo e o número de regiões geradas, a partir dos quais foram realizadas as análises de desempenho. Tem-se ainda para fim de estimativa de tempo que as segmentações foram realizadas em um computador com processador Intel Core i3 de velocidade de 2,4 GHz e 4,0Gb de memória RAM.

4.6. Implementação de algoritmo de avaliação

Para avaliar quantitativamente o desempenho do algoritmo foi implementado em linguagem IDL (*Interactive Data Language*) o algoritmo para computar as medidas de ajuste entre regiões desenvolvidas por Delves et al. (1992) e apresentadas no Capítulo 3. Este algoritmo foi usado para extrair, dos resultados obtidos na segmentação dos dados SAR simulados e da imagem de referência, as informações necessárias para computar os valores das medidas de ajuste para cada segmentação realizada.

4.7. Análise de resultados

Os resultados obtidos nas segmentações dos dados SAR simulados e reais são analisados respectivamente nos Capítulos 6 e 7.

Para cada segmentação realizada foram computadas as médias (sobre o conjunto de regiões da imagem de referência) das medidas de ajuste de

posição (\bar{M}_{pos}), de ajuste de intensidade (\bar{M}_{val}), de ajuste de dimensão (\bar{M}_{dim}), de ajuste de forma (\bar{M}_{for}) e de ajuste geral (M_{geral}). Além disso, após a execução das 100 segmentações, para uma dada configuração de parâmetros, foram computadas a média e o desvio padrão de cada medida, denotadas por $\bar{\bar{M}}_{pos}$, $\bar{\bar{M}}_{val}$, $\bar{\bar{M}}_{dim}$, $\bar{\bar{M}}_{for}$, e $\bar{\bar{M}}_{geral}$, respectivamente. O número médio de regiões e o tempo médio de processamento também foram utilizados na análise. Estas estatísticas foram utilizadas para identificar os valores dos parâmetros que proporcionaram o melhor resultado de segmentação para cada um dos algoritmos analisados. Por fim, estes melhores resultados foram comparados para se determinar se havia diferença significativa entre eles.

Os primeiros resultados analisados foram os obtidos na segmentação com os dados simulados univariados em intensidade. Nesta atividade foi investigado, para o PolSeg e o SegSAR, como os parâmetros de segmentação influenciaram nos resultados das segmentações e quais combinações de parâmetros geraram os melhores resultados. Adicionalmente, foi realizada uma análise comparativa dos resultados obtidos com os dois algoritmos a fim de investigar se a modelagem estatística adotada para o PolSeg para segmentar dados univariados em intensidade é superior a modelagem adotada pelo SegSAR.

A mesma abordagem foi adotada para realizar a análise dos resultados obtidos na segmentação realizada com o PolSeg das imagens simuladas com três bandas, a qual é complementada com a comparação da segmentação da matriz de covariância diagonal, que supõe independência estatística entre os dados da matriz. Esta comparação foi feita para verificar se a modelagem adotada para o PolSeg, apesar de supor independência, é melhor que a adotada para o SegSAR.

Para a segmentação realizada com duas bandas foi verificado inicialmente os parâmetros que geraram os melhores resultados e a combinação de polarização que apresentou melhor a segmentação. Além disso, foram analisados os resultados com o uso de três e de duas bandas a fim de

investigar se o uso de somente duas bandas já seria suficiente para obter valores similares aos obtidos com três polarizações.

5 O ALGORITMO POLSEG

Neste capítulo descreve-se o algoritmo de segmentação desenvolvido para extrair informações a partir de dados PolSAR. Este algoritmo, denominado PolSeg, foi desenvolvido tomando-se como base: o modelo multiplicativo, usado para modelar o comportamento estatístico dos dados SAR; o modelo *cartoon*, apropriado para regiões homogêneas, e utilizado para representar o *backsacater* médio das regiões contidas nas imagens; e, a matriz de covariância complexa, usada para representar os dados polarimétricos capturados pelo sensor. Para tanto, duas suposições foram feitas: a primeira é que os alvos contidos na imagem SAR polarimétrica são homogêneos; e, a segunda é que a matriz de covariância da imagem SAR polarimétrica possui uma distribuição *Gama* ($\Gamma(L, \beta)$), quando a ordem da matriz é igual a um, ou uma distribuição *Wishart* complexa escalonada ($W_E(L, \Sigma)$), quando a ordem da matriz é superior aquele valor.

No que diz respeito ao processamento dos dados, o PolSeg segue uma abordagem conceitual similar a usada pelo SegSAR (SOUSA JUNIOR, 2005). Dessa forma, o algoritmo pode ser classificado como híbrido, pois usa diversas técnicas de processamento de imagens para realizar a segmentação. Além disso, também é multinível e hierárquico, pois trabalha com imagens comprimidas em níveis segundo o critério hierárquico de pirâmides. Finalmente, quanto ao número de canais usado no processamento o algoritmo pode ser classificado como multicanais, pois permite processar diversos canais simultaneamente para obter a segmentação. A seguir será apresentado como o algoritmo foi concebido, seu desenvolvimento e funcionamento.

5.1. Concepção

Conforme já mencionado, o PolSeg foi originalmente concebido para processar dados PolSAR processados em *1-look* ou múltiplas visadas. Para isso, os dados são representados na forma de matriz de covariância, independentemente da quantidade de canais que se deseja segmentar (dados multicanais ou dado monocanal). Nestas duas situações, a única diferença

para o processamento dos dados, reside no teste estatístico usado para realizar a segmentação. Para dados contidos em mais de um canal é usado o teste de igualdade de matrizes de covariância. Neste caso supõe-se que a variável aleatória usada para representar os dados possui distribuições *Wishart* complexa escalonada ($W_E(L, \Sigma)$), conforme apresentado na Seção 2.2.3. Já para dados em um único canal é usado o teste de igualdade de médias de intensidade. Nesta opção, supõe-se que os dados em intensidade, contidos no canal representados pela matriz de covariância de ordem unitária, possui uma distribuição $\Gamma(L, \beta)$, conforme visto na Seção 2.2.4.

Após analisar os algoritmos apresentados no Capítulo 3, adotou-se para o PolSeg o uso da característica de similaridade encontrada nas imagens para definição dos segmentos, e a modelagem estatística do *speckle* e do *backscatter* via modelo multiplicativo. Decorrente desta decisão adotou-se a técnica de segmentação por crescimento de regiões como ferramenta principal para a obtenção dos segmentos. Esta decisão foi tomada devido ao fato desta técnica adequar-se bem ao modelo *cartoon* e pelo fato de não exigir a suavização previa da imagem por meio de filtros, como ocorre com a maioria das técnicas de detecção de bordas. Outro fator preponderante que influenciou nesta decisão foi o fato do crescimento de regiões já ter sido aplicado com bons resultados em algoritmos usados na extração de informações a partir de dados SAR, tais como o MUM (OLIVER e QUEGAN, 2004), a versão do MUM adaptada para dados polarimétricos (SKRIVER et. al, 2002) e o SegSAR (SOUSA JUNIOR, 2005), dentre outros.

Com relação à estrutura de processamento para obter a segmentação final, optou-se pela concepção de um algoritmo híbrido, conceitualmente semelhante ao SegSAR. Este integra a técnica de crescimento de regiões às técnicas de agrupamento de regiões, ajuste de bordas, análise de homogeneidade de regiões e divisão de regiões não homogêneas. Decorrente também desta decisão, adotou-se para o algoritmo o uso de compressão seguindo o critério hierárquico de pirâmide (JAIN et al., 1995).

Cabe ressaltar que, embora adotada uma estrutura de processamento similar ao SegSAR, em essência o algoritmo concebido é completamente diferente daquele, uma vez que os tipos de dados processados pelos dois algoritmos possuem características estatísticas e físicas distintas, o que permite a extração de diferentes informações a partir das imagens SAR. Dessa forma, é possível diferenciar os dois algoritmos com relação aos seguintes aspectos:

- a) Tipo de dado processado - com relação ao tipo de dado processado, tem-se que enquanto o PolSeg, processa dados PolSAR representados pela matriz de covariância complexa, o SegSAR processa somente dados no formato de intensidade ou dados transformados para este formato. Isto significa, em termos de quantidade de informações, que o SegSAR usa somente uma parte da informação polarimétrica disponibilizada pelos sensores SAR, que é a formada pelos dados da diagonal principal da matriz de covariância. Este fato faz com que as informações de fase contidas nos dados complexos, as quais podem ajudar na identificação de diferentes mecanismos elementares de espalhamentos contidos nos alvos da superfície terrestre, sejam desprezadas no processamento;
- b) Modelagem dos dados e testes estatísticos - outro aspecto que diferencia os dois algoritmos é a modelagem estatística adotada para representar os dados e o seu uso na fundamentação da teoria dos testes de crescimento de regiões, agrupamento de regiões e ajuste de bordas. Enquanto o SegSAR modela os dados e usa testes estatísticos baseados na distribuição *Gama* ($\Gamma(L, L)$) e Gaussiana, o algoritmo concebido modela os dados e usa, dependendo da ordem da matriz de covariância, os testes baseados na distribuição *Gama* ($\Gamma(L, \beta)$) para dados monocanal e na distribuição *Wishart* complexa escalonada ($W_E(L, \Sigma)$) para dados multicanais;
- c) Aplicação dos testes estatísticos - os dois algoritmos aplicam os testes estatísticos sobre os dados de forma distinta. O PolSeg aplica os testes

sobre os dados representados pela variável aleatória, que reúne em um único elemento a representação de todas as informações polarimétricas, para a formação das regiões. Já o SegSAR, aplica os testes sobre os dados em formato de intensidade individualmente para cada canal antes de decidir se uma região será formada ou não;

- d) Parâmetros de segmentação - além das características já mencionadas, existem diferenças significativas com relação às opções de parâmetros de segmentação nos dois algoritmos. Estas diferenças por si só bastariam para diferenciá-los, já que o resultado da segmentação está fortemente relacionado aos valores adotados para cada parâmetro. O SegSAR foi desenvolvido para trabalhar com quatro parâmetros de segmentação, os quais são: nível de compressão, nível de confiança para os testes estatísticos, valor de similaridade (expresso em *dB*) e área mínima. O PolSeg, por sua vez, foi concebido de modo a possuir uma maior flexibilidade de uso de parâmetros, a fim de disponibilizar ao usuário mais opções para o processo de segmentação. Sendo assim, o algoritmo foi desenvolvido de forma a permitir o uso de níveis de significância diferentes para os módulos de crescimento e agrupamento de regiões. Além disso, também foi incorporado ao algoritmo como parâmetros os conceitos de ciclos de crescimento de regiões e de agrupamento de regiões;
- e) Interatividade com o usuário - com relação à interatividade com o usuário os dois algoritmos também são bem distintos. No PolSeg é disponibilizada a opção de visualizar os resultados intermediários da segmentação a cada descompressão. Caso esta opção seja selecionada, uma interface gráfica é acionada a cada descompressão, a qual permite a visualização de resultados parciais da segmentação, a análise de informações a respeito do processamento e a alteração de parâmetros de processamento. Por sua vez, o SegSAR apresenta a cada nível de descompressão somente a visualização do resultado da segmentação em janelas com informações estáticas; e,

- f) Ambiente de desenvolvimento e execução - o PolSeg foi desenvolvido unicamente em ambiente IDL e para ser executado necessita que somente este ambiente esteja disponível, para que seu código seja compilado. Já o SegSAR foi desenvolvido em ambiente híbrido IDL/ENVI e para ser executado necessita que ambos os ambientes estejam disponíveis.

A Tabela 5.1 apresenta um resumo das principais diferenças encontradas entre os algoritmos PolSeg e SegSAR.

Tabela 5.1 - Principais diferenças entre os algoritmos PolSeg e SegSAR.

Aspecto	PolSeg	SegSAR
Tipo de dado processado	Polarimétrico e polarizado em intensidade	Polarizado em intensidade
Modelagem estatística (distribuições)	Wishart complexa escalonada e Gama	Gaussiana e Gama
Aplicação dos testes estatísticos	Sobre os dados da matriz de covariância	Sobre cada canal em intensidade da imagem SAR
Parâmetros de segmentação	7 parâmetros: tipo de conectividade para o <i>pixel</i> (quatro ou oito), nível de compressão, nível de confiança (crescimento e agrupamento de regiões), ciclos (crescimento de e agrupamentos de regiões), área mínima.	4 parâmetros: nível de compressão, nível de confiança, similaridade, área mínima.
Interatividade com usuário	Visualização de resultados intermediários em janela com barra de rodagens, alteração de parâmetros e interrupção antes do término do processamento.	Visualização de resultados intermediários em janelas estáticas.
Ambiente de execução	IDL	IDL + ENVI
Saída de dados	Imagens: Id, intensidade média; Relatórios.	Imagens: Id, intensidade média, regiões com contornos.

Cabe ressaltar aqui que embora o algoritmo PolSeg tenha sido desenvolvido originalmente para processar dados polarimétricos representados pela matriz de covariância, ele também pode ser usado para processar dados polarizados multivariados em intensidade. Isto é feito, usando-se o artifício de formar matrizes de covariância diagonais antes do processamento, o que implica em supor que os elementos da diagonal principal da matriz não possuem correlação estatística. Esta característica confere ao algoritmo uma funcionalidade extra que permite ampliar seu uso nas aplicações de segmentação de dados SAR.

5.2. Desenvolvimento e funcionamento

O PolSeg foi implementado em linguagem IDL (*Interactive Data Language*) de propriedade da empresa Exelis Visual Information Solutions. O IDL é uma linguagem de programação amplamente usada na análise de grande quantidade de dados, tal como ocorre no processamento de imagens. Sua escolha foi feita devido a esta característica e ao fato desta linguagem ser usada no INPE no desenvolvimento de diversos algoritmos destinados a pesquisa na área de classificação, segmentação e tratamento de imagens.

A segmentação realizada pelo PolSeg é o resultado do processamento dos dados realizados pela estrutura modular de processamento ilustrada na Figura 5.1. Esta estrutura está dividida em três etapas, as quais estão subdivididas em módulos de processamento específicos. A adoção de módulos de processamento dentro das etapas foi adotada para permitir uma maior versatilidade na composição da sequência de processamento. Dentro desta estrutura estão embutidos cinco testes distintos: teste para crescimento de regiões, teste de ajuste de bordas, teste de homogeneidade de regiões, teste de agrupamento de regiões e teste de área mínima. O acionamento dos módulos responsáveis pela aplicação destes testes dentro de uma sequência pré-estabelecida para o algoritmo é que realiza a segmentação da imagem SAR. Uma descrição mais detalhada desta estrutura de processamento e seu funcionamento são feitos a seguir.

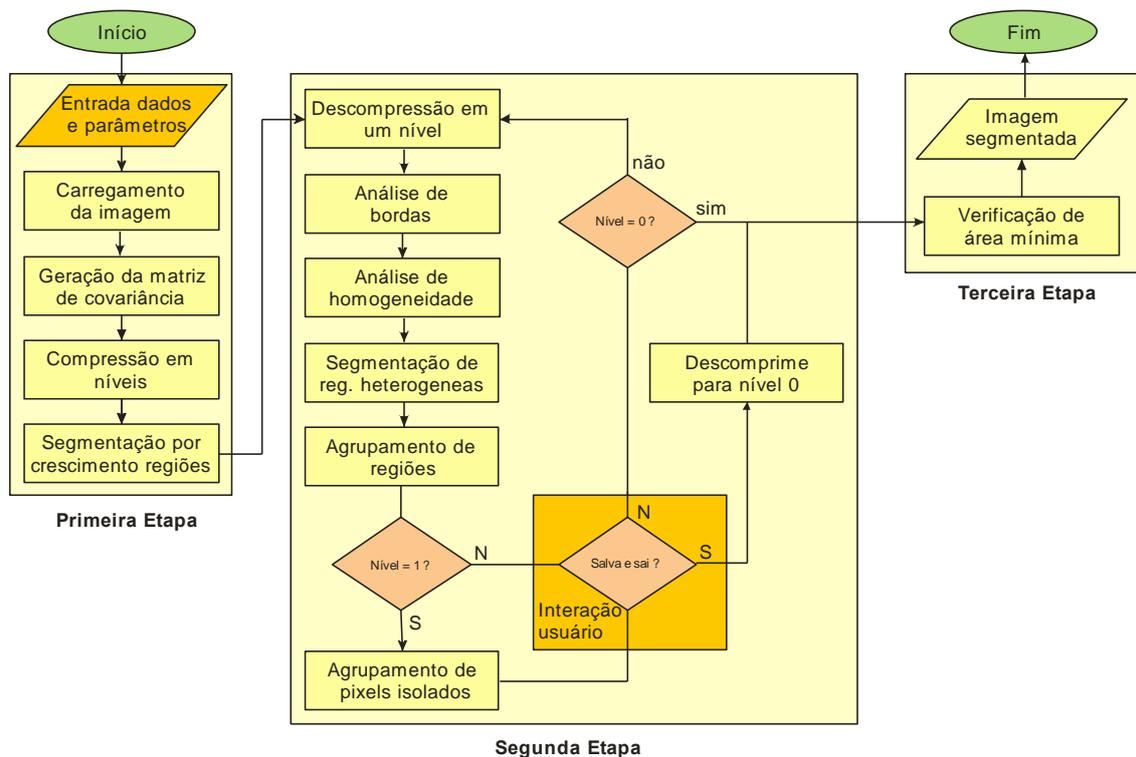


Figura 5.1 - Estrutura de processamento do PoISeg.

5.2.1. Primeira etapa de processamento

A primeira etapa é constituída da seqüência de cinco módulos de processamento: entrada de dados, carregamento da imagem, geração da matriz de covariância, compressão em níveis e segmentação por crescimento de regiões. Ao término do processamento são obtidos os dados de segmentação no nível de compressão selecionado pelo usuário, os quais são encaminhados para a segunda etapa. A seguir é apresentada uma descrição mais detalhada dos módulos de processamento envolvidos na obtenção destes dados.

5.2.1.1. Entrada de dados e parâmetros

A entrada de dados e parâmetros do algoritmo é realizada via interface gráfica criada para esta finalidade, a qual também é responsável pelo acionamento do

início do processamento (Figura 5.2), a qual tem seu funcionamento descrito detalhadamente no Anexo B.

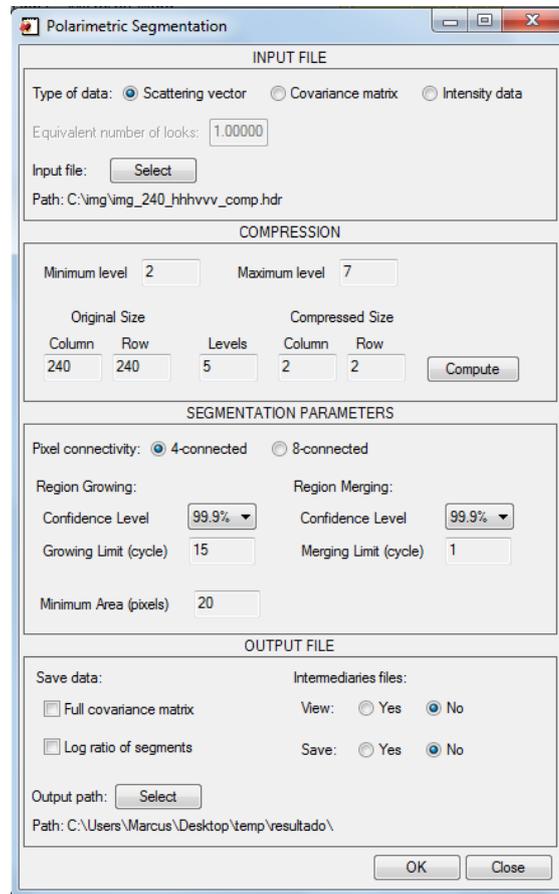


Figura 5.2 - Interface de entrada de dados e parâmetros do PolSeg.

Nesta interface é realizada a entrada de informações referentes ao tipo de dado que se pretende segmentar e ao seu número de *looks*, bem como, é realizado o carregamento dos dados via seleção do arquivo digital usado para armazená-los.

5.2.1.1.1. Dados de Entrada

O algoritmo foi desenvolvido para trabalhar basicamente com um dos três tipos de dados de entrada: vetor de espalhamento (*Scattering vector*); matriz de covariância (*Covariance matrix*); e, dados polarizados multivariados em intensidade (*Intensity data*).

Para o processamento de imagem PolSAR, formada pela matriz de covariância complexa, e imagens polarizadas multivariadas em intensidade, deve ser informado o número equivalente de *looks* (nel_0). Caso a imagem seja constituída por um vetor de espalhamento complexo o algoritmo assume como nel_0 um valor igual a um (dados 1-look). Cabe mencionar que o algoritmo não foi desenvolvido para gerar imagens em múltiplas visadas a partir de dados de 1-look.

Tomando por base o número de canais da imagem de entrada e o seu respectivo número equivalente de *looks*, o algoritmo obtém o nível de compressão mínimo (nl_{min}). O valor deste parâmetro é usado pelo algoritmo para processar dados representados por matrizes de covariância com ordem maior que um e tem a finalidade de impedir o uso de níveis de compressão que ocasionem problemas numéricos impostos pelo teste estatístico de igualdade de matrizes de covariância conforme comentado na Seção 2.3.2.

O nível de compressão máximo (nl_{max}) da imagem de entrada, por sua vez, é calculado tomando por base as informações de número de colunas e de linhas, sendo obtido por meio da relação dada por (ROSENFELD, 1984)

$$nl_{max} = \log_2 dim_{min} \quad (5.1)$$

onde dim_{min} corresponde a menor dimensão em número de colunas ou linhas da imagem de entrada. O valor calculado é apresentado na caixa de texto, posicionada a direita do campo denominado *maximum level* e não pode ser editado pelo usuário. Foi estabelecido que o número máximo de compressão ficaria limitado a oito níveis nas situações onde as dimensões da imagem permitissem níveis maiores. Este limite foi adotado para evitar compressões muito altas e consequente número equivalente de *looks* elevado para a imagem comprimida, uma vez que este parâmetro aumenta com o aumento do nível de compressão.

5.2.1.1.2. Parâmetros de processamento

Para o processamento da imagem no PolSeg o valor do parâmetro *Levels*, que é o nível de compressão (*C*) fornecido pelo usuário, deve estar contido no intervalo limitado pelo nvl_{min} e nvl_{max} , incluindo estes valores.

O primeiro parâmetro de segmentação que deve ser informado é o *Pixel connectivity*, o qual define o número de vizinhos de um *pixel* que serão utilizados nos testes para o crescimento de regiões. As opções de conectividade que podem ser adotadas pelo PolSeg são quatro ou oito.

Os parâmetros que definem o processo de crescimento de regiões (*Region Growing*) são o *Confidence Level* e o *Growing Limit (cycle)*. O primeiro diz respeito ao nível de confiança a ser adotado para a execução do teste estatístico (Capítulo 2), o qual pode assumir os valores de 99,9%, 99,5%, 99,0%, 95,0%, 90,0%, 85,0%, 80,0%. O segundo parâmetro define o número máximo de ciclos de crescimento do processo de crescimento de regiões. Este último parâmetro foi inserido no algoritmo para evitar que regiões muito grandes sejam formadas. O processo de crescimento de regiões é interrompido quando for atingido este número máximo de ciclos de crescimento, ou quando o teste estatístico indicar que os pixels adjacentes a região não pertencem a ela.

Da mesma forma que no crescimento de regiões, o *Region Merging* usa dois parâmetros para realizar o processo de agrupamento de regiões, o *Confidence Level* e o *Merging Limit (cycle)*. As finalidades destes dois parâmetros para o processo de agrupamento de regiões são as mesmas das descritas para o crescimento de regiões.

O último parâmetro de segmentação é o *Minimum Area (pixels)*, que diz respeito à dimensão mínima permitida, em termos de quantidade de *pixels*, para a definição do tamanho das regiões.

5.2.1.1.3. Opções de saída

O algoritmo permite que sejam geradas duas saídas de dados adicionais ao fim do processamento (*Save data*): a imagem da matriz de covariância com todos os elementos (*Full covariance matrix*); e a imagem com os valores dos logaritmos da razão entre a intensidade de cada pixel e a intensidade média do segmento ao qual o pixel pertence (*Log ratio of segments*). A primeira opção foi inserida no algoritmo para permitir o armazenamento em disco rígido dos elementos da matriz de covariância gerada no processamento. Já a segunda opção foi introduzida para que se possa ter uma imagem que permita verificar ao final do processamento a qualidade da segmentação obtida, uma vez que sob a suposição de homogeneidade dos segmentos, esta razão assume valores próximos a zero (SKRYVER et al. 2003).

Caso haja o interesse de acompanhar os resultados do processamento o usuário pode visualizar como saída os arquivos de dados intermediários (*Intermediary files*) via interface gráfica. Esta interface gráfica é abordada com detalhes no Anexo B.

5.2.1.2. Carregamento da imagem

Neste módulo a imagem é carregada e tem suas dimensões ajustadas, conforme o nível de compressão selecionado, para ser submetida ao processo de segmentação.

Para realizar o carregamento da imagem o PolSeg inicialmente gera uma matriz preenchida com zeros, com as mesmas dimensões (coluna, linha, bandas) e tipo de dado da imagem de entrada (tipo complexo). Cabe ressaltar que o algoritmo foi programado para aceitar somente dados complexos. As informações para dimensionamento desta matriz são obtidas a partir do arquivo .hdr (arquivo formato ENVI). Em seguida os dados da imagem são lidos e copiados para matriz gerada. Esta matriz é então, caso seja necessário, submetida a um redimensionamento em termos de colunas e linhas, a fim de ajustar sua dimensão para poder ser submetida ao processo de compressão

seguindo o critério de pirâmides hierárquicas (JAIN et al., 1995). O processo de compressão será visto com mais detalhes na descrição do módulo compressão em níveis.

Para realizar o ajuste na dimensão da matriz é calculado o número de linhas e colunas que a imagem de entrada deveria ter para ser comprimida no nível de compressão selecionado pelo usuário. Para isso, o algoritmo calcula o fator de compressão relativo ao nível de compressão considerado usando a expressão

$$fc_C = 2^C, \quad (5.2)$$

onde, c é o nível de compressão selecionado pelo usuário. Na sequência, são calculados os valores do número de colunas e do número de linhas ajustados por meio das expressões

$$col_{ajust} = col_C \cdot fc_C \quad (5.3)$$

$$lin_{ajust} = lin_C \cdot fc_C \quad (5.4)$$

onde, col_C e lin_C são respectivamente o número de colunas e linhas no nível da imagem no nível de compressão C obtidos respectivamente pelas expressões

$$col_C = \left\lceil \frac{col_{orig}}{fc_C} \right\rceil \quad (5.5)$$

$$lin_C = \left\lceil \frac{lin_{orig}}{fc_C} \right\rceil \quad (5.6)$$

onde col_{orig} e lin_{orig} são respectivamente o número de colunas e linhas da imagem de entrada e $\lceil . \rceil$ denota arredondamento para cima (valor inteiro).

A Tabela 5.2 ilustra um exemplo de ajuste nas dimensões de colunas e linhas de uma imagem com dimensão original de 141 colunas e 257 linhas em diversos níveis de compressão. No exemplo apresentado, caso seja selecionado o nível de compressão igual a cinco a imagem original deve ser acrescida de 19 colunas e 31 linhas para atender o critério de compressão por pirâmides hierárquicas.

Tabela 5.2 - Exemplo ajustamento de dimensões de número de colunas e linhas conforme o nível selecionado para compressão, para atender o critério de compressão por pirâmides hierárquicas.

Parâmetros calculados	C								
	0	1	2	3	4	5	6	7	8
fc_C	1	2	4	8	16	32	64	128	256
col_C	141	71	36	18	9	5	3	2	1
lin_C	257	129	65	33	17	9	5	3	2
col_{ajust}	141	142	144	144	144	160	192	256	256
lin_{ajust}	257	258	260	264	272	288	320	384	512

O ajustamento das dimensões se faz necessário porque a matriz que representa a imagem de entrada pode ter dimensões que não estejam de acordo com o nível de compressão adotado ou ainda possuir números ímpar de colunas e/ou de linhas. Quando ocorre uma ou ambas as situações citadas, o algoritmo cria tomando por base os valores de colunas e/ou linhas ajustadas uma matriz preenchida com zeros.

Os elementos da matriz gerada são substituídos pelos valores dos dados da matriz formada pela imagem de entrada, a qual é posicionada de forma que o *pixel* do canto superior esquerdo de ambas as matrizes sejam coincidentes. Os valores de zero contido na matriz gerada, após esta ter recebido os dados da matriz da imagem original, correspondem às linhas e colunas que foram inseridas a mais no processo de geração da matriz. Estes espaços são preenchidos primeiro, replicando em cada coluna de zeros a última coluna de dados da matriz da imagem original e segundo, replicando em cada linha de zeros a última linha de dados da matriz (incluindo os dados da última coluna que porventura tenha sido replicada).

5.2.1.3. Geração da matriz de covariância

A matriz de covariância pode ser gerada a partir do vetor de espalhamento complexo, ou montada a partir dos elementos de sua diagonal principal e

superiores a diagonal ou ainda a partir dos elementos de sua diagonal principal.

Quando a entrada dos dados for um vetor de espalhamento o algoritmo calcula a matriz usando os elementos deste vetor. A matriz de covariância é gerada então por meio da multiplicação do vetor de espalhamento pelo seu complexo conjugado conforme a Equação (2.3). Por sua vez, quando os dados de entrada são elementos já existentes da matriz de covariância o algoritmo apenas organiza estes dados a fim de usá-los durante o processamento. Para o último caso, quando os dados são somente os elementos da diagonal principal da matriz de covariância a matriz formada será uma matriz diagonal. Esta funcionalidade foi inserida no algoritmo para possibilitar o processamento de dados polarizados multivariados em intensidade.

Em todas as situações o algoritmo armazena em memória somente os elementos da diagonal principal da matriz de covariância e os elementos da matriz triangular superior. Isto é feito para não sobrecarregar o uso da memória RAM. Além disso, a fim de disponibilizar memória RAM para processamento, o PolSeg grava os dados da matriz de covariância em disco rígido liberando a memória alocada à variável usada pelo algoritmo para armazenar os dados.

Após a geração da matriz de covariância é realizada a estimação da autocorrelação espacial dos *pixels* das imagens em intensidade com dimensões originais. Analogamente ao SegSAR, as correlações de *lags* (0,1), (1,0) e (0,1) são utilizadas para estimar, a cada nível de compressão, o número equivalente de *looks*, conforme será visto a seguir na descrição do módulo compressão em níveis.

5.2.1.4. Compressão em níveis

Este módulo realiza a compressão da matriz de covariância seguindo o critério hierárquico de pirâmide para o nível de compressão selecionado pelo usuário (C).

Nesse processamento, cada nível de compressão é representado por uma imagem de médias que possui a metade do número de colunas e linhas da imagem anterior. Sendo assim, o valor do *pixel* contido em uma imagem em um nível superior c , onde $c = \{1, 2, \dots, C\}$, é o resultado da média simples de quatro *pixels* da imagem do nível anterior ($c - 1$). O nível zero é o nível da imagem sem compressões e é definida como a base da pirâmide. A imagem comprimida em um nível ($c \geq 1$) se posiciona logo acima da base, sendo esta sequência repetida até o topo da pirâmide obtendo-se os demais níveis de compressão. Portanto, cada *pixel* de uma imagem comprimida no nível $c \geq 1$ é o resultado da média de $f c_c^2$ *pixels* da imagem do nível zero. A Figura 5.3 ilustra o processo de compressão de imagem por pirâmides hierárquicas, apresentando o exemplo de uma imagem com dimensões 16x16 submetida a três compressões.

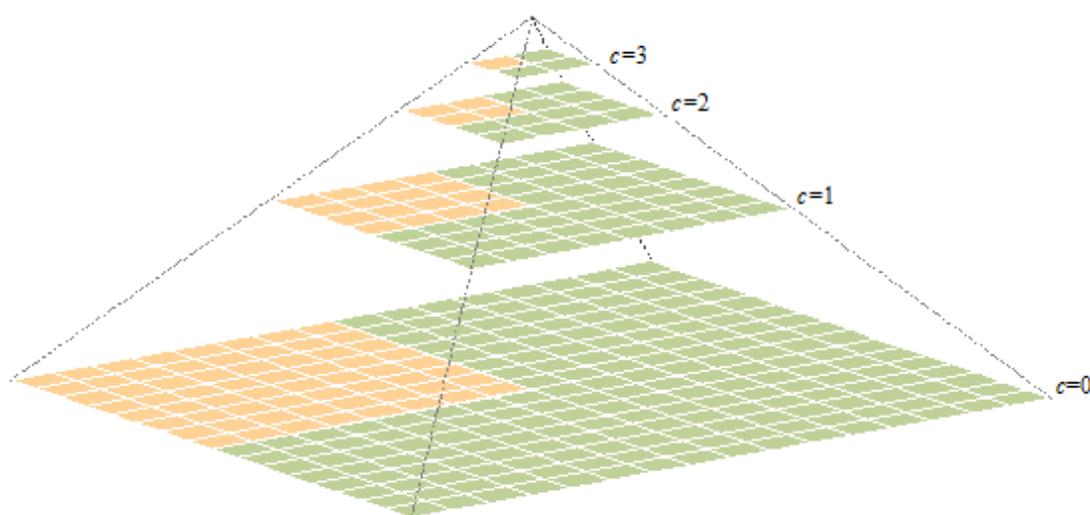


Figura 5.3 - Processo de compressão de uma imagem usando o critério de pirâmides hierárquicas até o nível de compressão igual a três de uma imagem com dimensão em linha e coluna de 16 *pixels*.
Fonte: adaptado de Sousa Junior (2005).

Além da aplicação na compressão em níveis, o fator de compressão $f c_c$ também é usado na obtenção do número equivalente de *looks* da imagem a cada nível de compressão. O valor deste parâmetro é calculado a cada nível de

compressão da mesma forma como é feito no SegSAR (SOUSA JUNIOR, 2005), usando a expressão dada por:

$$nel_c = \frac{nel_0 \cdot fc_c^2}{1 + 2 \cdot \left(1 - \frac{1}{fc_c}\right) \cdot \left[\hat{\rho}(0,1) + \hat{\rho}(1,0) + \left(1 - \frac{1}{fc_c}\right) \cdot \hat{\rho}(1,1)\right]} \quad (5.7)$$

onde nel_0 corresponde ao valor do número equivalente de *looks* fornecido pelo usuário para a imagem sem compressão, $\hat{\rho}(0,1)$ é o estimador da autocorrelação de *lag* 1 no sentido das linhas na imagem, $\hat{\rho}(1,0)$ é o estimador da autocorrelação de *lag* 1 no sentido das colunas na imagem e $\hat{\rho}(1,1)$ é o estimador da autocorrelação de *lag* 1 nos sentidos das colunas e linhas da imagem, todos obtidos a partir da média das autocorrelações dos elementos da diagonal principal da matriz de covariância no nível de compressão igual a zero.

O uso da técnica de compressão piramidal possui como vantagem o menor consumo de tempo no processo de segmentação de imagens por crescimento de regiões, decorrente da diminuição da dimensão da imagem original. Entretanto no SegSAR, esta técnica possui como desvantagem a necessidade de armazenamento em memória RAM da imagem a cada nível de descompressão, exigindo grande quantidade de memória. No PolSeg procurou-se minimizar a desvantagem apresentada no SegSAR. A abordagem adotada para isso foi realizar a leitura dos dados da matriz de covariância sem compressão (armazenados em disco após a geração da matriz) a cada início da sequência de processamento dos módulos da segunda etapa, os quais são carregados em uma variável temporária, que após ter sido usada na compressão é “zerada” liberando a memória RAM usada para alocar os dados. Os dados comprimidos também são armazenados em variável temporária, a qual é submetida ao mesmo tratamento após a segmentação por crescimento de regiões. Este procedimento foi adotado, pois foi verificado durante o desenvolvimento do algoritmo que o espaço de memória RAM usado para

armazenamento de dados poderia comprometer o uso desta memória durante o processamento, diminuindo o desempenho do algoritmo em termos de tempo de processamento.

5.2.1.5. Segmentação por crescimento de regiões

Este módulo de processamento realiza a segmentação da matriz de covariância comprimida no nível de compressão selecionado usando a técnica de crescimento de regiões. O processamento realizado no módulo é dividido em duas fases, a fase de preparo e a fase de segmentação.

5.2.1.5.1. Fase de preparo

Inicialmente é verificado o nível de compressão para definir se o número equivalente de *looks* deve ou não ser calculado. Nesta verificação se o nível de compressão for zero (imagem sem compressão) o PolSeg assume como número equivalente de *looks* do nível de compressão o nel_0 . Caso contrário, se o nível de compressão for maior que zero, o algoritmo calcula o número equivalente de *looks* para o nível de compressão selecionado por meio da Equação (5.7).

Após estas verificações iniciais é gerada uma imagem para ser usada como registro dos números identificadores das regiões, denominada por imagem de *Id's*. A imagem é gerada com as mesmas dimensões de coluna e linha da matriz de covariância comprimida e seus *pixels* possuem inicialmente valores iguais à zero.

Na sequência é gerado um vetor contendo os índices lexicográficos de todos os *pixels* da imagem de *Id's* ordenados de forma aleatória, denominado vetor de sementes. Este vetor é usado para armazenar os índices lexicográficos dos *pixels* que serão usados como sementes das regiões, ou seja, *pixels* a partir dos quais ocorrerão os crescimentos de regiões.

Logo após a geração do vetor de sementes é estabelecida a relação de conectividade para os *pixels* da imagem. Para fins de processamento no

PolSeg, cada *pixel* contido na matriz de covariância comprimida é considerado uma região, para a qual é estabelecida uma das duas relações de conectividade disponibilizadas para seleção na interface de entrada (quatro ou oito).

O próximo passo executado pelo algoritmo é a geração de vetores para armazenar os dados das regiões obtidas durante a segmentação. Ao todo são gerados três vetores, que são usados para armazenar os *Id's*, a quantidade de *pixels* e os valores médios das regiões para todos os elementos da matriz de covariância. A dimensão inicial destes vetores é igual a um e todos são preenchidos com zeros. Estes valores iniciais são removidos dos vetores ao término do processo de crescimento de regiões, sendo deixados somente os dados obtidos durante a segmentação. A adoção de vetores foi a alternativa encontrada para evitar a criação de estruturas matriciais para armazenamento de dados, as quais podem consumir quantidade significativa de memória RAM durante o processamento.

5.2.1.5.2. Fase de segmentação

Na fase de segmentação é realizada inicialmente uma verificação para decidir qual tipo de dado foi carregado e que tipo de teste estatístico deve ser usado para realizar a segmentação. Nesta verificação se a ordem da matriz de covariância for igual a um, dado monocal, é adotado para a segmentação o teste de hipótese fundamentado na distribuição *Gama* ($\Gamma(L, \beta)$) descrito na Seção 2.2.4. Caso contrário, se a ordem da matriz é diferente de um, dado multicanal, é adotado para a segmentação o teste de hipótese fundamentado na distribuição *Wishart* complexa escalonada ($W_E(L, \Sigma)$) descrito na Seção 2.2.3.

O início do processo de segmentação por crescimento de regiões se dá pela seleção do primeiro elemento do vetor de sementes, o qual é imediatamente retirado do vetor diminuindo sua dimensão. Para este índice lexicográfico, denominado aqui de semente, é atribuído um número identificador o qual é posicionado e registrado na imagem de *Id's*, a qual até este momento estava

completamente preenchida com zeros. A localização da semente na imagem comprimida, por sua vez, permite obter o valor do *pixel* correspondente ao índice selecionado e os valores de seus *pixels* vizinhos, conforme a relação de conectividade selecionada.

O processo de crescimento de regiões pode ocorrer após a aplicação do teste estatístico realizado entre os valores dos vizinhos e o valor da semente. Se o teste estatístico indicar que as matrizes de covariância do *pixel* semente e de um de seus vizinhos são estatisticamente iguais, ocorre o crescimento, caso contrário não há crescimento e a região é formada somente pela semente. Os vizinhos que passam no teste recebem o mesmo *Id* da semente e são registrados na imagem de *Id*'s formando por agrupamento uma região. Os índices dos *pixels* incorporados são então retirados do vetor de sementes, diminuindo ainda mais a dimensão do vetor.

Este ciclo se repete para os *pixels* vizinhos da região, até que o teste estatístico não seja mais satisfeito ou o limite de ciclos de crescimentos selecionado pelo usuário seja atingido. Os dados da região formada, número identificador (*Id*), quantidade de *pixels* e dados médios da matriz de covariância, são então, armazenados em seus respectivos vetores. Após isto, uma nova semente é selecionada e o processo se repete novamente gerando uma nova região. O processo termina quando não houver mais sementes no vetor, momento no qual a imagem de *Id*'s também não possuirá mais *pixels* preenchidos com o valor zero. Após isto os vetores contendo os dados das regiões formadas no processo são armazenados em uma estrutura para ser usada no módulo de processamento seguinte. Cabe ressaltar, que o plantio de sementes, bem como, o crescimento de regiões somente ocorre em *pixels* da imagem de *Id*'s com valores iguais a zero.

A seguir são descritas as aplicações dos dois testes estatísticos adotados pelo PolSeg, em função do tipo de dado de entrada, para realizar o agrupamento *pixel* com *pixel* e *pixel* com região das imagens SAR, efetuados neste módulo de processamento. O teste para agrupar regiões com regiões será visto na

segunda etapa de processamento quando for abordado o módulo agrupamento de regiões.

a) Aplicação do teste de igualdade de médias de intensidades

Os passos para aplicação do teste na segmentação de dados SAR univariado em intensidade são descritos a seguir:

1º) Adota-se o nível de significância α para o teste estatístico. Como o teste é bilateral o nível de significância adotado é dividido por dois para a definição do seu intervalo de confiança. Este intervalo é delimitado pelos valores críticos d_1 e d_2 , obtidos por

$$d_1 = 1 - \frac{\alpha}{2}, \text{ e} \quad (5.8)$$

$$d_2 = \frac{\alpha}{2}. \quad (5.9)$$

2º) Obtém-se os estimadores das regiões \mathbf{X} e \mathbf{Y} , compostas por N_1 e N_2 *pixels*, denominados de \bar{X} e \bar{Y} . Estes estimadores são obtidos por meio do cálculo da média simples dos valores no formato intensidade de cada *pixel* contido nas regiões, ou seja,

$$\bar{X} = \frac{1}{N_1} \sum_{i=1}^{N_1} x_i \quad (5.10)$$

$$\bar{Y} = \frac{1}{N_2} \sum_{i=1}^{N_2} y_i \quad (5.11)$$

3º) Computam-se os valores do número de *pixels* independentes das regiões \mathbf{X} e \mathbf{Y} , de acordo com as dimensões das regiões em termos de *pixels*, dados por

$$n = N_1 \cdot nel_c \quad (5.12)$$

$$m = N_2 \cdot nel_c \quad (5.13)$$

onde nel_c é o número equivalente de looks calculado para o nível de compressão c considerado;

4º) A partir dos estimadores \bar{X} e \bar{Y} , calcula-se a estatística de teste F^* , por meio de

$$F^* = \frac{\bar{Y}}{\bar{X}} \quad (5.14)$$

5º) Calculam-se os valores das probabilidades na distribuição de F da estatística de teste F^* , ser menor ou igual ao valor crítico d_1 , e de ser maior ou igual ao valor crítico d_2 , obtidas por

$$P(F^* \leq d_1) = P\{F(2m, 2n) \leq d_1\} \quad (5.15)$$

$$P(F^* \geq d_2) = 1 - P\{F(2m, 2n) \leq d_2\} \quad (5.16)$$

6º) Aplica-se o critério de decisão do teste dado pelas condições

Se $F^* \leq d_1$ ou $F^* \geq d_2 \rightarrow$ aceita-se H_0 , pois não há evidências para discordar da igualdade ao nível de significância α ;

Se $F^* \geq d_1$ ou $F^* \leq d_2 \rightarrow$ rejeita-se H_0 , pois há evidências para discordar da igualdade ao nível de significância α .

b) Aplicação do teste de igualdade de matrizes de covariância

Os passos para aplicação do teste na segmentação de dados PolSAR representados por matriz de covariância de ordem igual a dois ou superior são descritos a seguir:

1º) Adota-se um nível de significância α para o teste estatístico;

2º) Obtém-se os estimadores das regiões X e Y , compostas por N_1 e N_2 *pixels*, denominados aqui de \bar{X} e \bar{Y} . Estes estimadores são obtidos por meio do cálculo da média simples das matrizes de covariância de cada *pixel* contidos nas regiões, de modo que

$$\bar{\mathbf{X}} = \frac{1}{N_1} \sum_{i=1}^{N_1} \mathbf{x}_i \quad (5.17)$$

$$\bar{\mathbf{Y}} = \frac{1}{N_2} \sum_{i=1}^{N_2} \mathbf{y}_i \quad (5.18)$$

3º) Computam-se os valores do número de *pixels* independentes n da região \mathbf{X} e m da região \mathbf{Y} , de acordo com as quantidades de pixels das regiões, usando respectivamente as Equações (5.12) e (5.13);

4º) A partir dos estimadores $\bar{\mathbf{X}}$ e $\bar{\mathbf{Y}}$, calculam-se a razão de verossimilhança $\lambda_{W_E(L,\Sigma)}^*$ e a estatística de teste M^* , por meio de

$$\lambda_{W_E(L,\Sigma)}^* = \frac{|\bar{\mathbf{X}}|^n |\bar{\mathbf{Y}}|^m}{\left| \frac{N_1 \bar{\mathbf{X}} + N_2 \bar{\mathbf{Y}}}{N_1 + N_2} \right|^{n+m}} = \frac{|\bar{\mathbf{X}}|^n |\bar{\mathbf{Y}}|^m}{|\bar{\mathbf{Z}}|^{n+m}} \quad (5.19)$$

$$M^* = -2\rho \ln(\lambda_{W_E(L,\Sigma)}^*) \quad (5.20)$$

5º) Calcula-se o valor-p do teste por meio de

$$\text{valor} - p = 1 - P(M \leq M^*) \quad (5.21)$$

onde $P(M \leq M^*)$ é dada pela Equação (2.32).

6º) A decisão para o teste é tomada comparando-se o valor-p do teste estatístico com o nível de significância α adotado, de forma que:

Se $\text{valor} - p \geq \alpha \rightarrow$ Aceita-se H_0 , pois não há evidências para rejeitar a igualdade das matrizes de covariância ao nível de significância α ;

Se $\text{valor} - p \leq \alpha \rightarrow$ Rejeita-se H_0 , pois há evidências para rejeitar a igualdade das matrizes de covariância ao nível de significância α .

c) Teste para agrupar *pixel* com *pixel*

A única consideração feita com relação à aplicação do teste no agrupamento *pixel* com *pixel* é que neste caso $N_1 = N_2 = 1$, sendo os valores do número de *pixels* independentes da região formada pelo *pixel* semente (m) e da região adjacente formada pelo *pixel* vizinho (n), dado pelo número equivalente de *looks* calculado para o nível de compressão no qual o teste é aplicado (nel_c), ou seja,

$$n = m = nel_c \quad (5.22)$$

d) Teste para agrupar *pixel* com região

A consideração feita com relação à aplicação do teste para o agrupamento *pixel* com região é que a quantidades de *pixels* das regiões envolvidas são diferentes ($N_1 \neq N_2$). Neste caso, o valor do número de *pixels* independentes da região adjacente formada pelo *pixel* vizinho (n) é dado pelo nel_c . Enquanto, o valor do número de *pixels* independentes da região semente (m) é dado pelo nel_c multiplicado pela quantidade de *pixels* N_2 da região, ou seja,

$$n = nel_c \quad (5.23)$$

$$m = N_2 \cdot nel_c \quad (5.24)$$

5.2.2. Segunda etapa de processamento

A segunda etapa é constituída da sequencia dos módulos de processamento apresentados na Figura 5.1 que são: descompressão em um nível, análise de bordas, análise de homogeneidade, segmentação de regiões heterogêneas, agrupamento de regiões, agrupamento de *pixels* isolados, interação com usuário e descompressão para o nível zero.

No início da segunda etapa de processamento o algoritmo cria o arquivo de análise de homogeneidade (analisehomog.txt), para armazenar as informações

geradas durante a execução do módulo análise de homogeneidade. Após isso, o PolSeg executa um laço no qual repete a sequência de processamento pré-definida formada por vários módulos, conforme ilustrado na Figura 5.1, até que seja interrompido. Esta interrupção pode ser decorrente de três situações: (1) até que o nível de compressão seja o nível zero (nível da imagem de entrada); (2) caso o usuário deseje salvar um resultado parcial como sendo o final; ou, (3) caso o usuário deseje abortar o processamento antes que este termine. Quando a primeira ou a segunda situação ocorre, os dados de segmentação gerados são encaminhados para a terceira e última etapa de processamento. Cabe mencionar, que as duas últimas situações somente são possíveis se o usuário optar na interface de entrada de dados e parâmetros pela visualização dos dados intermediários. A seguir são descritos em detalhes a sequência e os módulos de processamento que fazem parte da segunda etapa de processamento.

5.2.2.1. Descompressão em um nível

Este módulo de processamento executa a descompressão em um nível dos dados segmentados gerados na primeira etapa ou oriundo de um nível superior.

Antes de realizar a descompressão em um nível o PolSeg calcula o número equivalente de *looks* para o nível de compressão considerado, o qual será usado pelos módulos de análise de homogeneidade, segmentação de regiões heterogêneas e agrupamento de regiões. Neste caso, se c for maior que zero o nel_c é calculado usando-se a Equação (5.7), caso contrário o algoritmo considera que $nel_c = nel_0$.

A descompressão em um nível, a bem da verdade, é realizada somente sobre a imagem de *Id*'s comprimida. Neste processo cada *pixel* desta imagem passa a ser representado por quatro *pixels* com o mesmo valor de *Id* do *pixel* da imagem comprimida (Figura 5.4), o que duplica sua dimensão em coluna e linha.

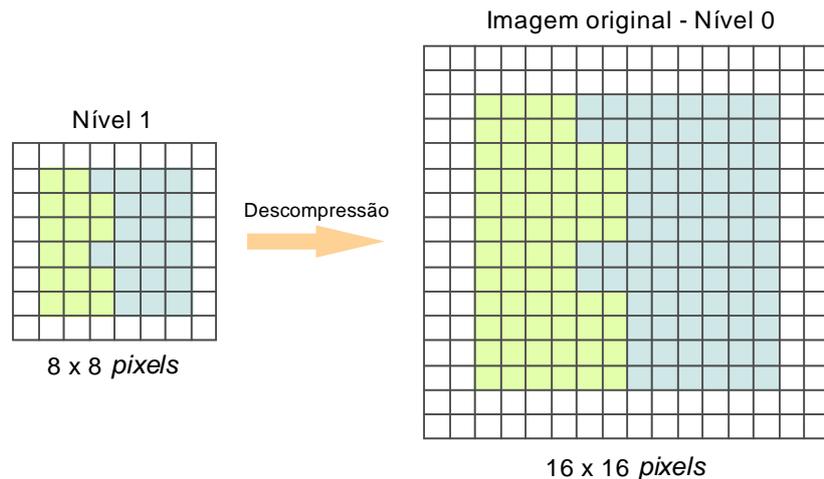


Figura 5.4 - Descompressão em um nível de uma imagem comprimida conforme o critério de pirâmides hierárquicas.

As informações da matriz de covariância, necessárias para serem usados pelos demais módulos de processamento, por sua vez, são obtidas a partir da compressão dos dados da matriz de covariância no nível zero para o nível de compressão considerado. Para isso, os dados da matriz de covariância no nível zero, gravados no disco rígido, após o término do processamento do módulo de geração da matriz de covariância, são restaurados e armazenados em uma variável aleatória temporária usada no processo de compressão. Esta variável é “zerada” após o término do processamento a fim de liberar espaço de memória RAM para processamento.

Para dar continuidade ao processamento realizado nesse módulo, são obtidos os valores que permitem verificar se a imagem no nível c considerado possui colunas ou linhas a mais, adicionadas a imagem original durante a execução do módulo de carregamento da imagem. Isto é feito para que estas colunas e linhas, caso existam, possam ser retiradas tanto da imagem de Id 's descomprimida como da matriz de covariância comprimida. Para isso, é calculado o fator de compressão fc_c , empregando-se a Equação (5.2), e as dimensões em coluna col_c e linha lin_c que a imagem original deveria ter no nível de compressão c considerado, usando respectivamente as Equações (5.5) e (5.6).

A quantidade de colunas col_{adic} e linhas lin_{adic} que por ventura possam ter sido adicionadas são obtidas pela diferença entre os valores de colunas e linhas da matriz de covariância que sofreu a descompressão para o nível c considerado, representados respectivamente por col_{desc} e lin_{desc} , e os valores col_c e lin_c calculados, ou seja,

$$col_{adic} = col_{desc} - col_c \quad (5.25)$$

$$lin_{adic} = lin_{desc} - lin_c \quad (5.26)$$

Se os valores de col_{adic} e lin_{adic} forem iguais a zero, então o algoritmo realiza a compatibilização da estrutura que armazena os dados das regiões para o nível de compressão c multiplicando por quatro os valores do vetor da estrutura que contém as quantidades de *pixels*. Caso contrário a imagem de *Id's* e a matriz de covariância comprimida são redimensionadas, retirando-se as colunas e ou linhas que foram adicionadas. Neste caso, a estrutura que armazena os dados das regiões é totalmente atualizada tomando por base a imagem de *Id's* e a matriz de covariância redimensionada.

Ao término do processamento realizado pelo módulo de descompressão em um nível são gravados no relatório de processamento: o nível de compressão, o fator de compressão do nível, a dimensão em coluna e linha da imagem de *Id's* e da matriz de covariância comprimida, e o tempo de processamento do módulo.

5.2.2.2. Análise de bordas

O módulo de análise de bordas executa o refinamento das bordas das regiões da imagem segmentada após esta ser submetida a descompressão em um nível.

A análise de bordas é realizada para os *pixels* de bordas da região analisada e os *pixels* de bordas pertencentes a regiões vizinhas, e consiste basicamente em verificar em que região os *pixels* localizados nas bordas devem ser

realmente agrupados. Para isso os *pixels* de bordas são testados em relação a região a que pertencem e a região vizinha com que fazem fronteira.

Este processamento se faz necessário porque a imagem oriunda da segmentação, após ter sido submetida à descompressão, pode apresentar segmentos com bordas grosseiras. Isto ocorre porque a segmentação é realizada sobre uma imagem comprimida, a qual sofre um aumento de resolução espacial após ser submetida à descompressão em um nível.

Antes de realizar a análise de bordas é verificada a ordem da matriz de covariância para definir como serão calculados os valores a serem usados nos testes lógicos. Os cálculos dos valores tomam por base as expressões usadas para calcular as variáveis aleatórias dos testes de hipóteses aplicados na segmentação por crescimento de regiões. Na verificação feita se a ordem da matriz de covariância for um (dado monocanal) é adotado para o cálculo dos valores a formulação baseada no módulo do logaritmo da razão das intensidades entre o *pixel* de borda e a região. Caso contrário, é adotada a formulação baseada no módulo do logaritmo da razão de verossimilhança entre os determinantes da matriz de covariância do *pixel* de borda e a região considerada.

Logo após a verificação são gerados dois vetores para ordenar e controlar a execução do processamento. O primeiro, denominado vetor de sementes, contém os *Id*'s das regiões existentes na imagem de *Id*'s. Este vetor é obtido replicando o vetor de *Id*'s da estrutura que armazena os dados das regiões. O segundo, denominado vetor de *pixels* alterados é usado para armazenar os *pixels* de bordas das regiões analisadas durante o processamento.

O início do processo de análise se assemelha ao processo de crescimento de regiões e se dá pela seleção do primeiro elemento do vetor de sementes, que corresponde ao *Id* da região que será analisada, o qual é imediatamente retirado do vetor diminuindo sua dimensão.

Para a região a ser analisada são obtidos, então, os *pixels* que fazem parte da faixa de fronteira. A partir destes *pixels* são identificados aqueles que pertencem à borda da região analisada e os que pertencem às bordas das regiões vizinhas. A Figura 5.5 apresenta um exemplo da identificação dos *pixels* de borda da região analisada (cor vermelha) e dos *pixels* de borda das regiões vizinhas (azul e verde).

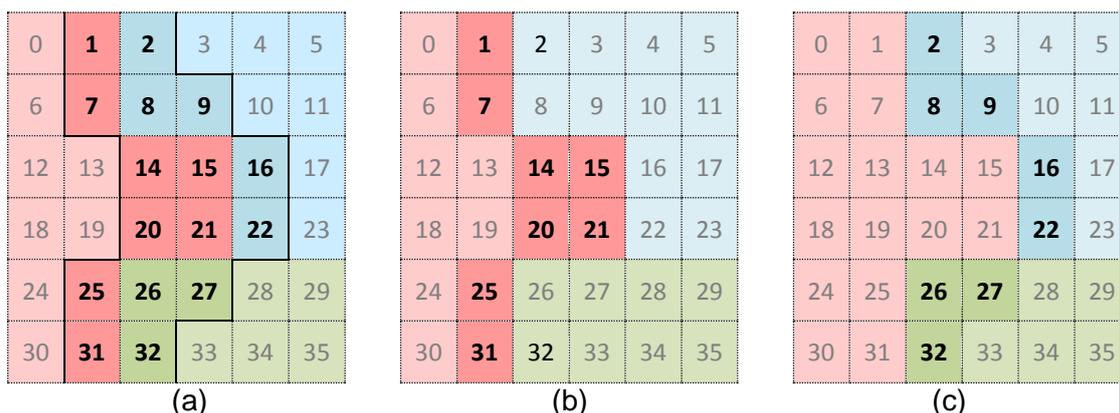


Figura 5.5 - Definição dos pixels de borda para análise: (a) faixa de fronteira de uma região analisada (faixa de *pixels* delimitada por linha cheia); (b) *pixels* de borda da região analisada (cor vermelha); e, (c) *pixels* de borda das regiões vizinhas (cores azul e verde).

Tomando por base os *pixels* de borda da região analisada (ps) e seu relacionamento topológico com os *pixels* de borda das regiões vizinhas (pv) realiza-se a vinculação entre os *pixels* das regiões envolvidas na análise (Figura 5.6). Esta vinculação é armazenada em um vetor contendo os pares de *pixels* vinculados. Tal processamento se faz necessário, pois um *pixel* posicionado na borda de uma região analisada pode possuir mais que um *pixel* de borda vizinho.

Na sequência os *pixels* de borda da região analisada são armazenados no vetor de *pixels* alterados, aumentando a quantidade de *pixels* armazenados em sua estrutura. Os *pixels* de borda são armazenados neste vetor para que não participem mais de análises que serão realizadas tomando por base outras regiões. Para que isto ocorra, o vetor de *pixels* alterados é consultado a fim de verificar quais *pixels* podem participar da análise. Se durante a verificação um

pixel de borda a ser analisado for identificado no vetor, então o algoritmo elimina o par de *pixels* vinculados que conter este *pixel*.

0	1	2	3	4	5	$ps - pv$ 01 - 02 07 - <u>08</u> 14 - <u>08</u> 15 - 09 15 - 16 21 - 22 21 - 27 20 - <u>26</u> 25 - <u>26</u> 31 - 32	Situações com mais de uma vinculação: - ps com mais de um <i>pixel</i> vizinho: 15 e 21 - pv com mais de um <i>pixel</i> vizinho: 8 e 26
6	7	8	9	10	11		
12	13	14	<u>15</u>	16	17		
18	19	20	<u>21</u>	22	23		
24	25	<u>26</u>	27	28	29		
30	31	32	33	34	35		

Figura 5.6 - Vinculação entre *pixels* de borda da região analisada (ps) e das regiões vizinhas (pv) e situações onde um *pixel* pode possuir mais que uma vinculação (índice lexicográfico sublinhado).

A partir do vetor de pares de *pixels* vinculados, são calculados então, para cada par, valores baseados no módulo do logaritmo da razão entre os *pixels* de bordas e as regiões. Estes valores são usados nos testes lógicos que decidem se há algum *pixel* de borda da região analisada que deve ser passado para a região vizinha ou se há algum *pixel* de borda da região vizinha que deve ser agrupado à região analisada.

A situação apresentada na Figura 5.7 ajuda a entender melhor como são obtidos os valores usados nos testes lógicos. Nesta figura, a região analisada **Y**, com N_2 *pixels*, contém o *pixel* de borda **y** e tem como vizinha a região **X**, com N_1 *pixels*, que contém o *pixel* de borda **x**, sendo ainda **y** adjacente a **x**.

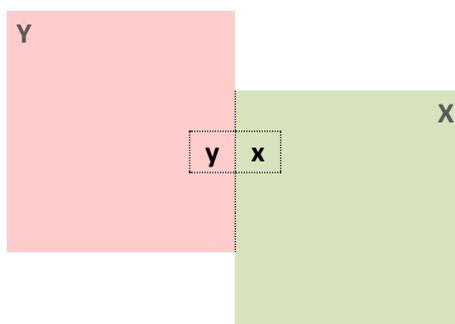


Figura 5.7 - Regiões analisada e vizinha com *pixels* de borda adjacentes.

A situação apresentada na Figura 5.7 mostra a existência de duas situações possíveis para os *pixels* de borda **x** e **y**:

- Os *pixels* de bordas permanecem em suas respectivas regiões, ou seja, não ocorre alteração na definição da borda; ou,
- Um dos *pixels* de borda deve passar para a região vizinha adjacente, ocorrendo a alteração da borda. Neste caso, uma das duas situações pode ocorrer:
 - o *pixel* de borda **x** passa para a região **Y**; ou,
 - o *pixel* de borda **y** passa para a região **X**.

Uma terceira situação possível que poderia ocorrer é a troca mútua de posição dos *pixels* adjacentes, onde o pixel de borda **x** passaria para a região **Y** enquanto o pixel **y** passaria para a região **X**. Essa situação entretanto não é considerada no algoritmo.

A confirmação das situações possíveis pode ser obtida por meio da obtenção de quatro valores a partir da informação dos *pixels* de bordas e das regiões, que depois de obtidos podem ser usados por testes lógicos para realizar o ajuste da borda.

Conforme comentado anteriormente, a obtenção dos valores é feita através de cálculos baseados no módulo da razão de logaritmos entre as informações existentes nos *pixels* de bordas e as regiões. A formulação para realizar estes cálculos depende da dimensão da matriz de covariância que está sendo processada, a qual pode possuir ordem igual a um ou maior. Portanto, os valores usados nos testes lógicos são obtidos de duas maneiras, as quais são vistas a seguir:

a) Matrizes de covariância com ordem unitária

Para matrizes de covariância com ordem unitária, formadas por um elemento da diagonal principal da matriz de covariância, são calculados os valores do módulo do logaritmo da razão das intensidades entre os *pixels* de borda e as regiões. Neste caso, os valores relacionando os *pixels* de bordas e as regiões, são obtidos por

$$R_{xX} = \text{mod} \left(\ln \left(\frac{x}{\bar{X}} \right) \right) = \text{mod}(\ln(x) - \ln(\bar{X})) \quad (5.27)$$

$$R_{xY} = \text{mod} \left(\ln \left(\frac{x}{\bar{Y}} \right) \right) = \text{mod}(\ln(x) - \ln(\bar{Y})) \quad (5.28)$$

$$R_{yX} = \text{mod} \left(\ln \left(\frac{y}{\bar{X}} \right) \right) = \text{mod}(\ln(y) - \ln(\bar{X})) \quad (5.29)$$

$$R_{yY} = \text{mod} \left(\ln \left(\frac{y}{\bar{Y}} \right) \right) = \text{mod}(\ln(y) - \ln(\bar{Y})) \quad (5.30)$$

onde $\text{mod}(\cdot)$ representa o módulo, x e y assumem respectivamente os valores das intensidades dos *pixels* de borda da região vizinha e da região analisada, e \bar{X} e \bar{Y} assumem respectivamente os valores médios de intensidade da região vizinha X e da região analisada Y .

Cabe mencionar que os cálculos de \bar{X} e \bar{Y} incluem, respectivamente os valores dos pixels x e y . Valores de R_{ij} próximos a zero significa maior possibilidade de i pertencer a j , onde i pode assumir x ou y e j pode assumir X ou Y .

b) Matrizes de covariância com ordem maior que um

Para matrizes de covariância com ordem maior que um, são calculados os valores do módulo do logaritmo da razão de verossimilhança dos determinantes da matriz de covariância entre os *pixels* de borda e as regiões. Dessa forma, os valores que relacionam os *pixels* de bordas e as regiões, são obtidos por

$$R_{\mathbf{x}\mathbf{x}} = \text{mod} \left(\ln \left(\frac{|\mathbf{x}|^{nel_c} \cdot |\bar{\mathbf{X}}|^n}{|\bar{\mathbf{Z}}|^{nel_c+n}} \right) \right) = \text{mod} \left(nel_c \ln|\mathbf{x}| + n \ln|\bar{\mathbf{X}}| - (nel_c + n) \ln|\bar{\mathbf{Z}}| \right) \quad (5.31)$$

$$R_{\mathbf{x}\mathbf{Y}} = \text{mod} \left(\ln \left(\frac{|\mathbf{x}|^{nel_c} \cdot |\bar{\mathbf{Y}}|^m}{|\bar{\mathbf{Z}}|^{nel_c+m}} \right) \right) = \text{mod} \left(nel_c \ln|\mathbf{x}| + m \ln|\bar{\mathbf{Y}}| - (nel_c + m) \ln|\bar{\mathbf{Z}}| \right) \quad (5.32)$$

$$R_{\mathbf{y}\mathbf{x}} = \text{mod} \left(\ln \left(\frac{|\mathbf{y}|^{nel_c} \cdot |\bar{\mathbf{X}}|^n}{|\bar{\mathbf{Z}}|^{nel_c+n}} \right) \right) = \text{mod} \left(nel_c \ln|\mathbf{y}| + n \ln|\bar{\mathbf{X}}| - (nel_c + n) \ln|\bar{\mathbf{Z}}| \right) \quad (5.33)$$

$$R_{\mathbf{y}\mathbf{Y}} = \text{mod} \left(\ln \left(\frac{|\mathbf{y}|^{nel_c} \cdot |\bar{\mathbf{Y}}|^m}{|\bar{\mathbf{Z}}|^{nel_c+m}} \right) \right) = \text{mod} \left(nel_c \ln|\mathbf{y}| + m \ln|\bar{\mathbf{Y}}| - (nel_c + m) \ln|\bar{\mathbf{Z}}| \right) \quad (5.34)$$

onde, $\text{mod}(\cdot)$ representa módulo, $|\cdot|$ representa determinante, \mathbf{x} e \mathbf{y} são as matrizes de covariância dos *pixels* de borda da região vizinha e da região analisada, e $\bar{\cdot}$ e $\bar{\cdot}$ são as matrizes de covariâncias média da região vizinha e da região analisada. Cabe mencionar que os cálculos de $\bar{\cdot}$ e $\bar{\cdot}$ incluem, respectivamente os valores dos *pixels* \mathbf{x} e \mathbf{y} . Valores de R_{ij} próximos a zero significa maior possibilidade de i pertencer a j , onde i pode assumir \mathbf{x} ou \mathbf{y} e j pode assumir \mathbf{X} ou \mathbf{Y} .

A análise de bordas tomando por base os valores R_{ij} é feita para cada *pixel* de borda da região que esta sendo analisada. Dessa forma, dependendo da posição do *pixel* de fronteira da região este poderá ter um ou dois *pixels* vizinhos, conforme visto na Figura 5.6. Além disso, para o caso de dois *pixels* vizinhos, dependendo disposição das regiões vizinhas, ambos podem pertencer a uma única região ou a regiões diferentes. Estas situações são identificadas antes de aplicar os testes lógicos para realizar o ajuste da borda.

Sendo assim, usando \mathbf{Y} para representar a região analisada, \mathbf{y} para representar o *pixel* de fronteira desta região, \mathbf{X} e \mathbf{Z} para representar regiões

vizinhas adjacentes à região analisada, com *pixels* de fronteira representados respectivamente por **x** e **z**, pode-se constatar a existência de três casos possíveis para a análise de *pixels* de bordas adjacentes, os quais são apresentados com mais detalhes a seguir:

a) Caso 1

No caso 1 o *pixel* de fronteira **y** da região analisada **Y** se encontra em contato com um único *pixel* de fronteira das regiões vizinhas, estabelecendo a relação de um para um (1–1). A Figura 5.8 ilustra exemplos, onde os *pixels* de índice lexicográfico 1 e 31 da região analisada **Y** (região de cor vermelha) estão em contato, respectivamente com o *pixel* **x** de índice lexicográfico 2 da região vizinha **X** (região de cor azul) e o *pixel* **z** de índice lexicográfico 32 da região vizinha **Z** (região de cor verde).

0	1	2	3	4	5
6	7	8	9	10	11
12	13	14	15	16	17
18	19	20	21	22	23
24	25	26	27	28	29
30	31	32	33	34	35

Figura 5.8 - Exemplo do Caso 1 onde *pixels* de fronteira da região analisada se encontram vinculados a *pixel* de fronteira de regiões vizinhas na relação de um para um.

Como há contato somente entre um *pixel* de fronteira da região analisada com um *pixel* das regiões vizinhas, a representação adotada para regiões e os *pixels* de fronteira pode ser resumida usando-se somente duas regiões **Y** e **X**. Dessa forma, são calculados, para cada par de *pixels* de fronteira vinculados, os valores de R_{xX} , R_{xY} , R_{yY} e R_{yX} , usando as Equações (5.27) a (5.30), se a ordem da matriz de covariância for igual a um, ou usando as Equações (5.31) a (5.34), se a ordem da matriz for maior que um. Estes valores são aplicados nos seguintes testes lógicos

Se $(R_{xX} > R_{xY})$ e $(R_{yY} \leq R_{yX}) \rightarrow xY = 1$, caso contrário $xY = 0$

Se $(R_{xX} < R_{xY})$ e $(R_{yY} \geq R_{yX}) \rightarrow yX = 1$, caso contrário $yX = 0$

sendo que, $xY = 1$ significa que \mathbf{x} pertence a \mathbf{Y} , e $xY = 0$ significa que \mathbf{x} não pertence a \mathbf{Y} , sendo a mesma definição aplicada para yX .

As situações que podem ocorrer são:

1) Não ocorre mudança entre os *pixels* envolvidos na análise. Dessa forma, \mathbf{y} permanece na região \mathbf{Y} e \mathbf{x} permanece na região \mathbf{X} . Sendo assim, os testes lógicos xY e yX devem resultar zero. O critério de decisão então é dado por:

Se $xY = 0$ e $yX = 0 \rightarrow \mathbf{y}$ permanece em \mathbf{Y} e \mathbf{x} permanece em \mathbf{X} .

2) Ocorre mudança entre os *pixels* envolvidos na análise, podendo ocorrer um dos dois casos:

a. \mathbf{x} vai para a região \mathbf{Y} , para isso o teste lógico xY deve resultar 1 enquanto que yX deve resultar zero, sendo o critério de decisão dado por:

Se $xY = 1$ e $yX = 0 \rightarrow \mathbf{x}$ vai para \mathbf{Y} ;

b. \mathbf{y} vai para a região \mathbf{X} , para isso o teste lógico yX deve resultar 1 enquanto que xY deve resultar zero, sendo o critério de decisão dado por:

Se $xY = 0$ e $yX = 1 \rightarrow \mathbf{y}$ vai para \mathbf{X} .

b) Caso 2

Já no caso 2 o *pixel* de fronteira da região analisada se encontra em contato com dois *pixels* de borda pertencentes a uma única região vizinha, estabelecendo a relação de um para dois (1-2). A Figura 5.9 ilustra um exemplo, onde o *pixel* \mathbf{y} , representado pelo índice lexicográfico 15, da região semente \mathbf{Y} (região de cor vermelha) esta em contato com dois *pixels* de fronteira da região vizinha \mathbf{X} (região de cor azul), *pixels* de índice lexicográfico 9 e 16.

0	1	2	3	4	5
6	7	8	9	10	11
12	13	14	15	16	17
18	19	20	21	22	23
24	25	26	27	28	29
30	31	32	33	34	35

Figura 5.9 - Exemplo do Caso 2 onde um *pixel* de fronteira da região analisada se encontra vinculado a dois *pixels* de fronteira de uma região vizinha (relação de um para dois).

Como há contato entre um *pixel* de fronteira da região analisada com dois *pixels* da região vizinha, estes são representados por \mathbf{x}_1 e \mathbf{x}_2 . Dessa forma, são calculados, para os dois pares de *pixels* vinculados, os valores de R_{yY} , R_{yX} , R_{x_1Y} , R_{x_1X} , R_{x_2Y} e R_{x_2X} , os quais são usados nos testes lógicos, dados por

$$\text{Se } (R_{x_1X} > R_{x_1Y}) \text{ e } (R_{yX} \geq R_{yY}) \rightarrow x_1Y = 1, \text{ caso contrário } x_1Y = 0$$

$$\text{Se } (R_{yY} > R_{yX}) \text{ e } (R_{x_1Y} \geq R_{x_1X}) \rightarrow yX_1 = 1, \text{ caso contrário } yX_1 = 0$$

$$\text{Se } (R_{x_2X} > R_{x_2Y}) \text{ e } (R_{yX} \geq R_{yY}) \rightarrow x_2Y = 1, \text{ caso contrário } x_2Y = 0$$

$$\text{Se } (R_{yY} > R_{yX}) \text{ e } (R_{x_2Y} \geq R_{x_2X}) \rightarrow yX_2 = 1, \text{ caso contrário } yX_2 = 0$$

onde $x_1Y = 1$ deve ser entendido como o teste que define se \mathbf{y} vai para \mathbf{X} em função de \mathbf{x}_1 , $yX_1 = 1$ significa que \mathbf{y} pertence a \mathbf{X} , enquanto $yX_1 = 0$ significa que \mathbf{y} não pertence a \mathbf{X} , com valor calculado em função de \mathbf{x}_1 , sendo a mesma definição aplicada para yX_2 .

As seguintes situações podem ocorrer neste caso:

1) Não ocorre mudança entre os *pixels* envolvidos na análise. Dessa forma, \mathbf{y} permanece na região \mathbf{Y} e \mathbf{x}_1 e \mathbf{x}_2 permanecem na região \mathbf{X} . Sendo assim, todos os testes lógicos devem resultar zero. O critério de decisão nesta situação é dado por:

Se $x_1Y = 0$ e $yX_1 = 0$ e $x_2Y = 0$ e $yX_2 = 0 \rightarrow \mathbf{y}$ permanece em **Y** e \mathbf{x}_1 e \mathbf{x}_2 permanecem em **X**;

2) Ocorre mudança entre os *pixels* envolvidos na análise, podendo ocorrer um dos seguintes casos:

a. \mathbf{y} vai para a região **X**, podendo ser em função do *pixel* vizinho \mathbf{x}_1 ou \mathbf{x}_2 . Dessa forma, os testes lógicos x_1Y e x_2Y devem resultar zero, e o teste lógico yX_1 ou yX_2 deve retornar 1. O critério de decisão então é dado por:

Se $x_1Y = 0$ e $x_2Y = 0$ e $yX_1 = 1$, ou $x_1Y = 0$ e $x_2Y = 0$ e $yX_2 = 1 \rightarrow \mathbf{y}$ vai para **X** em função de \mathbf{x}_1 ou de \mathbf{x}_2 ;

b. tanto \mathbf{x}_1 como \mathbf{x}_2 vão para a região **Y**. Para tanto, os testes lógicos yX_1 e yX_2 devem resultar zero e os testes lógicos x_1Y e x_2Y devem resultar 1. Neste caso o critério de decisão é dado por:

Se $x_1Y = 1$ e $yX_1 = 0$ e $x_2Y = 1$ e $yX_2 = 0 \rightarrow \mathbf{x}_1$ e \mathbf{x}_2 vão para **Y**;

c. \mathbf{x}_1 ou \mathbf{x}_2 vai para a região **Y** sendo que:

c1. para \mathbf{x}_1 ir para região **Y** então os testes lógicos yX_1 , yX_2 e x_2Y devem resultar zero e o teste lógico x_1Y deve resultar 1, sendo o critério de decisão dado por:

Se $x_1Y = 1$ e $yX_1 = 0$ e $x_2Y = 0$ e $yX_2 = 0 \rightarrow \mathbf{x}_1$ vai para **Y**;

c2. para \mathbf{x}_2 ir para região **Y** então os testes lógicos yX_2 , yX_1 e x_1Y devem resultar zero e o teste lógico x_2Y deve resultar, sendo o critério de decisão dado por:

Se $x_1Y = 0$ e $yX_1 = 0$ e $x_2Y = 1$ e $yX_2 = 0 \rightarrow \mathbf{x}_2$ vai para **Y**.

d. \mathbf{x}_1 ou \mathbf{x}_2 vai para a região **Y** e \mathbf{y} vai para a região **X**, sendo que:

d1. para \mathbf{x}_1 ir para a região **Y** e \mathbf{y} ir para a região **X** em função de \mathbf{x}_2 então os testes lógicos x_2Y e yX_1 devem resultar zero e os testes

lógicos x_1Y e yX_2 devem resultar 1, sendo o critério de decisão dado por:

Se $x_1Y = 1$ e $yX_1 = 0$ e $x_2Y = 0$ e $yX_2 = 1 \rightarrow \mathbf{y}$ vai para **X** em função de \mathbf{x}_2 e \mathbf{x}_1 vai para **Y**;

d2. para \mathbf{x}_2 ir para a região **Y** e \mathbf{y} ir para a região **X** em função de \mathbf{x}_1 então os testes lógicos x_1Y e yX_2 devem resultar zero e os testes lógicos x_2Y e yX_1 devem resultar 1, sendo o critério de decisão dado por:

Se $x_1Y = 0$ e $yX_1 = 1$ e $x_2Y = 1$ e $yX_2 = 0 \rightarrow \mathbf{y}$ vai para **X** em função de \mathbf{x}_1 e \mathbf{x}_2 vai para **Y**.

c) Caso 3

Por fim, no caso 3 o *pixel* de fronteira **y** da região analisada se encontra em contato com dois *pixels* de borda pertencentes a regiões vizinhas distintas, estabelecendo a relação de um para dois (1-2). A Figura 5.10 ilustra um exemplo, onde o *pixel* **y** da região analisada **Y** (região de cor vermelha), representado pelo índice lexicográfico 21, está em contato com dois *pixels* de fronteira pertencentes a duas regiões vizinhas, região **X** (região de cor azul), com *pixel* **x** representado pelo índice 22, e região **Z**, com *pixel* **z** representado pelo índice 27.

0	1	2	3	4	5
6	7	8	9	10	11
12	13	14	15	16	17
18	19	20	21	22	23
24	25	26	27	28	29
30	31	32	33	34	35

Figura 5.10 - Exemplo do Caso 3 onde um *pixel* de fronteira da região analisada se encontra vinculado a dois *pixels* de fronteira pertencentes a regiões vizinhas distintas (relação de um para dois).

Neste caso são calculados então, para os dois pares de *pixels* vinculados, os valores de R_{yY} , R_{yX} , R_{xY} , R_{xX} , R_{yZ} , R_{zY} e R_{zZ} , os quais são usados nos testes lógicos, dados por

$$\text{Se } (R_{xX} > R_{xY}) \text{ e } (R_{yX} \geq R_{yY}) \rightarrow xY = 1, \text{ caso contrário } xY = 0$$

$$\text{Se } (R_{yY} > R_{yX}) \text{ e } (R_{xY} \geq R_{xX}) \rightarrow yX = 1, \text{ caso contrário } yX = 0$$

$$\text{Se } (R_{zZ} > R_{zY}) \text{ e } (R_{yZ} \geq R_{yY}) \rightarrow zY = 1, \text{ caso contrário } zY = 0$$

$$\text{Se } (R_{yY} > R_{yZ}) \text{ e } (R_{zY} \geq R_{zZ}) \rightarrow yZ = 1, \text{ caso contrário } yZ = 0$$

sendo que, $xY = 1$ significa que \mathbf{x} pertence a \mathbf{Y} e $xY = 0$ significa que \mathbf{x} não pertence a \mathbf{Y} , com a mesma definição aplicada para os demais testes.

As seguintes situações podem ocorrer neste caso:

1) Não ocorre mudança entre os *pixels* envolvidos na análise. Dessa forma, \mathbf{y} permanece na região \mathbf{Y} e \mathbf{x} permanece na região \mathbf{X} e \mathbf{z} permanece na região \mathbf{Z} . Portanto, todos os testes lógicos devem resultar zero. O critério de decisão é dado por:

$$\text{Se } xY = 0 \text{ e } yX = 0 \text{ e } zY = 0 \text{ e } yZ = 0 \rightarrow \mathbf{y} \text{ permanece em } \mathbf{Y}, \text{ e } \mathbf{x} \text{ e } \mathbf{z} \text{ permanecem em } \mathbf{X} \text{ e } \mathbf{Z};$$

2) Ocorre mudança entre os *pixels* envolvidos na análise, podendo ocorrer um dos casos:

a. \mathbf{y} pode ir tanto para a região \mathbf{X} , como para a região \mathbf{Z} , o desempate é feito tomando por base o valor do módulo da razão dos logaritmos R_{yX} e R_{yZ} . Para isso, os testes lógicos yX e yZ devem retornar 1 e os testes lógicos zY e xY devem resultar zero. Dessa forma, a seguinte condição deve ser constatada:

$$\text{Se } xY = 0 \text{ e } yX = 1 \text{ e } zY = 0 \text{ e } yZ = 1 \rightarrow \mathbf{y} \text{ pode ir para } \mathbf{X} \text{ ou para } \mathbf{Z}.$$

Enquanto que o critério de decisão é dado por:

Se $R_{yX} < R_{yZ} \rightarrow \mathbf{y}$ vai para **X**;

Se $R_{yX} \geq R_{yZ} \rightarrow \mathbf{y}$ vai para **Z**;

b. tanto **x** como **z** vão para a região **Y**. Para isso, os testes lógicos yX e yZ devem resultar zero e os testes lógicos xY e zY devem resultar 1. O critério de decisão neste caso é dado por:

Se $xY = 1$ e $yX = 0$ e $zY = 1$ e $yZ = 0 \rightarrow$ tanto **x** como **z** vão para **Y**;

c. **x** ou **z** vai para a região **Y**, sendo que:

c1. para **x** ir para a região **Y** então os testes lógicos yX , yZ e zY devem resultar zero e o teste lógico xY deve resultar 1, sendo o critério de decisão dado por:

Se $xY = 1$ e $yX = 0$ e $zY = 0$ e $yZ = 0 \rightarrow \mathbf{x}$ vai para **Y**;

c2. para **z** ir para a região **Y** então os testes lógicos xY , yX e yZ devem resultar zero e o teste lógico zY deve resultar 1, sendo o critério de decisão dado por:

Se $xY = 0$ e $yX = 0$ e $zY = 1$ e $yZ = 0 \rightarrow \mathbf{z}$ vai para **Y**;

d. **y** vai para a região **X** ou para a região **Z**, sendo que:

d1. para **y** ir para a região **X** então os testes lógicos xY , yZ e zY devem resultar zero e o teste lógico yX deve resultar 1, sendo o critério de decisão dado por:

Se $xY = 0$ e $yX = 1$ e $zY = 0$ e $yZ = 0 \rightarrow \mathbf{y}$ vai para **X**;

d2. para **y** ir para a região **Z** então os testes lógicos xY , yX e zY devem retornar zero e o teste lógico yZ deve resultar 1, sendo o critério de decisão dado por:

Se $xY = 0$ e $yX = 0$ e $zY = 0$ e $yZ = 1 \rightarrow \mathbf{y}$ vai para **Z**;

e. Ocorre mudança entre os *pixels* envolvidos na análise. Neste caso, **x** ou **z** vai para a região **Y** e **y** vai para a região **X** ou **Z**, sendo que:

e1. para **x** ir para a região **Y** e **y** ir para a região **Z** então os testes lógicos xY e yZ devem resultar 1 e os testes lógicos yX e zY devem resultar zero. O critério de decisão para isso é dado por:

Se $xY = 1$ e $yX = 0$ e $zY = 0$ e $yZ = 1 \rightarrow \mathbf{y}$ vai para **Z** e **x** vai para **Y**;

e2. para **z** ir para a região **Y** e **y** ir para a região **X** então os teste lógicos xY e yZ devem resultar zero e os testes lógicos yX e zY devem resultar 1. O critério de decisão para isso é dado por:

Se $xY = 0$ e $yX = 1$ e $zY = 1$ e $yZ = 0 \rightarrow \mathbf{y}$ vai para **X** e **z** vai para **Y**.

Os *pixels* de bordas de regiões vizinhas que são alterados no processo de análise de bordas, ou seja, aqueles que passarem para região analisada são armazenados durante o processo no vetor de *pixels* alterados e não participam mais do processo de ajuste de borda. Da mesma forma, a matriz de segmentação é atualizada a cada alteração ocorrida nas bordas das regiões envolvidas na análise. Além disso, a cada alteração de *pixel* também é realizada uma atualização dos dados contidos na estrutura que armazena os dados das regiões. O processo de análise de bordas termina quando não houver mais elementos (*ld's*) no vetor de sementes.

O resultado da análise de bordas e o ajuste decorrente deste processo podem, dependendo da posição do *pixel* de fronteira da região analisada e da disposição das regiões vizinhas, ocasionar a desconexão de *pixels* pertencentes à região analisada. Cabe mencionar, que neste caso o *pixel* é considerado desconectado se este não estiver ligado a região a que pertence segundo o critério de conectividade quatro. A Figura 5.11 apresenta na imagem de *ld's* exemplos de desconexão de *pixels*, que podem ocorrer após a análise de bordas, para os casos 2 e 3.

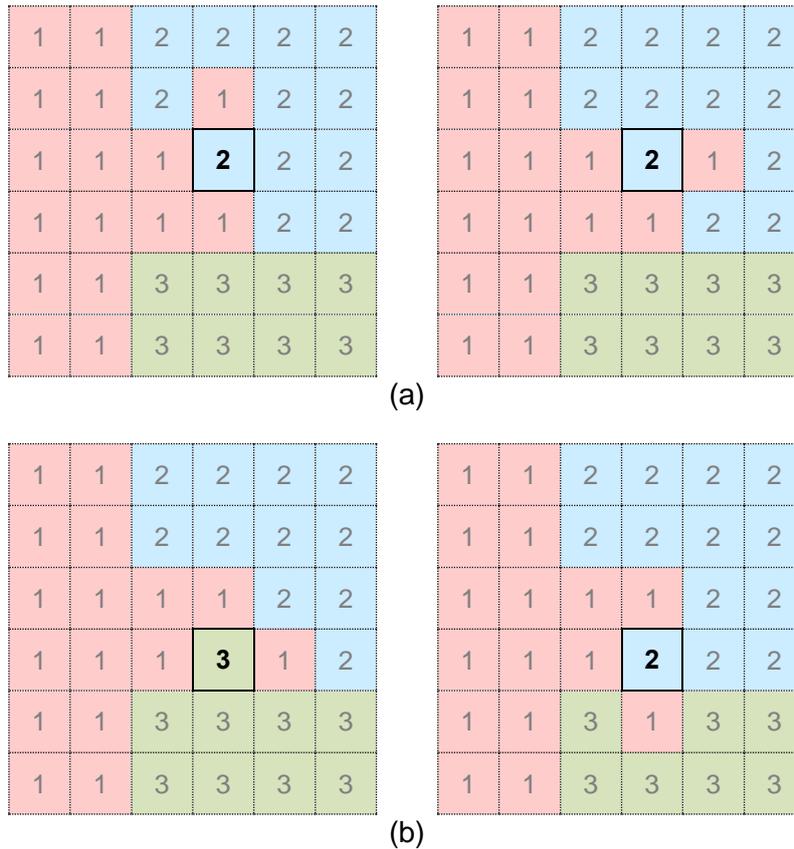


Figura 5.11 - Exemplos de desconexão de pixels decorrente da análise de bordas, onde o pixel de borda (destacado), da região analisada representada pelo Id igual a 1 (cor vermelha), se encontrava anteriormente em contato com: (a) dois pixels de borda pertencentes a uma única região vizinha representada pelo Id igual a 2 (cor azul); e, (b) dois pixels de borda pertencentes a regiões vizinhas distintas representadas pelos Id 's iguais a 2 e 3 (cores azul e verde).

Para o PolSeg os *pixels* desconectados, embora possuam a mesma identificação da região analisada, devem ser tratados como novas regiões. Isto se deve porque estes *pixels* podem originar regiões completamente desconectadas da região da qual tiveram origem após novos ciclos de processamento da segunda etapa. A Figura 5.12 ilustra um exemplo de geração de possíveis regiões desconectadas da região original após dois ciclos de processamento da segunda etapa.

Devido a isso, logo após a análise de bordas, os *pixels* desconectados de suas regiões originais recebem novos Id 's, passando dessa forma a representar novas regiões. Estas alterações são gravadas na imagem de Id 's (Figura 5.13),

a qual, na sequência, é usada para atualizar a estrutura que armazena os dados das regiões segmentadas.

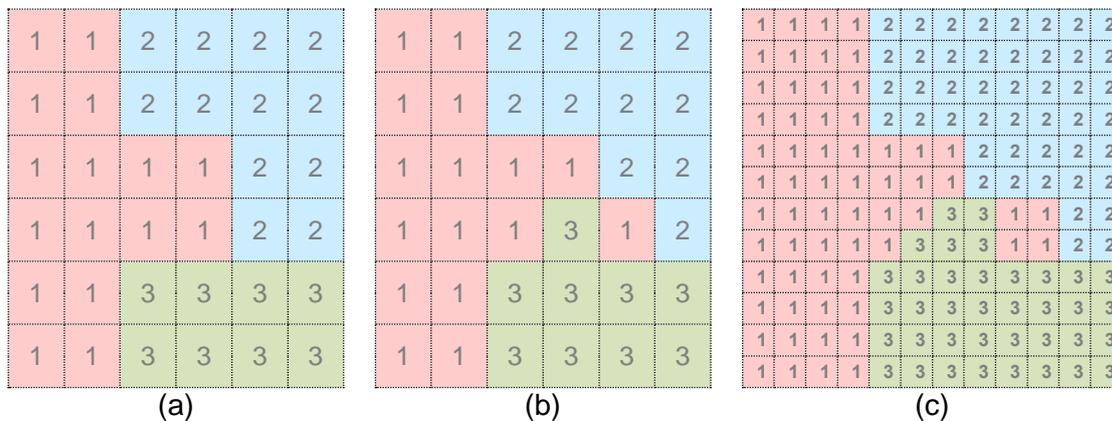


Figura 5.12 - Exemplo de geração de região desconectada de sua região original devido ao processo de análise de bordas: (a) imagem inicial; (b) imagem após um ciclo de processamento da segunda etapa; e, (c) imagem após dois ciclos de processamento da segunda etapa.

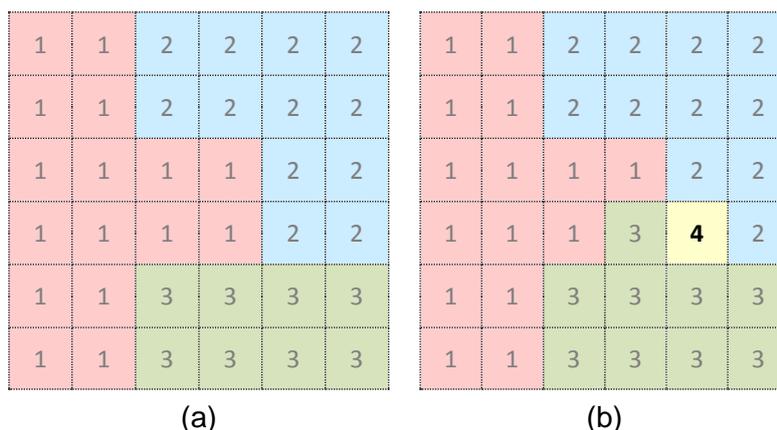


Figura 5.13 - Geração de nova região a partir de *pixels* isolados de sua região original devido ao processo de análise de bordas: (a) imagem inicial; e, (b) imagem após um ciclo de processamento da segunda etapa com nova região gerada.

Ao término do processamento realizado pelo módulo de análise de bordas são gravados no relatório de processamento (arquivo *processamento.txt*): a dimensão em coluna e linha da imagem de *Id's*; o número de regiões; a dimensão média de cada região (em *pixels*); e, o tempo de processamento consumido no módulo.

5.2.2.3. Análise de homogeneidade

O módulo de análise de homogeneidade tem por finalidade identificar as regiões que devem sofrer novo processo de segmentação por crescimento de regiões.

Este processo se faz necessário, pois a análise de bordas pode comprometer a homogeneidade estatística das regiões geradas na segmentação. Isto ocorre porque, durante o processo de ajuste de bordas, *pixels* pertencentes às outras regiões podem ser agrupados as regiões analisadas alterando sua estatística.

O procedimento adotado pelo PolSeg para testar a homogeneidade das regiões contidas em uma imagem segmentada submetida a um determinado nível de compressão é o mesmo usado no SegSAR (SOUSA JUNIOR, 2005). Cabe lembrar que, para dados SAR, tal algoritmo processa somente dados no formato de intensidade e realiza o teste de homogeneidade tomando por base a modelagem estatística adotada para este tipo de dado. Sendo assim, a fim de adequar o uso desta abordagem no PolSeg, são usados na análise de homogeneidade somente os dados provenientes dos elementos da diagonal principal da matriz de covariância (formato intensidade).

O algoritmo SegSAR testa a homogeneidade de uma região por meio da comparação do valor do coeficiente de variação (cv) da região com um coeficiente de variação crítico tabelado (cv_{crit}) para o nível de compressão considerado. O valor de coeficiente de variação para uma determinada região X é calculado por

$$cv_X = \frac{s_X}{\bar{X}} \quad (5.35)$$

onde, \bar{X} é a média simples dos valores dos *pixels* contidos na região X e s_X é o desvio padrão da região.

Por sua vez, os valores de cv_{crit} tabelados foram obtidos por Sousa Junior (2005) por meio do cálculo sobre uma distribuição de cv , obtida através de simulações de uma variável aleatória possuindo distribuição *Gama* ($\Gamma(nel, nel/\mu)$), para diferentes valores de nel e diferentes tamanhos de regiões, para os níveis de confiança de 99,9%, 99,5%, 99,0%, 95,0%, 90,0%, 85,0% e 80,0%. A obtenção dos valores de cv_{crit} a partir das tabelas criadas para cada nível de significância é feita por meio do nel_C e da quantidade de *pixels* N da região. Uma região X é considerada homogênea, ao nível de confiança $1 - \alpha$, se

$$cv_X \leq cv_{crit} \quad (5.36)$$

Para realizar a análise de homogeneidade o PolSeg cria para cada canal em intensidade da imagem que esta sendo processada, uma matriz onde são armazenados em colunas para cada região segmentada, o Id , a quantidade de *pixels*, a intensidade média, o valor calculado do s_X e o valor de cv_{crit} obtido da tabela. Estes dados além de serem usados no processamento são armazenados no relatório de análise de homogeneidade em arquivo no formato .txt, gravado no caminho de saída definido pelo usuário.

As colunas referentes aos valores de cv calculados para cada canal em intensidade da imagem em processamento são comparadas com a coluna contendo o cv_{crit} usando o teste da Equação (5.36). As regiões que forem aprovadas no teste em todos os canais em intensidade são consideradas homogêneas. Aquelas que forem reprovadas em pelo menos um teste são consideradas heterogêneas devendo ser submetida a um novo processo de segmentação. Os Id 's destas regiões são então armazenados em um vetor para serem usados no módulo de segmentação de regiões heterogêneas. A tabela contendo os dados usados na análise é então “zerada”, liberando desta forma o espaço em memória RAM usado para armazená-la.

Ao término do processamento são armazenados no relatório de processamento o número de regiões homogêneas, o número de regiões heterogêneas e o tempo de processamento consumido pelo módulo.

5.2.2.4. Segmentação de regiões heterogêneas

O módulo de segmentação de regiões heterogêneas tem por finalidade realizar a segmentação por crescimento de regiões das regiões heterogêneas identificadas pelo módulo de análise de homogeneidade. Este processamento se faz necessário para gerar dentro da região considerada heterogênea novas regiões que possuam consistência estatística de acordo com o nível de confiança adotado.

No processamento executado neste módulo as regiões heterogêneas são segmentadas individualmente uma a uma. A identificação destas regiões é obtida no vetor de *Id's* gerado pelo módulo de análise de homogeneidade, o qual vai sendo esvaziado a cada região processada.

A segmentação ocorre de forma similar ao processo já discutido no módulo de segmentação por crescimento de regiões, por meio de testes estatísticos do tipo *pixel* com *pixel* e região com *pixel*. Para isso, é criado para cada região heterogênea um vetor de sementes com os índices lexicográficos dos *pixels* que a compõe. A única diferença entre o processamento realizado por este módulo quando comparado ao processamento realizado com o módulo de segmentação da primeira etapa diz respeito ao limite de crescimento para as regiões semeadas a partir dos *pixels* sementes. Enquanto o crescimento de regiões da primeira etapa é limitado a dois critérios de parada, definidos a partir do número de ciclos de crescimento ou baseado no teste estatístico, o crescimento de regiões deste módulo é limitado, além dos dois critérios mencionados, à área da região heterogênea que esta sendo segmentada.

A limitação do processo de crescimento de regiões tomando por base a área da região heterogênea (Figura 5.14) é feita se atribuindo o valor zero na imagem de *Id's* a área região que será segmentada. Antes de cada ciclo de crescimento de regiões é verificado para os *pixels* candidatos a crescimento se sua posição na imagem de *Id's* corresponde ao valor zero. Os *pixels* candidatos que satisfizerem esta condição são então submetidos ao processo de crescimento de regiões. Cabe mencionar, que o *Id* da região retirado do

vetor de regiões heterogênea serve somente para identificar os *pixels* da área da região que deve ser segmentada e não para identificar quaisquer das novas regiões que serão geradas no processo de segmentação. Para a identificação destas regiões o algoritmo verifica qual foi o último *ld* usado e da continuidade a sequência de números usados para gerar as novas regiões.

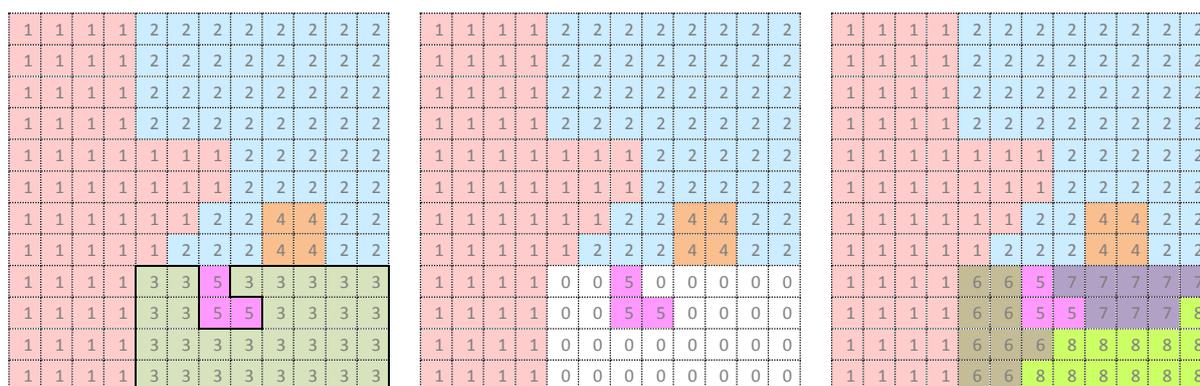


Figura 5.14 - Limitação do processo de crescimento de regiões no módulo de segmentação de regiões heterogêneas: (a) imagem de *ld*'s com região heterogênea de *ld* igual a 3 destacada (delimitada por linha cheia); (b) atribuição de zeros a área da região heterogênea; e, (c) geração de novas regiões de *ld*'s iguais a 6, 7 e 8 na área correspondente a região heterogênea submetida a segmentação por crescimento de regiões.

O fim do processamento ocorre quando o vetor contendo os *ld*'s das regiões heterogêneas estiver vazio. Quando isto ocorre, a estrutura que armazena os dados das regiões é atualizada retirando-se desta os dados das regiões que foram re-segmentadas, as quais deixam de existir por terem sido substituídas por novas regiões.

Ao término do processamento são armazenadas no relatório de processamento a dimensão em coluna, linha e canal da imagem segmentada, o número equivalente de *looks* calculado para o nível de compressão, o número de regiões criadas na segmentação das regiões heterogêneas, o número total de regiões e o tempo de processamento consumido pelo módulo.

5.2.2.5. Agrupamento de regiões

O módulo de agrupamento de regiões tem por finalidade realizar o agrupamento de regiões adjacentes que possuam características estatísticas

similares. Este processamento se faz necessário porque durante o processo de segmentação de regiões heterogêneas podem ser gerados novos segmentos que sejam estatisticamente iguais aos seus vizinhos. Dessa forma, a finalidade do agrupamento de regiões é realizar, caso seja possível, o agrupamento destes segmentos a suas regiões vizinhas de modo a obter uma redução do número de regiões.

O agrupamento de regiões no PolSeg pode ser entendido como um processo de crescimento de regiões a partir de uma região analisada. O vetor de sementes neste caso é obtido a partir das informações de *Id's* das regiões armazenado na estrutura de dados das regiões, as quais são copiadas para tal vetor. O módulo de agrupamento de regiões, da mesma forma que o módulo de crescimento de regiões, foi desenvolvido para possuir dois critérios de parada, o qual pode ser definido a partir do número de ciclos de agrupamento ou baseado no teste estatístico.

O teste de agrupamento realizado neste módulo é do tipo região com região e é feito considerando o número de *pixels* independentes das regiões envolvidas, os quais são calculados multiplicando-se a quantidade de *pixels* existentes nas regiões pelo nel_c . Desse modo, considerando **X** uma região que possui N_1 *pixels*, e **Y** uma região que possui N_2 *pixels*, os números de *pixels* independentes dessas regiões serão calculados respectivamente por

$$n = N_1 \cdot nel_c \quad (5.37)$$

$$m = N_2 \cdot nel_c \quad (5.38)$$

onde, n é o número de *pixels* independentes da região **X** e m é o da região **Y**.

O processo de agrupamento se inicia pelo primeiro elemento contido no vetor de sementes, o qual é retirado do vetor diminuindo sua dimensão. As regiões que vão sendo agrupadas também vão sendo retiradas deste vetor, e gravadas em um vetor de regiões alteradas juntamente com a região analisada. Este vetor tem por finalidade armazenar os *Id's* das regiões que não podem ser mais agrupadas por outras regiões. Após a seleção de cada região analisada

ou após cada ciclo de crescimento é verificado se os *Id's* das regiões candidatas a agrupamento pertencem ao vetor de regiões alteradas. Os *Id's* das regiões que se encontrarem neste vetor são eliminados evitando que estas regiões participem do processo. As regiões candidatas são então testadas estatisticamente uma a uma em relação à região analisada. A região que passa no teste recebe o *Id* da região analisada, o qual é registrado diretamente na imagem de *Id's*. Quando isto ocorre é feita a atualização da estrutura que armazena os dados das regiões, registrando para região analisada a nova quantidade de *pixels* e o valor médio recalculado da sua matriz de covariância.

O fim do processamento ocorre quando o vetor de sementes contendo os *Id's* das regiões estiver vazio. Quando isto ocorre, a estrutura que armazena os dados das regiões é atualizada retirando-se desta os dados das regiões que foram agrupadas, as quais deixam de existir.

Ao término do processamento são armazenadas no relatório de processamento a dimensão em coluna, linha e canal da imagem segmentada, o número de regiões agrupadas, o número de regiões e o tempo de processamento consumido pelo módulo.

5.2.2.6. Agrupamento de *pixels* isolados

O módulo de agrupamento de *pixels* isolados tem por finalidade realizar o agrupamento, no nível de compressão igual a um, dos *pixels* que se encontram completamente isolados dentro de uma região, os quais correspondem a regiões formadas por quatro *pixels* na imagem original. Este processamento é realizado para eliminar possíveis ruídos e diminuir a quantidade de regiões na imagem segmentada antes dela ser submetida a terceira etapa de processamento.

Caso o usuário decida sair e salvar os dados processados em uma fase intermediária do processamento antes de chegar ao nível de compressão igual a um este módulo não é acionado. Neste caso, o pixel isolado será eliminado na terceira fase de processamento pelo módulo de área mínima.

O processo de agrupamento de *pixels* isolados pode ser entendido basicamente como um processo de filtragem. Isto se deve porque o algoritmo analisa a situação de cada região formada por apenas um *pixel* a fim de verificar, usando a informação de contexto, se o mesmo deve ou não ser agrupado (Figura 5.15).

1	1	1	1	2	2	2	2	2	2	2	2
1	1	1	1	2	2	2	2	2	2	2	2
1	1	1	1	2	2	2	2	10	2	2	2
1	1	1	1	11	2	2	2	2	2	2	2
1	1	1	1	1	1	1	2	2	2	12	2
1	1	1	1	1	1	1	2	2	2	2	2
1	1	1	1	1	1	2	2	4	4	2	2
1	1	1	1	1	2	2	13	4	4	2	2
1	1	1	1	6	6	5	7	7	7	7	7
1	1	1	1	6	6	5	5	7	7	7	8
1	1	1	1	6	6	6	8	8	8	8	8
1	1	1	1	6	6	8	8	8	8	8	8

Figura 5.15 - Situações de contexto para regiões representadas por somente um *pixel*: região representada como *pixel* isolado (*Id* igual a 10 e 12) e região representada por um *pixel* adjacente a outras regiões (*Id* igual 11 e 13).

Para realizar o agrupamento de *pixels* isolados o PolSeg gera um vetor contendo os *Id*'s das regiões que possuem somente um *pixel*, a partir da estrutura que armazena os dados das regiões. Os elementos deste vetor são percorridos um a um na imagem de *Id*'s a fim de verificar se os seus *pixels* vizinhos pertencem a uma única região. Quando isto ocorre o *pixel* é considerado isolado e tem seu *Id* armazenado no vetor de regiões incorporadas. Neste caso, tanto a imagem de *Id*'s como a estrutura que armazena os dados das regiões são atualizadas. Para isso, o *pixel* isolado na imagem de *Id*'s tem seu *Id* substituído pelo identificador da região que o envolve. Enquanto, os dados de quantidade de *pixels* e média dos elementos da matriz de covariância da região que recebeu o *pixel* isolado na estrutura que armazena os dados das regiões são recalculados e atualizados.

O fim do processamento ocorre quando todos os elementos do vetor contendo os *Id's* das regiões unitárias forem analisados. Quando isto ocorre, a estrutura que armazena os dados das regiões é atualizada retirando-se desta os dados das regiões que foram incorporadas, as quais deixam de existir. Além disso, o vetor usado para armazenar as regiões com um *pixel* é “zerado” para liberar espaço em memória RAM.

Ao término do processamento são armazenadas no relatório de processamento a dimensão em coluna, linha e canal da imagem segmentada, o número de regiões agrupadas, o número total de regiões, o tempo de processamento consumido pelo módulo e a dimensão média dos segmentos em *pixels*.

5.2.2.7. Interação com o usuário

O módulo de interação com o usuário tem por finalidade permitir que o usuário acompanhe o andamento do processamento para verificar se os resultados obtidos estão sendo os esperados para a sua aplicação. Para isso é disponibilizada uma interface gráfica (Figura 5.16) que permite analisar os resultados parciais obtidos a cada nível de compressão.

As informações apresentadas por esta interface podem ser usadas para que o usuário possa fazer uma análise antes de tomar uma decisão a respeito do processamento que está sendo executado. Esta interface permite que o usuário possa visualizar os resultados do processamento em forma de imagens, selecione as opções de visualização, verifique os resultados numéricos da segmentação e altere parâmetros, selecione a decisão que deseja tomar e decida se quer continuar vendo os resultados intermediários. A interface gráfica do módulo de interação com o usuário é discutida com mais detalhes no Anexo B.

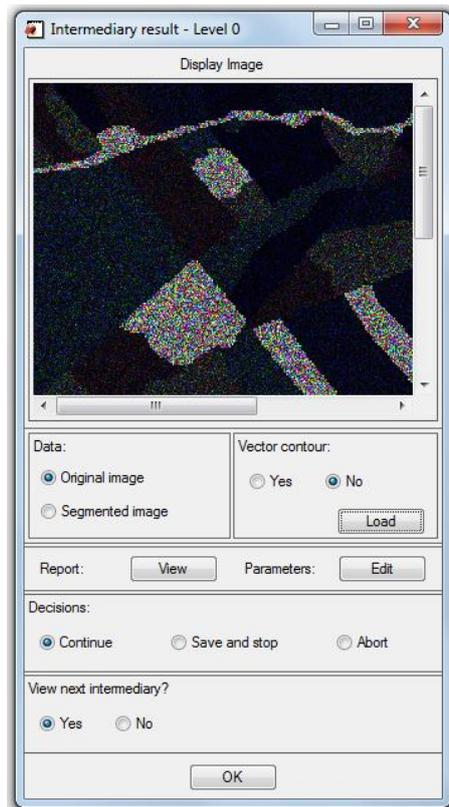


Figura 5.16 - Interface de do módulo interação com o usuário.

Ao término do processo de interação com o usuário o algoritmo armazena no relatório de processamento decisões tomadas pelo usuário quanto a alteração ou não dos parâmetros de processamento. Dessa forma, são armazenados no relatório, os valores referentes ao tipo de conectividade, o nível de confiança e o limite de ciclos de crescimento para a segmentação, e o nível de confiança e o limite de ciclos de agrupamento para o agrupamento.

5.2.2.8. Descomprime para o nível zero

O módulo de processamento descomprime para o nível zero tem por finalidade realizar a descompressão dos dados obtidos na segunda etapa de processamento para o nível de compressão igual a zero quando o usuário optar, na interface de visualização de dados, parar o processamento em um nível de compressão intermediário. Este processamento se faz necessário para

deixar os resultados obtidos na segunda etapa de processamento prontos para a próxima etapa.

A descompressão para o nível zero é executada de forma similar a que é executada no módulo de descompressão em um nível. Nesse processo somente a imagem de ld 's é realmente submetida ao o processo de descompressão. As informações da matriz de covariância, necessárias para serem usadas na terceira etapa de processamento serão obtidas diretamente a partir da restauração em uma variável temporária dos dados gravados em disco rígido na geração da matriz de covariância.

No processo de descompressão da imagem para o nível zero cada *pixel* da imagem no nível de compressão c considerado passa a ser representado na por 2^{2c} *pixels*. Por sua vez, a obtenção da dimensão em linha e coluna no nível zero da imagem de ld 's comprimida é obtida por

$$col_0 = col_c \cdot 2^c \quad (5.39)$$

$$lin_0 = lin_c \cdot 2^c \quad (5.40)$$

onde, col_0 e lin_0 correspondem a dimensão em coluna e linha da imagem no nível de compressão igual a 0 e col_c e lin_c correspondem a dimensão da imagem comprimida no nível de compressão c .

Cabe lembrar que a imagem descomprimida para o nível de compressão zero pode possuir colunas ou linhas a mais adicionada para adequação ao processo de compressão por critério de pirâmides. Dessa forma, caso existam, estas linhas ou colunas são removidas da imagem de ld 's. Para isso a imagem de ld 's, após ser descomprimida para o nível de compressão igual a zero sofre um redimensionamento tomando por base a dimensão em linha e coluna da imagem de entrada.

Após o redimensionamento da imagem de ld 's é realizada a atualização da estrutura que armazena os dados das regiões. Nesta atualização são

registrados para cada região sua nova quantidade de *pixels* e recalculados os valores médios das matrizes de covariância.

Ao término do processamento são armazenadas no relatório de processamento a dimensão em coluna, linha e canal da imagem segmentada, o número de regiões, o tempo de processamento consumido pelo módulo e a dimensão média dos segmentos em *pixels*.

Conforme mencionado anteriormente na descrição do bloco *OUTPUT FILES*, da interface de entrada de dados e parâmetros, o PolSeg fornece a opção de armazenar os resultados dos processamentos intermediários realizados na segunda etapa em disco. Isto ocorre quando o usuário seleciona no início do processamento na interface de entrada a opção *Intermediary Files/Save/Yes*. Caso esta opção tenha sido selecionada, os resultados da segunda etapa, imagem de *Id's*, imagem de média de intensidade dos segmentos e arquivo de dados das regiões, são armazenados no diretório *result_interm* criado no caminho indicado pelo usuário no início do processamento.

5.2.3. Terceira etapa de processamento

A terceira etapa é constituída basicamente de dois módulos: verificação de área mínima e saída de dados, os quais são descritos com mais detalhes a seguir.

5.2.3.1. Verificação de área mínima

O módulo de verificação de área mínima tem por finalidade identificar e eliminar regiões com área menor, em termos de quantidade de *pixel*, que a área definida pelo usuário no início do processamento. Este processamento se faz necessário para eliminar segmentos pequenos indesejáveis e ou que podem ser desconsiderados para uma determinada aplicação.

Para realizar a eliminação dos segmentos pequenos, as regiões que possuem a quantidade de *pixels* abaixo do limiar estabelecido são identificadas e seus *Id's* são armazenados em um vetor. Esta identificação é feita tomando por

base a informação contida no vetor de quantidade de *pixels* da estrutura que armazena os dados das regiões. As regiões pequenas contidas no vetor são então analisadas uma a uma a fim de determinar qual região vizinha adjacente deve agrupá-la. Nesse processo, pode acontecer que a região pequena analisada já tenha sido agrupada em uma oportunidade anterior por outra região pequena, passando a possuir por este motivo uma quantidade de *pixel* maior que o limiar estabelecido. Portanto, para evitar esta situação o algoritmo verifica se a quantidade de *pixels* da região pequena analisada realmente está abaixo do limiar. Quando isto não ocorre uma nova região pequena é selecionada para análise. Por sua vez, caso seja verificado que a região é realmente pequena são estabelecidas relações de vizinhança entre a região pequena e as regiões vizinhas adjacentes, para as quais são calculados os valores do logaritmo da razão de verossimilhança Q que dependendo da ordem p da matriz pode ser dada por

$$Q = \text{mod}\left(\ln(F^*)\right) = \text{mod}\left(\ln\left(\frac{\mathbf{X}}{\mathbf{Y}}\right)\right) \text{ para } p = 1, \text{ ou} \quad (5.41)$$

$$Q = \text{mod}\left(\ln\left(\lambda_{w_c(L,\Sigma)}\right)\right) = \text{mod}\left(\ln\left(\frac{|\mathbf{X}|^n |\mathbf{Y}|^m}{|\mathbf{Z}|^{n+m}}\right)\right) \text{ para } p \neq 1 \quad (5.42)$$

onde $\text{mod}(\cdot)$ representa o módulo, \mathbf{X} e \mathbf{Y} são respectivamente as matrizes de covariâncias média da região vizinha e da região pequena, \mathbf{Z} é dado pela Equação (2.29).

O menor valor de Q indica a região vizinha que deve agrupar a região pequena. Quando isto ocorre é realizada uma atualização da imagem de *Id*'s, onde os *Id*'s dos *pixels* da região pequena são substituídos pelo *Id* da região vizinha. Além disso, após a realização de cada agrupamento também é realizada uma atualização dos dados da região vizinha contidos na estrutura que armazena os dados das regiões.

O fim do processamento ocorre quando todos os *Id*'s contidos no vetor de regiões pequenas tiverem sido analisados e incorporados por outras regiões.

Nesse caso, a estrutura que armazena os dados das regiões é atualizada retirando-se desta os dados das regiões pequenas, as quais deixam de existir por terem sido agrupadas por uma de suas regiões vizinhas. Além disso, o vetor que armazena os *Id's* das regiões pequenas é eliminado a fim de liberar espaço em memória RAM.

Ao término do processamento do módulo são armazenadas no relatório de processamento a dimensão em coluna, linha e canal da imagem segmentada, o número de regiões pequenas agrupadas, o número total de regiões, o tempo de processamento consumido pelo módulo e a dimensão média dos segmentos em termos de *pixels*.

5.2.3.2. Saída de dados

O módulo de saída de dados tem por finalidade armazenar os resultados finais do processo de segmentação obtidos após a sequência envolvendo a primeira, segunda e terceira etapas de processamento. Estes resultados são armazenados no caminho de saída informado pelo usuário no início do processamento.

Como saída final do algoritmo são geradas as imagens de *Id's* dos segmentos e a imagem de intensidade média dos segmentos, no formato de arquivo *.tif*, e o arquivo de dados das regiões, em formato *.txt*. Além disso, são gerados os arquivos, em formato *.txt*, do relatório de processamento contendo todas as informações a respeito dos resultados obtidos em cada módulo de processamento executado e do relatório de análise de homogeneidade contendo os dados de homogeneidade das regiões obtidos a cada nível de compressão.

6 AVALIAÇÃO DO ALGORITMO POLSEG COM IMAGENS SIMULADAS

O presente capítulo tem por finalidade apresentar e discutir alguns resultados obtidos da aplicação dos segmentadores PolSeg e SegSAR sobre diferentes imagens SAR, a fim de investigar o potencial de uso do primeiro algoritmo. A avaliação foi realizada com imagens PolSAR simuladas com *1-look* e tem por objetivo analisar e comparar os algoritmos PolSeg e SegSAR sob condições ideais, isto é, supondo que os pixels de uma dada região, caracterizados por matrizes de covariância, são independentes e identicamente distribuídos segundo uma distribuição *Wishart* complexa escalonada ($W_E(L, \Sigma)$). As imagens simuladas possuem 29 regiões e foram obtidas seguindo a metodologia descrita no Capítulo 4.

Este capítulo está dividido em três seções. A primeira apresenta a análise dos resultados de segmentações realizadas com dados univariados polarizados em intensidade, e tem por objetivo comparar o desempenho dos algoritmos PolSeg e SegSAR sob as condições em que o SegSAR com modelo *cartoon* foi desenvolvido. Com isto procurar-se-á analisar a importância da correta modelagem e dos testes estatísticos utilizados pelo PolSeg, uma vez que este algoritmo é totalmente concebido para testes entre distribuições *Gama* ($\Gamma(L, \beta)$), enquanto que o SegSAR utiliza também teste-t e limiares de similaridade.

Na segunda seção duas funcionalidades do PolSeg são utilizadas: a segmentação através da matriz de covariância complexa, e a segmentação através de somente os elementos da diagonal principal desta matriz. Os resultados são também comparados com os resultados obtidos pelo SegSAR utilizando os três canais de intensidade. O objetivo desta seção é avaliar o desempenho do PolSeg na segmentação de dados polarizados em intensidade e polarimétricos, a fim de verificar a relevância da informação adicional de fase contida neste último. Também tem por objetivo analisar se o uso da modelagem estatística mais rigorosa do PolSeg é capaz de gerar resultados consistentes quando comparados com os obtidos na aplicação do SegSAR.

Ainda na segunda seção é apresentada a análise da segmentação de dados polarimétricos duais, com o objetivo de verificar se o uso de apenas duas polarizações na matriz de covariância é suficiente para a geração de resultados consistentes e se a adição de mais uma polarização gera ganhos significativos na segmentação. Para tal verificação, os resultados das segmentações baseadas em matrizes de covariância de ordem 2, formadas pela combinação das polarizações hh , hv e vv , são comparados entre si e com os resultados da segmentação baseada em matrizes de covariância de ordem 3.

A terceira e última seção apresenta uma síntese com os resultados obtidos da segmentações realizadas com o PolSeg e SegSAR dos dados SAR simulados. Esta síntese tem por finalidade ressaltar os resultados obtidos com o primeiro algoritmo e salientar qual a combinação de imagens foi capaz de gerar uma segmentação mais próxima à imagem de referência.

6.1. Resultados obtidos na segmentação de dados univariados em intensidade

Antes de realizar as segmentações com o SegSAR foi preciso definir para este algoritmo o valor do parâmetro de segmentação relativo ao limiar de similaridade (*Similarity*), o qual para dados SAR é expresso em dB . Este parâmetro define o limiar de similaridade para os testes de crescimento e agrupamento de regiões e é alterado a cada nível de compressão, conforme descrito em Sousa Junior (2005). O valor sugerido ao usuário para este parâmetro é $1,0\ dB$, o que significa que duas regiões são consideradas similares se a diferença entre suas médias, calculadas em dB , não exceder a $1,0\ dB$. Como o parâmetro está diretamente ligado às características de homogeneidade da imagem SAR, foi realizado um processamento preliminar com o SegSAR para verificar qual seria o valor de similaridade mais adequado para ser usado no processamento dos dados simulados nas polarizações hh , hv e vv . Para isso, foi adotada uma das imagens simuladas como referência, a qual foi submetida a uma série de segmentações no SegSAR variando o valor de similaridade de $0,1$ a $2,0\ dB$, com nível de compressão igual a cinco, nível de confiança de $95,0\%$ e área mínima de $15\ pixels$. Os resultados do

processamento foram então submetidos a uma análise usando as medidas de desempenho desenvolvidas por Delves et al. (1992), para verificar qual valor de similaridade apresentou melhores resultados quantitativos. Por meio desta análise, decidiu-se utilizar os valores de similaridade de 0,8, 0,9 e 0,6 dB para as polarizações hh , hv e vv , respectivamente.

6.1.1. Imagens na polarização hh

A Figura 6.1(a) apresenta um exemplo de uma imagem simulada na polarização hh , em intensidade, e a Figura 6.1(b) a sua respectiva imagem de referência, em que os níveis de cinza das regiões representam as médias das regiões nesta polarização.

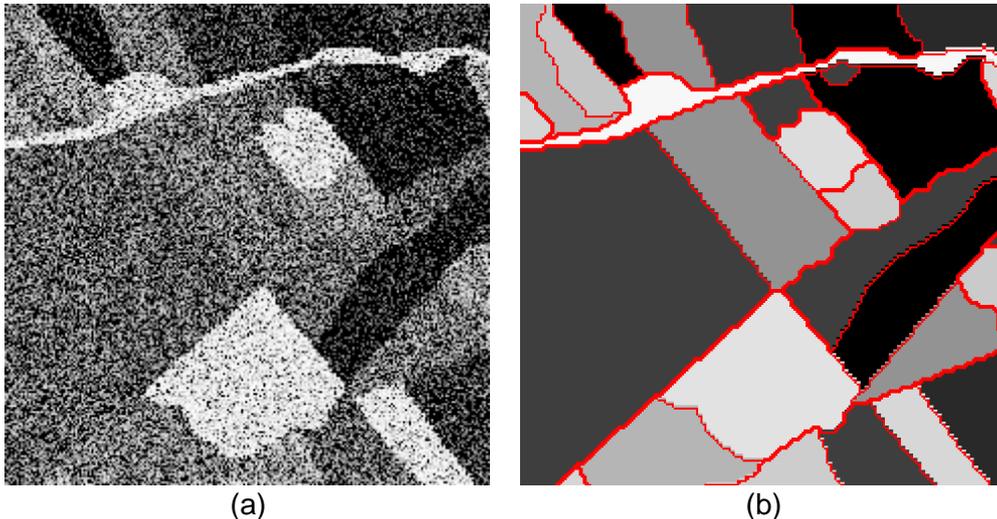


Figura 6.1 - (a) imagem simulada na polarização hh e (b) Imagem de referência, com os contornos e as médias em intensidade das 29 regiões.

A Figura 6.2 e Figura 6.3 apresentam os resultados, em termos de números de regiões e tempo de processamento, da aplicação dos algoritmos PolSeg e SegSAR com as imagens de polarização hh , para diferentes valores de nível de compressão máximo escolhido pelo usuário, e diferentes níveis de confiança.

Percebe-se na Figura 6.2(a), que, para o PolSeg, a quantidade de regiões geradas na segmentação diminui com o aumento do nível de confiança adotado na segmentação. Para o SegSAR (Figura 6.2(b)) este comportamento é observado a partir do nível de compressão maior que três. Na Figura 6.3 (a)

pode-se verificar que o tempo de processamento do PolSeg a partir do nível de compressão maior ou igual a cinco tende a diminuir com o aumento do nível de confiança. Já na Figura 6.3(b) percebe-se que o tempo de processamento do SegSAR oscilou de valores altos a valores baixos a cada nível de compressão.

Da comparação dos resultados apresentados nas Figura 6.2 e Figura 6.3 percebe-se que o PolSeg obteve um resultado superior ao obtido pelo SegSAR, no sentido que o PolSeg foi capaz de gerar um número de regiões mais próximo ao número de regiões contidos na imagem de referência com tempo de processamento significativamente inferior ao obtido com o SegSAR.

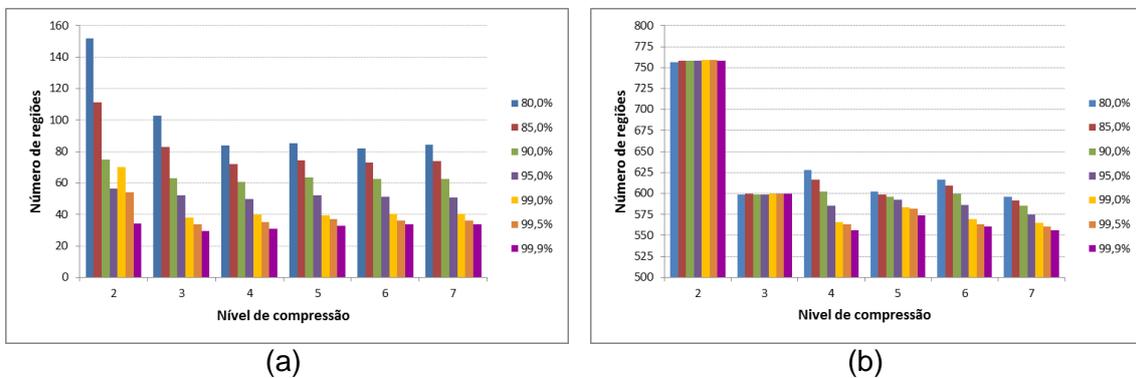


Figura 6.2 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a quantidade de regiões geradas nas segmentações das imagens simuladas com polarização *hh*.

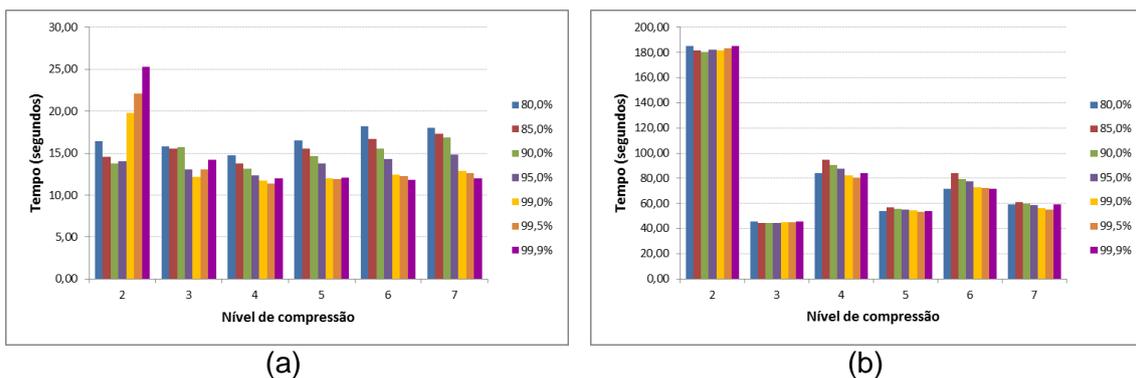


Figura 6.3 - Desempenho do (a) PolSeg e (b) SegSAR, segundo o tempo de processamento das segmentações das imagens simuladas com polarização *hh*.

Os resultados das medidas de ajuste obtidos na aplicação dos algoritmos PolSeg e SegSAR com as imagens de polarização *hh* são apresentados na Figura 6.4 à Figura 6.8. Nestas figuras as curvas ilustradas nos gráficos representam os valores médios das medidas de ajuste, definidas na

Seção 3.3.1, para cada nível de confiança ao variar o nível de compressão selecionado pelo usuário. Estes valores médios foram calculados sobre as segmentações de 100 imagens simuladas. Os valores numéricos usados para gerar os gráficos apresentados nestas figuras podem ser encontrados no Anexo A.

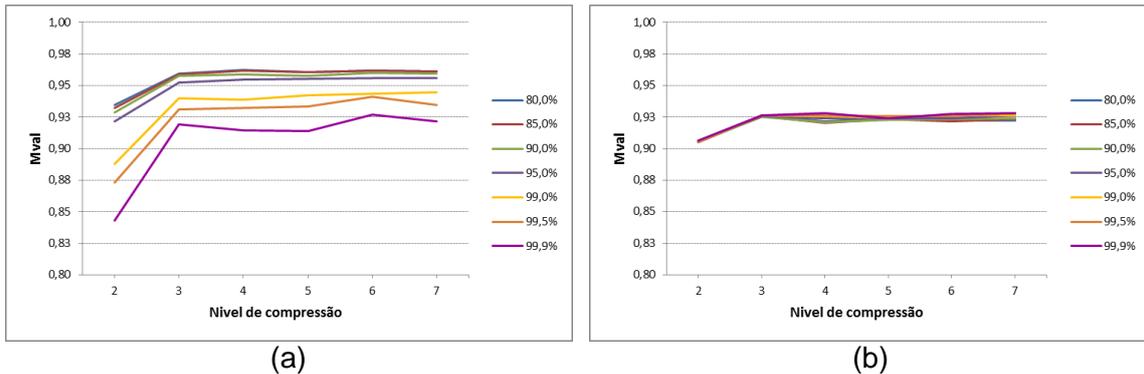


Figura 6.4 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de intensidade (\bar{M}_{val}) das imagens simuladas com polarização *hh*.

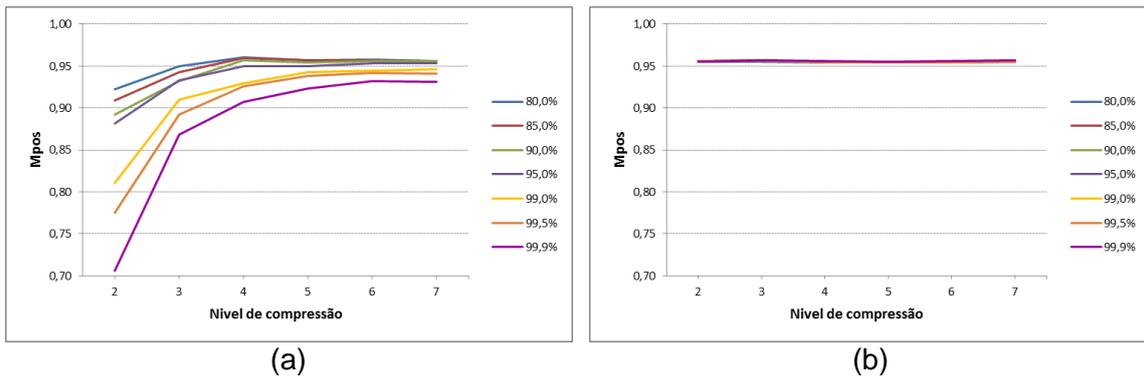


Figura 6.5 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de posição (\bar{M}_{pos}) das imagens simuladas com polarização *hh*.

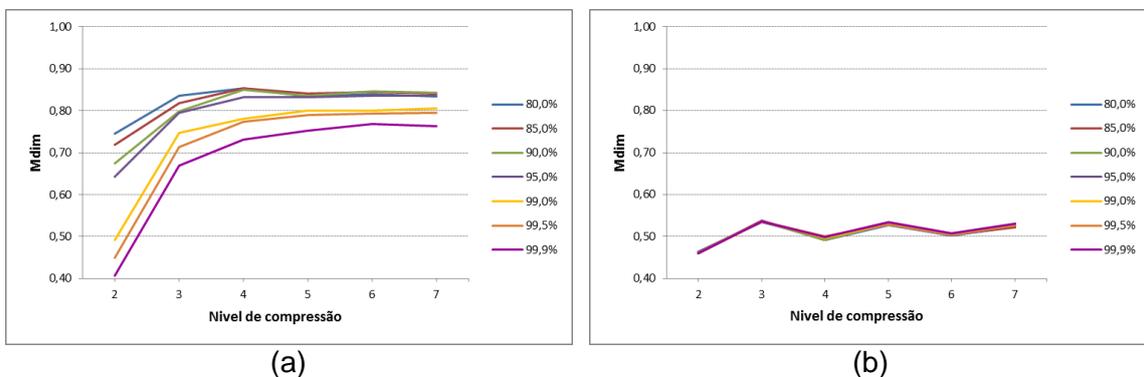


Figura 6.6 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de dimensão (\bar{M}_{dim}) das imagens simuladas com polarização *hh*.

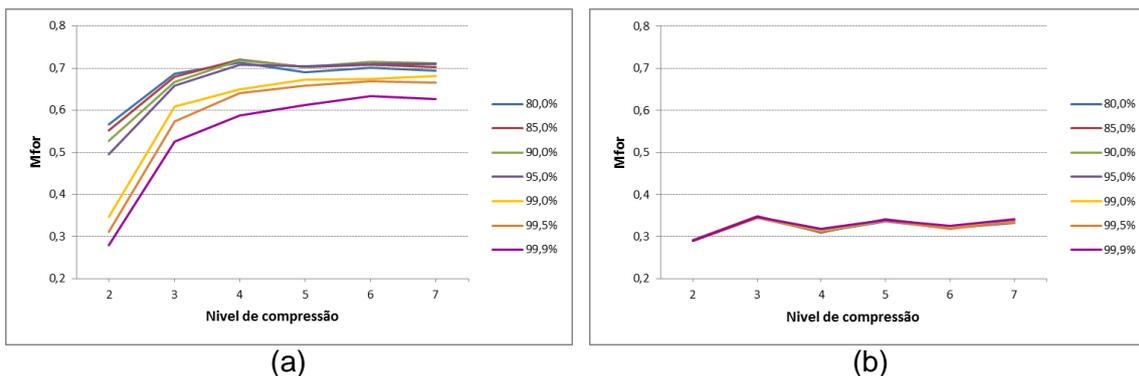


Figura 6.7 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de forma (\bar{M}_{for}) das imagens simuladas com polarização *hh*.

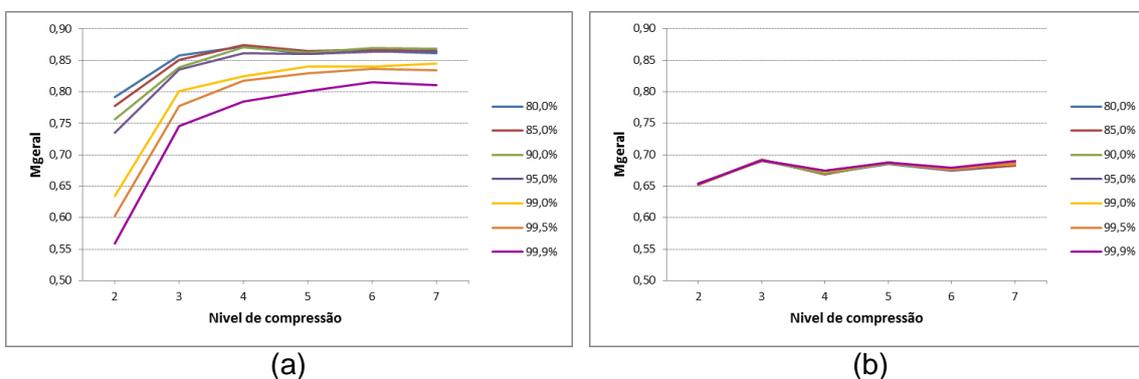


Figura 6.8 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste geral (\bar{M}_{geral}) das imagens simuladas com polarização *hh*.

A partir de uma inspeção visual dos gráficos ilustrados nas Figura 6.4 à Figura 6.8 pode-se notar que, com exceção da medida de ajuste de posição \bar{M}_{pos} obtida com o SegSAR, ambos os algoritmos apresentaram os menores valores de medidas de ajuste no nível de compressão igual a dois e que a partir deste nível os valores das medidas tendem a possuir uma menor variação.

Da Figura 6.4(a) a Figura 6.8 (a) pode-se verificar que, para o PolSeg, o uso de níveis de confiança com valores mais baixos acarreta em maiores valores para as medidas de ajuste, independentemente do nível de compressão adotado. A consequência direta da diminuição do nível de confiança é o aumento na quantidade de regiões, o qual pode ser constatado na Figura 6.2(a), e consequente aumento do tempo de processamento, conforme pode ser verificado na Figura 6.3(a). Nota-se ainda, a partir dos gráficos da Figura 6.4(a) a Figura 6.8(a), que com o aumento do nível de compressão ocorre um aumento nos valores das medidas, os quais tendem a se estabilizar a partir do

nível de compressão igual a quatro. Este resultado é decorrente do aumento do nível de compressão, que minimiza a influência do ruído *speckle*, principal causador da incerteza na definição das regiões durante a segmentação.

Por sua vez, a partir dos gráficos ilustrados na Figura 6.4(b) a Figura 6.8(b), nota-se para o SegSAR que a variação do nível de confiança aparentemente não interfere nos resultados das medidas, independentemente do nível de compressão adotado. Nota-se também que ao aumentar o nível de compressão ocorre uma leve variação nas medidas, a qual se apresenta na forma de valores altos e valores baixos intercalados.

A fim de constatar estatisticamente a igualdade dos valores das medidas para os comportamentos apresentados variando o nível de compressão de três a sete em cada nível de confiança no PolSeg, foram realizados testes de hipóteses, denominados aqui de teste-Z, com nível de significância de 1%. O mesmo teste foi usado para verificar os resultados obtidos pelo SegSAR usando a mesma variação de níveis de compressão, para fim de análise comparativa entre os dois algoritmos. A Tabela A.1 e a Tabela A.2 do Apêndice A mostram os resultados destes testes para os valores das medidas \bar{M}_{val} , \bar{M}_{pos} , \bar{M}_{dim} , \bar{M}_{for} e \bar{M}_{geral} , obtidos respectivamente pelo PolSeg e pelo SegSAR. Nestas tabelas as áreas em verde indicam os pares de níveis de compressão para os quais as imagens segmentadas produzem valores médios das respectivas medidas considerados estatisticamente iguais ao nível de significância de 1%.

Dos resultados do teste-Z apresentados na Tabela A.1, pode-se notar que para o PolSeg os valores das medidas de ajuste tendem a ser considerados estatisticamente iguais a partir de níveis de compressão aproximadamente maiores ou iguais a quatro. Este fato associado aos valores altos apresentados pelas medidas, a quantidade de regiões praticamente iguais para os níveis de compressão superiores a quatro (Figura 6.2(a)) e ao tempo de processamento menor (Figura 6.3(a)), faz com os níveis de compressão 4 ou 5 sejam considerados mais indicados para serem usados na segmentação com o

PolSeg do conjunto de imagens simuladas na polarização *hh*. Fixando-se o nível de compressão em quatro, pode-se observar pela Figura 6.8(a) e por testes estatísticos (não apresentados aqui) que segmentações efetuadas com níveis de confiança de 80%, 85% e 90% fornecem medidas de ajuste geral (\bar{M}_{geral}) estatisticamente iguais entre si e superiores às demais. Como o número de regiões mais próximo do real e o menor tempo de processamento é geralmente obtido para maiores níveis de confiança, os níveis de confiança de 85 ou 90% são os mais indicados para a segmentação das imagens em intensidade da polarização *hh* para o PolSeg.

Para o SegSAR, a partir dos resultados apresentados na Tabela A.2, percebe-se que, para um dado nível de confiança adotado no segmentador, os valores das medidas de ajuste de intensidade e de ajuste de posição podem ser consideradas estatisticamente iguais para praticamente todos os níveis de compressão. Para as demais medidas os testes indicam que níveis de compressão ímpares (3, 5 ou 7) fornecem medidas de ajustes estatisticamente iguais entre si e superiores aos níveis de compressão pares. Não foi encontrado um motivo para este comportamento atípico do SegSAR. Dessa forma, pode-se adotar para o SegSAR como parâmetros mais indicados para realizar a segmentação dos dados polarizados em intensidade aqueles que geraram maior valor para a medida de ajuste geral, ou seja, nível de compressão sete e nível de confiança de 99,9%.

6.1.1.1. Análise comparativa do desempenho dos algoritmos PolSeg e SegSAR para a polarização *hh*

Os testes-Z foram também utilizados para verificar a diferença estatística entre os valores médios das medidas de ajuste dos dois algoritmos. Segundo estes testes e os gráficos da Figura 6.4 a Figura 6.8 verifica-se que, a partir do nível de compressão igual a três, os piores resultados do PolSeg para as medidas de ajuste de dimensão, de forma e geral, obtidos para todos os níveis de confiança estudados, foram significativamente superiores aos resultados obtidos pelo SegSAR.

Na Tabela 6.1 e Tabela 6.2 são apresentados os valores da estatística Z e valor-p (bilateral) do teste estatístico para a igualdade das medidas de intensidade e de posição dos dois algoritmos. Nestas tabelas, as áreas verdes indicam para quais pares dos parâmetros de nível de confiança e de nível de compressão, os valores médios destas medidas podem ser consideradas estatisticamente iguais para os dois algoritmos, ao nível de significância de 1%. As áreas azuis indicam os pares de parâmetros para os quais o PolSeg forneceu resultados superiores ao SegSAR, e as áreas em rosa onde o SegSAR obteve resultados melhores que o PolSeg. Pode-se observar, portanto que, em geral as medidas de ajuste de intensidade do PolSeg são superiores ao do SegSAR, enquanto que as medidas de ajuste de posição do SegSAR são em geral superiores às do PolSeg.

Tabela 6.1 - Valor da estatística Z e valor-p (bilateral) do teste de igualdade da medida de ajuste de intensidade (\bar{M}_{val}) dos segmentadores PolSeg e SegSAR, calculadas na segmentação das imagens simuladas na polarização *hh*.

Nível de confiança	Estatística	Nível de compressão				
		3	4	5	6	7
80,0%	Z	23,289	27,731	25,130	23,788	27,055
	Valor-p	0,000	0,000	0,000	0,000	0,000
85,0%	Z	21,080	25,522	26,388	25,980	24,327
	Valor-p	0,000	0,000	0,000	0,000	0,000
90,0%	Z	19,634	21,336	20,338	21,908	21,757
	Valor-p	0,000	0,000	0,000	0,000	0,000
95,0%	Z	14,444	16,815	15,383	17,774	16,478
	Valor-p	0,000	0,000	0,000	0,000	0,000
99,0%	Z	6,552	6,289	6,762	7,128	8,097
	Valor-p	0,000	0,000	0,000	0,000	0,000
99,5%	Z	1,959	2,002	3,051	6,640	2,467
	Valor-p	0,050	0,045	0,002	0,000	0,014
99,9%	Z	-3,157	-4,189	-3,040	-0,252	-2,329
	Valor-p	0,002	0,000	0,002	0,801	0,020

A partir da análise apresentada para os resultados obtidos na segmentação dos dados simulados com a polarização *hh* com os dois algoritmos, verificou-se que o desempenho apresentado pelo PolSeg foi superior ao desempenho apresentado pelo SegSAR para praticamente todas as medidas de ajuste (com

exceção da medida de posição), para o número de regiões e para o tempo de processamento. A superioridade da medida de ajuste de posição obtida com o SegSAR é explicada pelo fato do algoritmo ter gerado uma grande quantidade de regiões pequenas. Decorrente deste fato alguns segmentos próximos as posições dos centros das regiões da imagem de referência foram adotados para o cálculo da medida de ajuste de posição, elevando dessa forma o valor da medida.

Tabela 6.2 – Valor da estatística Z e valor-p (bilateral) do teste de igualdade da medida de ajuste de posição (\bar{M}_{pos}) dos segmentadores PolSeg e SegSAR, calculadas na segmentação das imagens simuladas na polarização *hh*.

Nível de confiança	Estatística	Nível de compressão				
		3	4	5	6	7
80,0%	Z	-4,156	6,531	2,108	3,514	0,823
	Valor-p	0,000	0,000	0,035	0,000	0,410
85,0%	Z	-10,553	5,681	2,226	1,446	0,602
	Valor-p	0,000	0,000	0,026	0,148	0,547
90,0%	Z	-17,988	2,127	-0,281	1,284	-0,051
	Valor-p	0,000	0,033	0,779	0,199	0,959
95,0%	Z	-12,234	-3,204	-3,863	-0,808	-2,035
	Valor-p	0,000	0,001	0,000	0,419	0,042
99,0%	Z	-19,593	-13,625	-8,204	-9,362	-7,837
	Valor-p	0,000	0,000	0,000	0,000	0,000
99,5%	Z	-27,178	-15,860	-11,588	-9,848	-8,628
	Valor-p	0,000	0,000	0,000	0,000	0,000
99,9%	Z	-37,991	-22,133	-16,443	-12,907	-15,841
	Valor-p	0,000	0,000	0,000	0,000	0,000

A comparação dos resultados obtidos na segmentação do conjunto de imagens simuladas polarizadas em intensidade na polarização *hh*, adotando os parâmetros de segmentação mais indicados em ambos os algoritmos, por sua vez, mostrou que as medidas de ajuste de intensidade, posição, dimensão e forma, apresentadas no Anexo A, geradas com o PolSeg foram em média respectivamente, 3,6%, 0,3%, 60,8% e 110,9%, superiores aos gerados no SegSAR. Tem-se ainda que o PolSeg gerou em média um número de regiões 7,7 vezes menor que o gerado pelo SegSAR, e consumiu em média 4 vezes menos tempo que o consumido pelo SegSAR.

6.1.2. Imagens na polarização *hv*

Um exemplo de uma imagem, em intensidade, simulada na polarização *hv*, e sua respectiva imagem de referência, é apresentado na Figura 6.9.

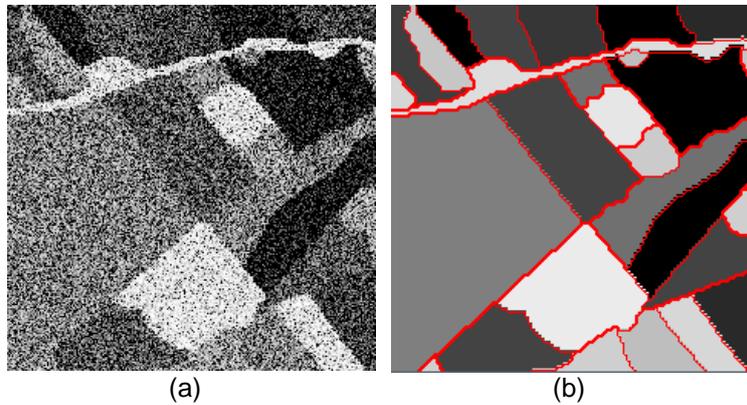


Figura 6.9 - (a) Imagem simulada na polarização *hv* e (b) Imagem de referência, com os contornos e as médias em intensidade das 29 regiões.

O mesmo estudo realizado para a polarização *hh* foi efetuado para a polarização *hv*. Os resultados obtidos em termos de números de regiões e tempo de processamento da aplicação dos algoritmos PolSeg e SegSAR são apresentados na Figura 6.10 e Figura 6.11.

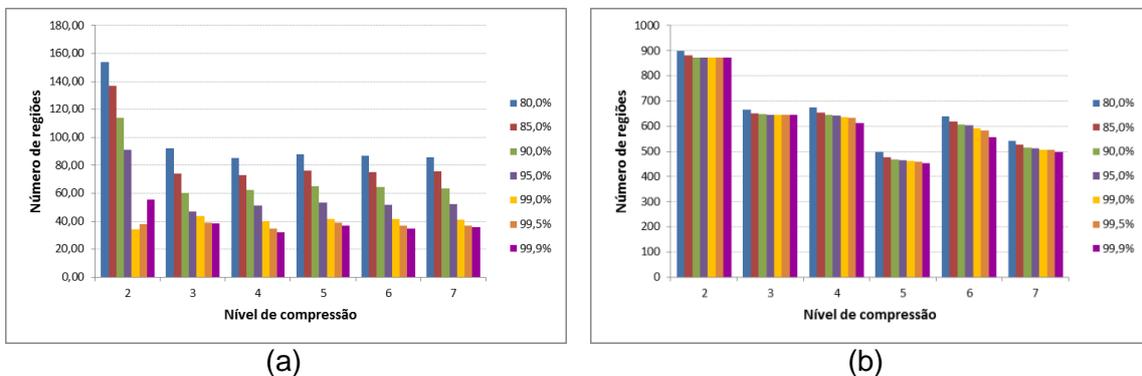


Figura 6.10 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a quantidade de regiões geradas na segmentação das imagens simuladas com polarização *hv*.

Percebe-se na Figura 6.10(a), para a segmentação no PolSeg da imagem na polarização *hv* o que já havia sido constatado para a segmentação da imagem na polarização *hh*, onde as quantidades de regiões geradas na segmentação diminuem com o aumento do nível de confiança. Da Figura 6.10(b) também se verifica o que já foi visto para o SegSAR na segmentação das imagens com

polarização *hh*, onde a partir do nível de compressão igual a três pode-se notar um comportamento semelhante ao encontrado para o PolSeg.

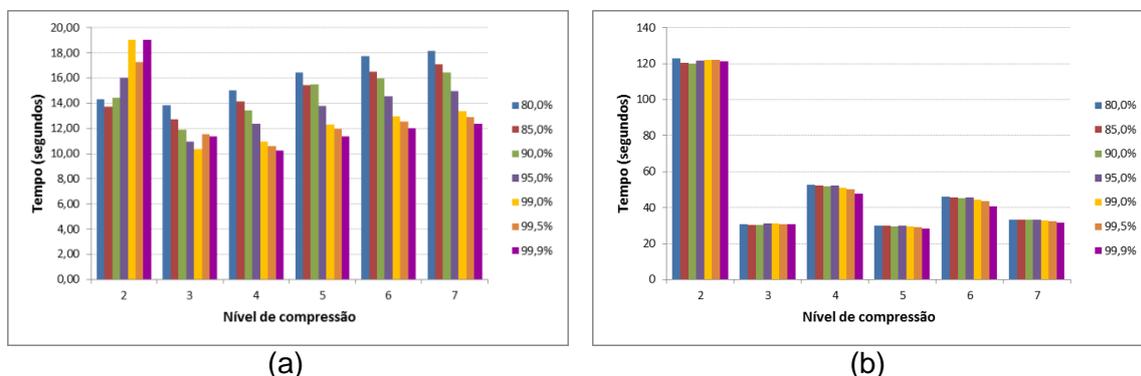


Figura 6.11 - Desempenho do (a) PolSeg e (b) SegSAR, segundo o tempo de processamento das imagens simuladas com polarização *hv*.

Os dois algoritmos também apresentaram o mesmo comportamento verificado para a imagem na polarização *hh* no que diz respeito ao tempo (Figura 6.11) gasto na segmentação das imagens na polarização *hv*.

Desse modo, os resultados da segmentação das imagens na polarização *hv* apresentados na Figura 6.10 e Figura 6.11 mostram que o PolSeg obteve um resultado superior ao obtido pelo SegSAR pelos mesmos motivos já comentados anteriormente na segmentação das imagens na polarização *hh*.

Os resultados da aplicação dos algoritmos PolSeg e SegSAR com as imagens de polarização *hv* são apresentados na Figura 6.12 a Figura 6.16, onde as curvas ilustradas nos gráficos apresentam os valores médios das medidas de ajuste para as 100 imagens simuladas, para cada nível de confiança ao variar o nível de compressão selecionado pelo usuário. Os valores numéricos usados para gerar os gráficos apresentados nestas figuras podem ser encontrados no Anexo A.

A inspeção visual dos gráficos ilustrados na Figura 6.12 à Figura 6.16 mostram uma repetição dos padrões de comportamento já apresentados na segmentação dos dados simulados na polarização *hh* por ambos os algoritmos. Da mesma forma que no caso anterior o nível de compressão igual a dois foi o que gerou os menores valores para as medidas de ajuste. Para o PolSeg o

nível de compressão igual a quatro aparece novamente como ponto de início da estabilização dos valores das medidas. Por sua vez, para o SegSAR verifica-se que houve uma maior variação para as medidas de dimensão, forma e geral para os níveis de confiança nos níveis de compressão iguais a quatro, seis e sete.

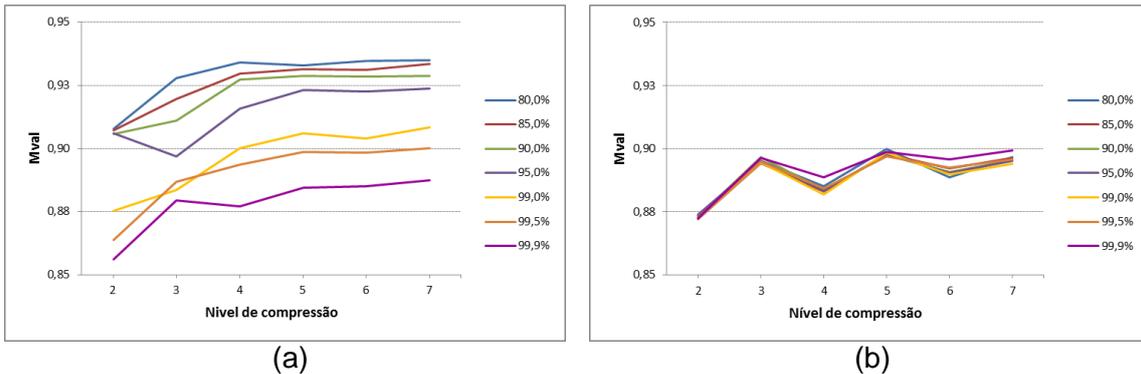


Figura 6.12 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de intensidade (\bar{M}_{val}) das imagens simuladas com polarização hv .

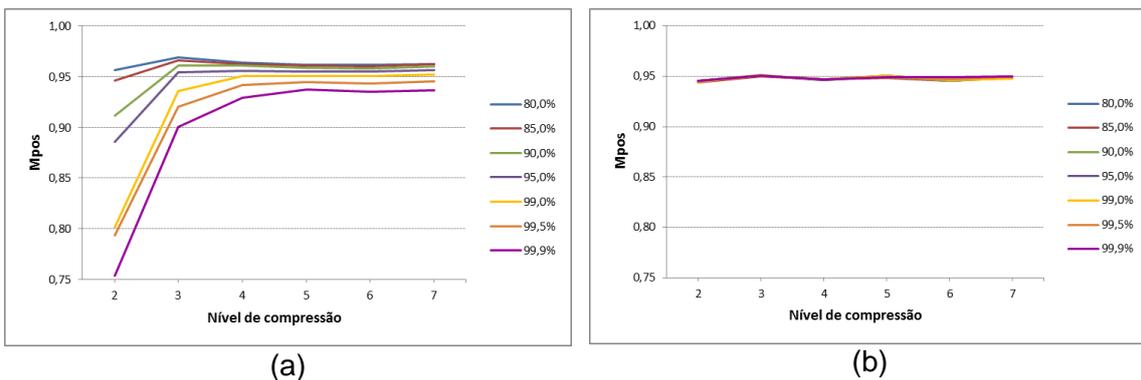


Figura 6.13 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de posição (\bar{M}_{pos}) das imagens simuladas com polarização hv .

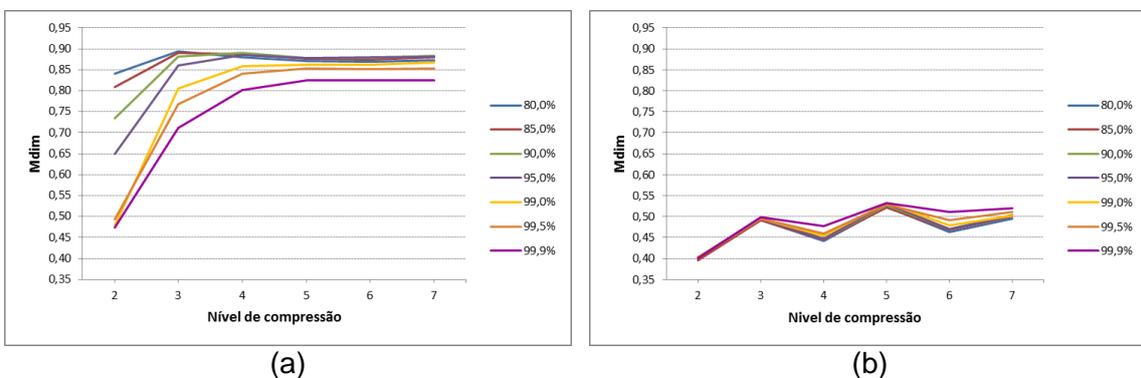


Figura 6.14 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de dimensão (\bar{M}_{dim}) das imagens simuladas com polarização hv .

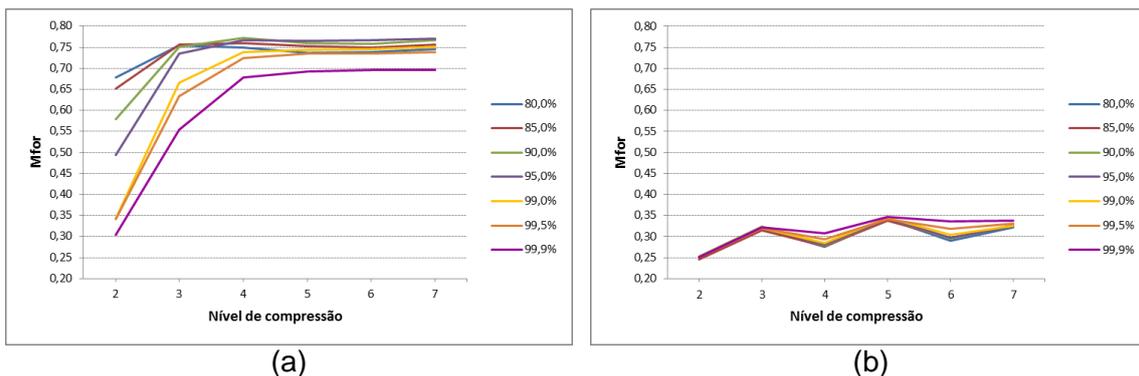


Figura 6.15 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de forma (\bar{M}_{for}) das imagens simuladas com polarização *hv*..

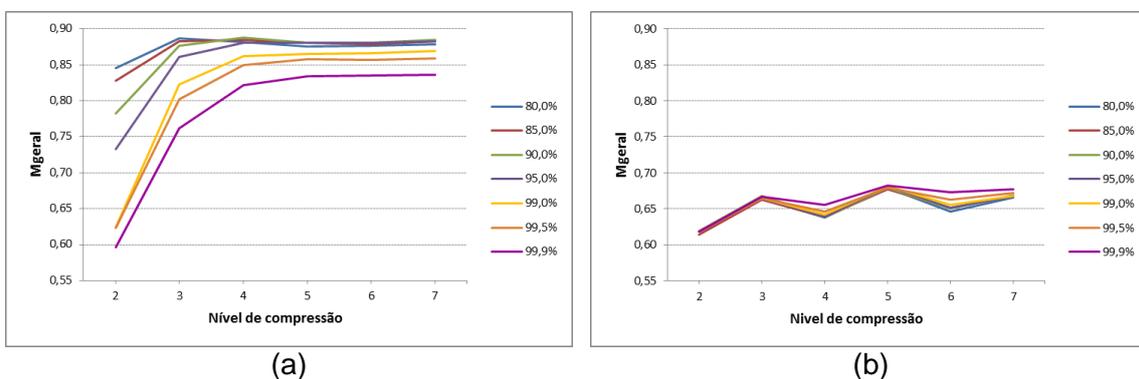


Figura 6.16 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste geral (\bar{M}_{geral}) das imagens simuladas com polarização *hv*.

A fim de verificar a igualdade estatística dos valores das medidas de ajuste obtidas pelo PolSeg no nível de compressão igual a três em diante, foi empregado o teste-Z. O mesmo teste foi usado também para verificar os resultados obtidos pelo SegSAR para análise comparativa dos algoritmos. As Tabelas A.3 e A.4, do Apêndice A, mostram os resultados dos testes para os valores das medidas obtidos nas segmentações realizadas respectivamente pelo PolSeg e pelo SegSAR, para níveis de compressão maiores ou iguais a três. As áreas em verde nestas tabelas indicam, para cada medida, os pares de níveis de compressão para os quais as imagens segmentadas produzem valores médios considerados estatisticamente iguais ao nível de significância de 1%.

Assim como no caso da polarização *hh*, os resultados mostram que para o PolSeg os valores de todas as medidas de ajuste tendem a estabilizar para níveis de compressão maior ou igual a quatro. Além disto, testes (não

apresentados aqui) mostram que para este nível de compressão os valores médios da medida de ajuste geral (\bar{M}_{geral}) relativos aos níveis de confiança de 80%, 85%, 90% e 95% podem ser considerados iguais estatisticamente. Desta maneira, os parâmetros mais indicados para a segmentação da imagem hv são níveis de compressão aproximadamente iguais a quatro e níveis de confiança de 90% ou 95%, pois além de fornecerem valores altos das medidas de ajuste, a quantidade de regiões são mais próximas do verdadeiro valor e requerem um tempo menor de processamento.

Os resultados apresentados para o SegSAR na Figura 6.12(b) a Figura 6.16(b) e pela Tabela A.4, evidenciam novamente a tendência em se obter resultados melhores neste algoritmo para níveis de compressão ímpares. Como o maior valor obtido para as medidas foi obtido no nível de compressão igual a cinco com nível de confiança de 99,9%, isto indica que este nível de compressão e nível de confiança podem ser considerados adequados para serem usados pelo SegSAR na segmentação do conjunto de imagens simuladas com polarização hv .

6.1.2.1. Análise comparativa do desempenho dos algoritmos PolSeg e SegSAR para a polarização hv

Os resultados das medidas de dimensão, forma e geral obtidas na segmentação das imagens simuladas na polarização hv , conforme pode ser visto na Figura 6.14, Figura 6.15 e Figura 6.16, repetem o padrão encontrado para imagens simuladas na polarização hh . A partir do nível de compressão igual a dois nota-se que os piores resultados do PolSeg, obtidos no nível de compressão igual a três com nível de confiança de 99,9%, são significativamente superiores aos resultados obtidos pelo SegSAR.

A Tabela 6.3 e Tabela 6.4 apresentam os resultados do teste-Z, usado para testar a igualdade das medidas de intensidade e de posição. Nestas tabelas, as áreas verdes indicam para quais pares dos parâmetros de nível de confiança e de nível de compressão, os valores médios destas medidas podem ser consideradas estatisticamente iguais para os dois algoritmos, ao nível de

significância de 1%. As áreas azuis indicam os pares de parâmetros para os quais o PolSeg forneceu resultados superiores ao SegSAR, e as áreas em rosa onde o SegSAR obteve resultados melhores que o PolSeg.

Tabela 6.3 – Valor da estatística Z e valor-p (bilateral) do teste de igualdade da medida de ajuste intensidade (\bar{M}_{val}) dos segmentadores PolSeg e SegSAR, calculadas na segmentação das imagens simuladas na polarização *hv*.

Nível de confiança	Estatística	Nível de compressão				
		3	4	5	6	7
80,0%	Z	17,353	30,006	16,995	29,821	23,137
	Valor-p	0,000	0,000	0,000	0,000	0,000
85,0%	Z	13,604	26,670	19,299	22,740	23,160
	Valor-p	0,000	0,000	0,000	0,000	0,000
90,0%	Z	8,094	24,129	17,179	21,272	19,559
	Valor-p	0,000	0,000	0,000	0,000	0,000
95,0%	Z	0,743	14,549	12,432	16,156	15,684
	Valor-p	0,457	0,000	0,000	0,000	0,000
99,0%	Z	-3,988	7,578	3,118	5,370	6,700
	Valor-p	0,000	0,000	0,002	0,000	0,000
99,5%	Z	-3,320	3,789	0,636	2,366	1,602
	Valor-p	0,001	0,000	0,525	0,018	0,109
99,9%	Z	-6,677	-4,255	-4,599	-3,585	-3,993
	Valor-p	0,000	0,000	0,000	0,000	0,000

Tem-se ainda, que a comparação dos resultados obtidos na segmentação do conjunto de imagens simuladas polarizadas em intensidade na polarização *hv*, adotando os parâmetros de segmentação mais indicados para os algoritmos, mostrou que as medidas de ajuste de intensidade, posição, dimensão e forma, apresentadas no Anexo A, geradas com o PolSeg foram em média respectivamente, 3,2%, 1,2%, 67,1% e 122,4%, superiores aos gerados no SegSAR. Tem-se ainda que o PolSeg gerou em média um número de regiões 7,3 vezes menor que o gerado pelo SegSAR, e consumiu em média 2,1 vezes menos tempo que o consumido pelo SegSAR.

Tabela 6.4 – Valor da estatística Z e valor-p (bilateral) do teste de igualdade da medida de ajuste de posição (\bar{M}_{pos}) dos segmentadores PolSeg e SegSAR, calculadas na segmentação das imagens simuladas na polarização *hv*.

Nível de confiança	Estatística	Nível de compressão				
		3	4	5	6	7
80,0%	Z	15,666	12,670	8,667	12,466	10,360
	Valor-p	0,000	0,000	0,000	0,000	0,000
85,0%	Z	12,813	11,521	8,855	10,992	9,771
	Valor-p	0,000	0,000	0,000	0,000	0,000
90,0%	Z	7,911	10,395	6,484	9,447	8,606
	Valor-p	0,000	0,000	0,000	0,000	0,000
95,0%	Z	2,537	7,312	3,375	5,960	5,623
	Valor-p	0,011	0,000	0,001	0,000	0,000
99,0%	Z	-8,383	2,798	-0,070	2,555	2,648
	Valor-p	0,000	0,005	0,944	0,011	0,008
99,5%	Z	-12,637	-3,774	-2,369	-2,548	-2,742
	Valor-p	0,000	0,000	0,018	0,011	0,006
99,9%	Z	-16,007	-11,577	-8,452	-8,581	-8,400
	Valor-p	0,000	0,000	0,000	0,000	0,000

6.1.3. Imagens na polarização *vv*

Na Figura 6.17 é apresentada uma imagem simulada na polarização *vv*, e a sua respectiva imagem de referência cujos níveis de cinza das regiões representam a intensidade média das mesmas.

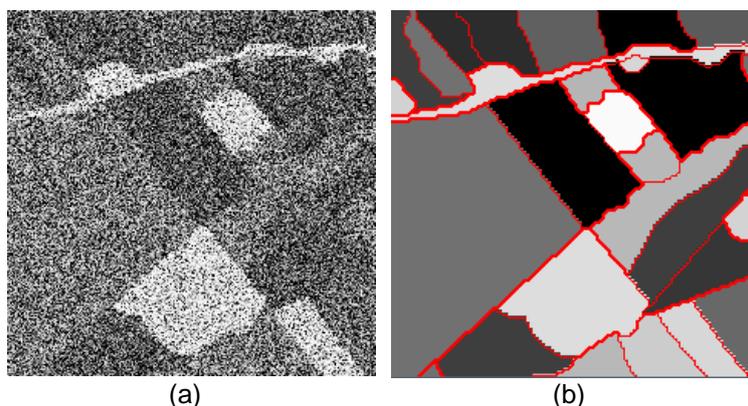


Figura 6.17 - (a) Imagem simulada na polarização *vv* e (b) Imagem de referência, com os contornos e as médias em intensidade das 29 regiões.

Os resultados em termos de números de regiões e tempo de processamento da aplicação dos algoritmos PolSeg e SegSAR com as imagens de polarização vv são apresentados na Figura 6.18 e Figura 6.19. Estas figuras confirmam, de maneira geral, os resultados já apresentados para as polarizações hh e hv. Novamente, da comparação dos resultados apresentados nas Figura 6.18 e Figura 6.19 percebe-se que o PolSeg obteve um resultado superior ao obtido pelo SegSAR, pois foi capaz de gerar um número de regiões mais próximo ao número de regiões contidos na imagem de referência, com um tempo de processamento significativamente inferior ao consumido pelo SegSAR.

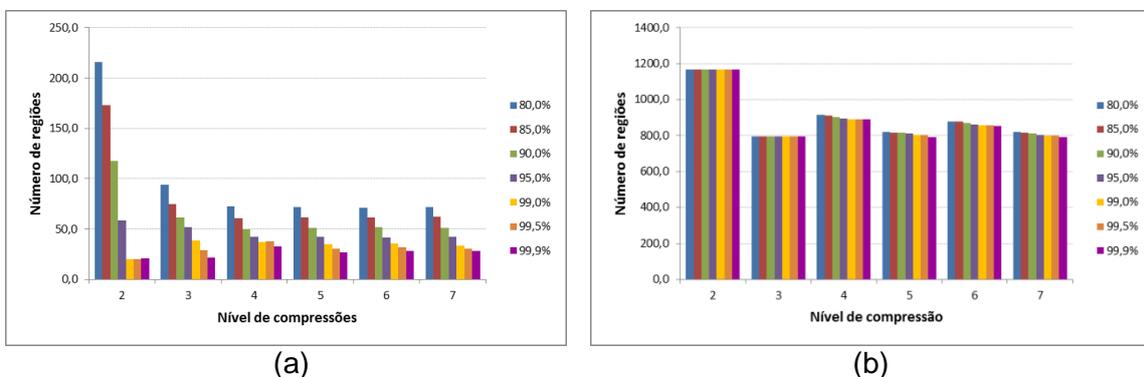


Figura 6.18 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a quantidade de regiões geradas nas segmentações das imagens simuladas com polarização vv.

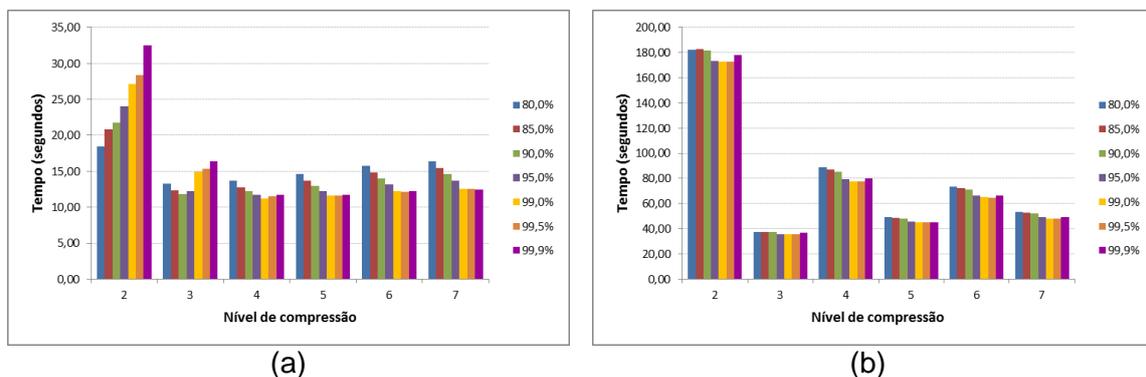


Figura 6.19 - Desempenho do (a) PolSeg e (b) SegSAR, segundo o tempo de processamento das imagens simuladas com polarização vv.

Os resultados da aplicação dos algoritmos PolSeg e SegSAR com as imagens simuladas de polarização vv são apresentados na Figura 6.20 a Figura 6.24, onde as curvas ilustradas nos gráficos apresentam os valores calculados das medidas de ajuste, para cada nível de confiança ao variar o nível de

compressão selecionado pelo usuário. Os valores numéricos usados para gerar os gráficos apresentados nestas figuras podem ser encontrados no Anexo A.

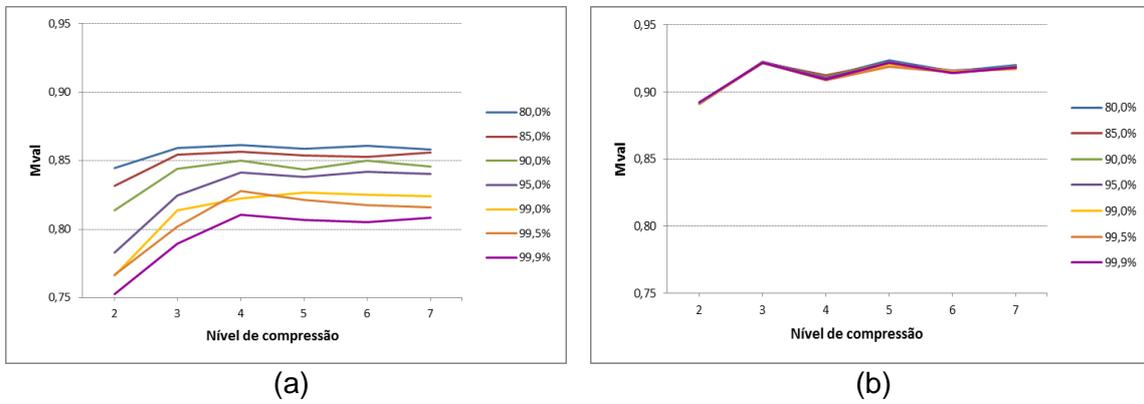


Figura 6.20 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de intensidade (\bar{M}_{val}) das imagens simuladas com polarização vv.

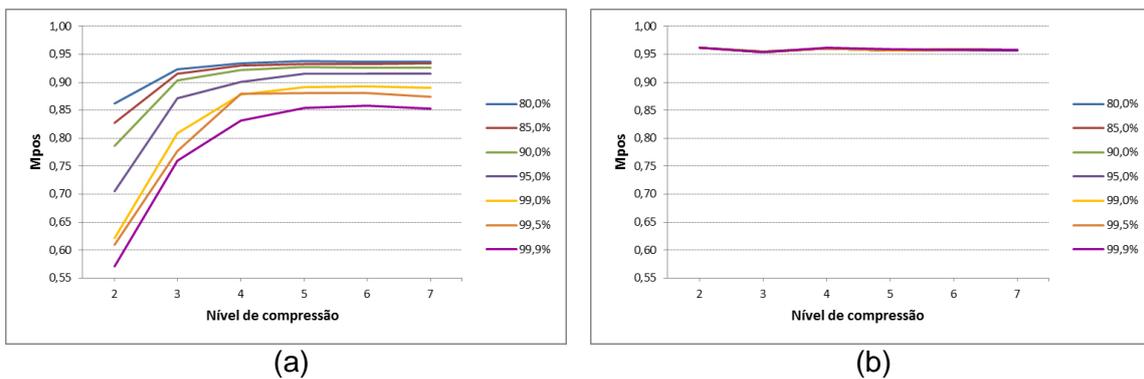


Figura 6.21 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de posição (\bar{M}_{pos}) das imagens simuladas com polarização vv.

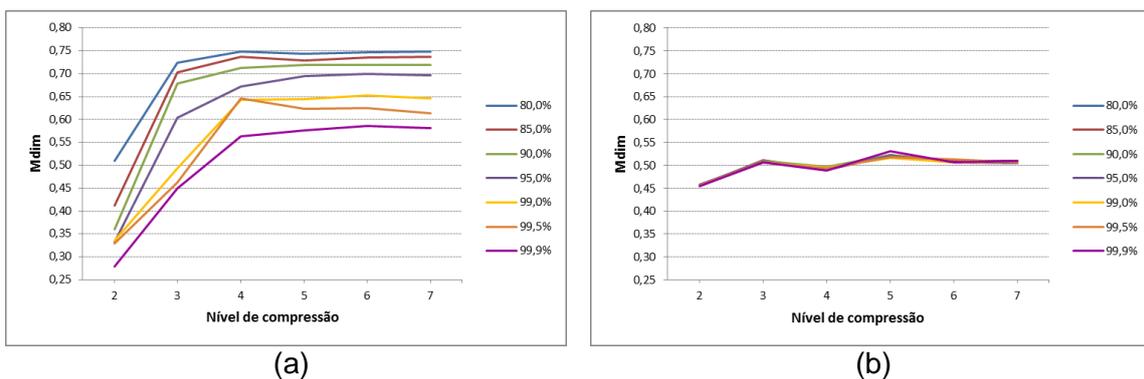


Figura 6.22 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de dimensão (\bar{M}_{dim}) das imagens simuladas com polarização vv.

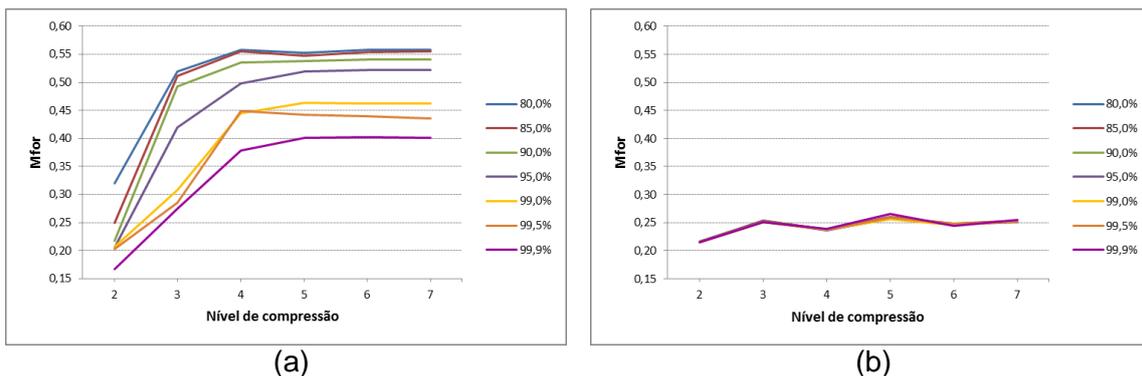


Figura 6.23 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste de forma (\bar{M}_{for}) das imagens simuladas com polarização *vv*.

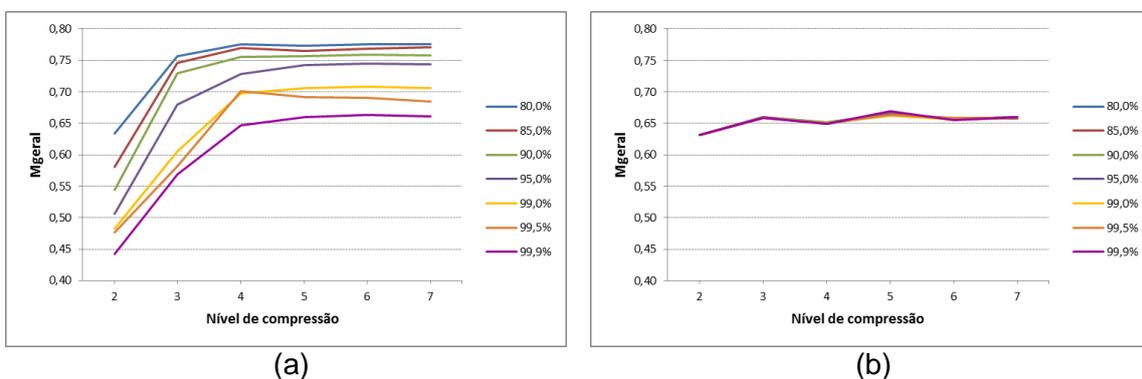


Figura 6.24 - Desempenho do (a) PolSeg e (b) SegSAR, segundo a medida de ajuste geral (\bar{M}_{geral}) das imagens simuladas com polarização *vv*.

Os gráficos ilustrados na Figura 6.20(a) a Figura 6.24(a) mostram que para o PolSeg os valores obtidos para as medidas de ajuste na segmentação das imagens com a polarização *vv* foram menores aos obtidos na segmentação das imagens com polarizações *hh* e *hv*. Para o SegSAR, os gráficos da Figura 6.20(b) a Figura 6.24(b) mostram comportamentos e valores similares aos já observados na segmentação das imagens com polarização *hh* e *hv*.

As Tabelas A.5 e A.6 do Apêndice A mostram os resultados do teste-Z, para os valores das medidas obtidos, respectivamente, pelo PolSeg e pelo SegSAR, na segmentação das imagens simuladas com polarização *vv*. Apesar dos resultados inferiores obtidos pelo PolSeg para a polarização *vv* quando comparados com as das demais polarizações, a Tabela A.5 mostra novamente que, para um dado nível de significância, este algoritmo possui uma tendência em apresentar resultados similares para níveis de compressão maiores ou iguais a quatro. Além disto, fixando-se o nível de compressão em quatro, pode-

se observar pela Figura 6.24(a) e por testes estatísticos (não apresentados aqui) que segmentações efetuadas com níveis de confiança de 80% e 85% fornecem medidas de ajuste geral (\bar{M}_{geral}) estatisticamente iguais entre si e superiores às demais. Estes resultados indicam como parâmetros adequados para a segmentação no PolSeg da polarização vv da imagem simulada o nível de compressão quatro e nível de confiança de 85%.

Para o SegSAR, a Tabela A.6 mostra que os valores de todas as medidas de ajuste de intensidade e posição podem ser consideradas estatisticamente iguais a partir do nível de compressão igual a três. Para as demais medidas, os valores obtidos para os níveis de compressão ímpares tendem a ser iguais entre si e superiores aos níveis de compressão pares, como visto anteriormente. Este fato associado a pequena quantidade de regiões e menor o tempo de processamento para os níveis de compressão iguais a três, cinco ou sete, faz com que qualquer um destes níveis de compressão sejam indicados para ser usado pelo SegSAR na segmentação do conjunto de imagens simuladas com a polarização vv.

6.1.3.1. Análise comparativa do desempenho dos algoritmos PolSeg e SegSAR para a polarização vv

Os valores observados para o PolSeg das medidas de ajuste de dimensão (Figura 6.22(a)), de posição (Figura 6.21(a)) e geral (Figura 6.24(a)), para os níveis de compressão maiores que dois, mostram uma maior aproximação aos valores obtidos com o SegSAR (Figura 6.22(b), Figura 6.21(b) e Figura 6.24(b)). A fim de investigar com que combinações de parâmetros os algoritmos apresentaram valores estatisticamente iguais foram realizados testes-Z para cada medida de ajuste calculada para os dois algoritmos.

Para as medida de ajuste de intensidade e de posição (Figura 6.20 e Figura 6.21) estes testes indicaram que os valores obtidos com o SegSAR foram em geral estatisticamente maiores que os valores obtidos com o PolSeg para todos os níveis de confiança.

Para as medidas de ajuste de dimensão e de forma (Figura 6.22 e Figura 6.23) os testes indicaram que PolSeg obteve valores em geral superiores aos obtidos pelo SegSAR.

Os resultados do teste de hipótese para a igualdade da medida de ajuste geral (Figura 6.24) entre os dois algoritmos são apresentados na Tabela 6.5. Nesta tabela, as áreas verdes indicam para quais pares dos parâmetros de nível de confiança e de nível de compressão, os valores médios destas medidas podem ser consideradas estatisticamente iguais para os dois algoritmos, ao nível de significância de 1%. As áreas azuis indicam os pares de parâmetros para os quais o PolSeg forneceu resultados superiores ao SegSAR, e as áreas em rosa onde o SegSAR obteve resultados melhores que o PolSeg. Pode-se verificar que, exceto para o nível de compressão igual a três associado a níveis de confiança maiores que 99%, o algoritmo PolSeg é superior ou igual ao algoritmo SegSAR.

Tabela 6.5 - Valor da estatística Z e valor-p (bilateral) do teste de igualdade da medida de ajuste geral (\bar{M}_{geral}) dos segmentadores PolSeg e SegSAR, calculadas na segmentação das imagens simuladas na polarização vv.

Nível de confiança	Nível de compressão				
	3	4	5	6	7
80,0%	7,535	11,615	8,272	10,519	8,912
	0,000	0,000	0,000	0,000	0,000
85,0%	29,392	53,525	35,665	42,536	44,590
	0,000	0,000	0,000	0,000	0,000
90,0%	20,300	38,153	31,699	39,764	35,404
	0,000	0,000	0,000	0,000	0,000
95,0%	4,577	22,725	25,501	28,530	27,897
	0,000	0,000	0,000	0,000	0,000
99,0%	-9,115	11,781	11,898	16,124	13,962
	0,000	0,000	0,000	0,000	0,000
99,5%	-13,354	12,365	8,276	9,979	6,944
	0,000	0,000	0,000	0,000	0,000
99,9%	-13,710	-0,665	-2,281	1,839	0,279
	0,000	0,506	0,023	0,066	1,219

A comparação, por sua vez, dos resultados obtidos na segmentação do conjunto de imagens simuladas polarizadas em intensidade na polarização vv, adotando os parâmetros de segmentação mais indicados para os algoritmos, mostrou que as medidas de ajuste de dimensão e forma, apresentadas no Anexo A, geradas com o PolSeg foram em média respectivamente, 38,6% e 109,1%, superiores as geradas no SegSAR. Já os valores das medias de ajuste de intensidade e posição foram respectivamente, 7,1% e 2,9% inferiores. Tem-se ainda que o PolSeg gerou em média um número de regiões 61,8 vezes menor que o gerado pelo SegSAR, e consumiu em média 0,7 vezes menos tempo que o consumido pelo SegSAR.

6.1.4. Análise visual comparativa da segmentação no PolSeg e SegSAR de uma imagem simulada

Nesta seção é realizada uma análise visual comparativa dos resultados das segmentações dos algoritmos PolSeg e SegSAR de uma imagem simulada, utilizando os valores de parâmetros que, pela análise quantitativa, forneceram as melhores segmentações. Para o PolSeg foi realizado uma análise do processo de segmentação, tomando por base o resultado obtido para uma imagem a cada ciclo da segunda etapa de processamento, a quantidade de regiões geradas e o tempo consumido pelos módulos de processamento. Para o SegSAR foi feito uma análise tomando por base somente os resultados finais obtidos na segmentação da mesma imagem utilizada no PolSeg.

6.1.4.1. Resultados obtidos com o PolSeg

Para ilustrar o processo de segmentação executado no PolSeg foi selecionada uma das imagens simuladas, a qual teve suas polarizações segmentadas individualmente pelo algoritmo. Nas segmentações realizadas foram usadas as combinações de parâmetros que geraram os melhores resultados para a medida de ajuste geral. A Tabela 6.6 apresenta os valores destes parâmetros e o valor obtido para a medida de ajuste geral.

Tabela 6.6 - Parâmetros de segmentação usados na segmentação com o PolSeg das imagens simuladas nas polarizações *hh*, *hv* e *vv* que apresentaram melhores resultados para a medida de ajuste geral.

Polarização da imagem	Nível máximo de compressão	Nível de confiança	Área mínima	\bar{M}_{geral}
<i>hh</i>	4	85,0%	15	0,8742
<i>hv</i>	4	90,0%	15	0,8877
<i>vv</i>	4	90,0%	15	0,7755

A Figura 6.25 ilustra os resultados das segmentações obtidas para as polarizações *hh*, *hv* e *vv* da imagem selecionada. As ilustrações desta figura apresentam as imagens de intensidade média das regiões geradas na segmentação, para cada nível de compressão a partir do nível de compressão quatro, e a imagem original submetida ao processamento, também representada em intensidade.

Da sequência de imagens apresentadas na Figura 6.25, pode-se notar que a obtenção da segmentação final foi o resultado do refinamento da segmentação da imagem realizada no nível máximo de compressão. Este comportamento é previsto para o algoritmo e mostra que seu funcionamento está de acordo com o que foi idealizado na sua concepção.

Pode-se notar ainda na Figura 6.25, que ao se aproximar do nível de compressão igual a zero as bordas das regiões se tornam mais ruidosas (serrilhadas). Este efeito está associado ao aumento do nível de ruído *speckle* na imagem SAR, que prejudica o desempenho do algoritmo na definição das bordas. Tal efeito fica bem caracterizado quando se visualiza o resultado final da segmentação no nível de compressão igual a zero, onde a imagem possui *nel* igual a um.

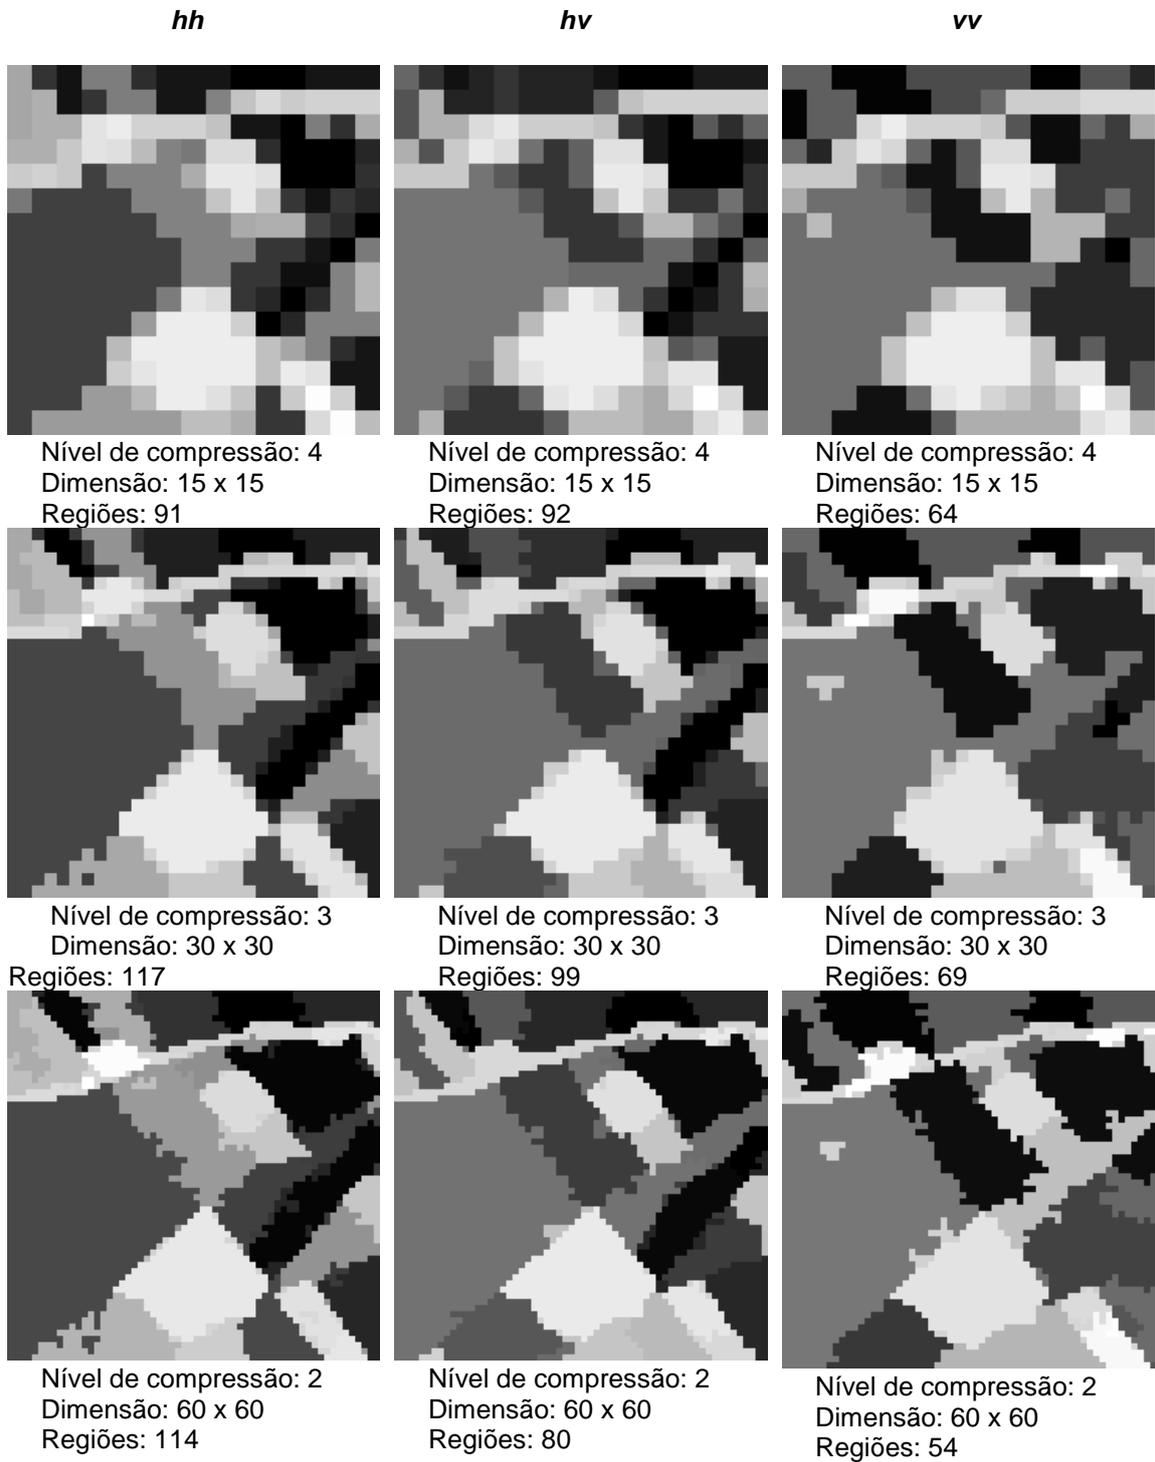


Figura 6.25 - Resultados de segmentações obtidas pelo PolSeg com as imagens nas polarizações (a) *hh*, (b) *hv* e (c) *vv* usando os parâmetros que apresentaram melhores resultados para a medida de ajuste geral (\bar{M}_{geral}).

(Continua)

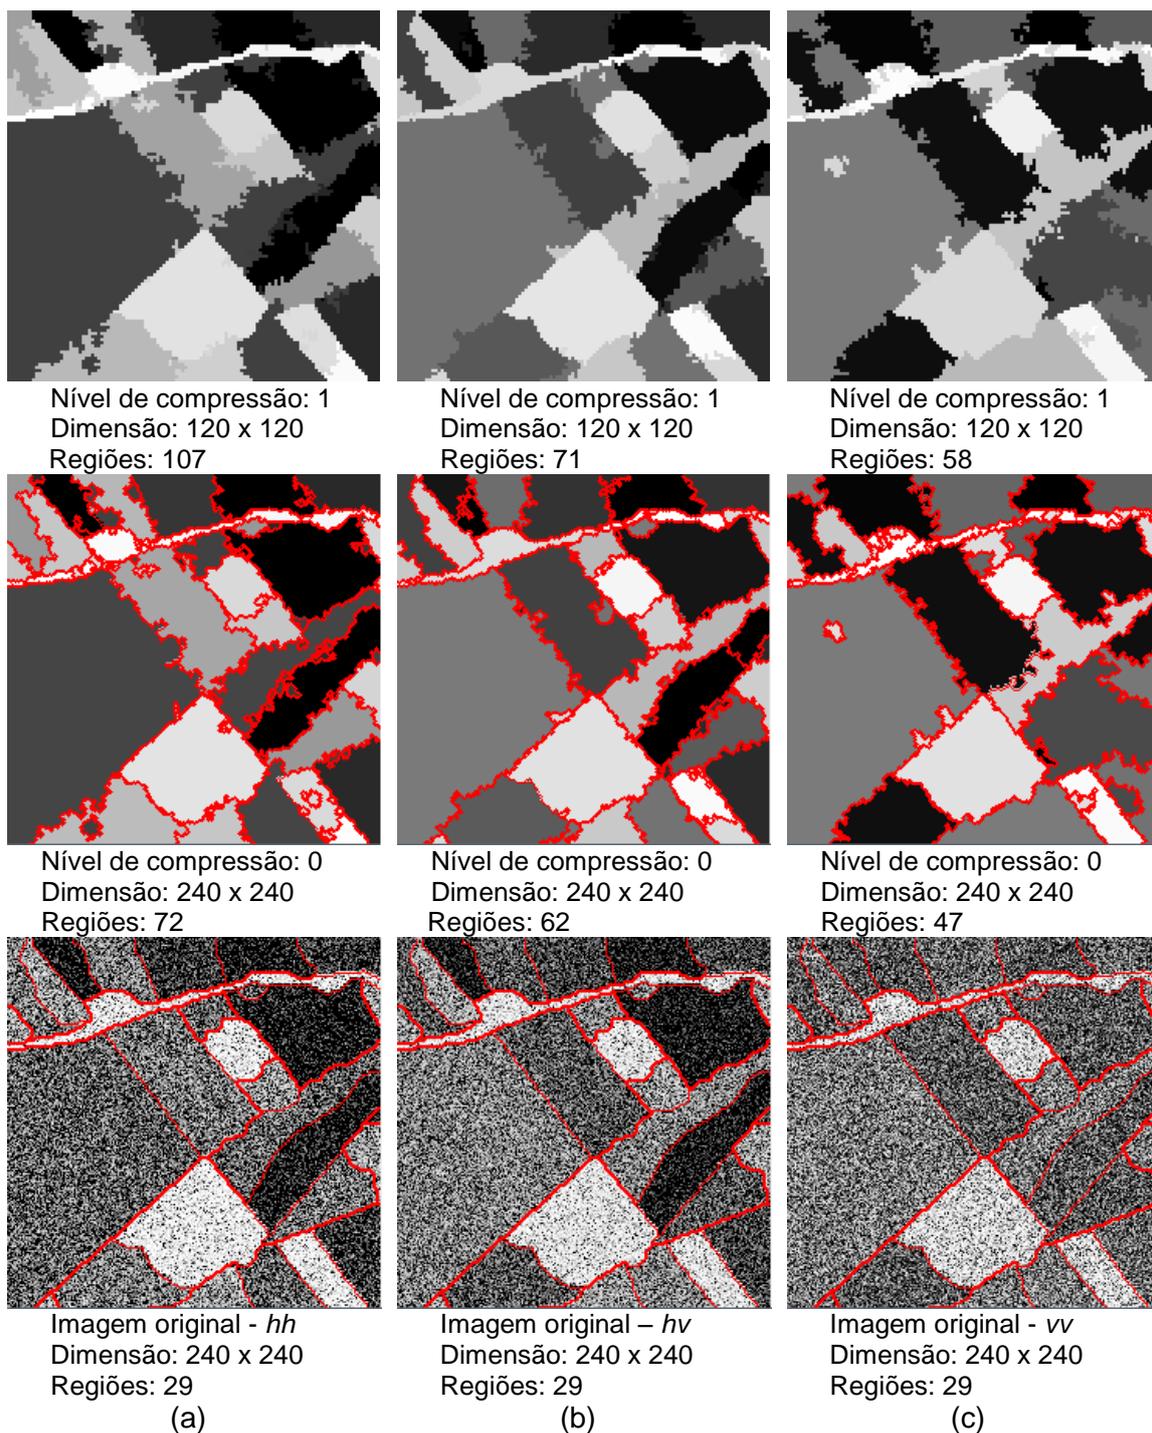


Figura 6.25 – Conclusão.

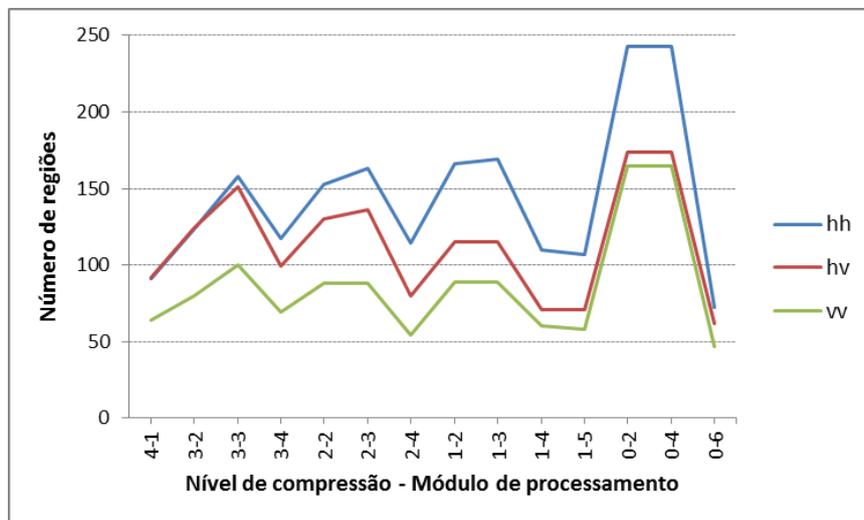
Por fim, verifica-se na Figura 6.25 que a segmentação da imagem simulada com polarização vv não foi eficiente na definição de algumas regiões para o conjunto de imagens simuladas, quando comparado com os resultados apresentados pelas segmentações das imagens com as polarizações hh e hv . Isto se deve, provavelmente, às limitações da polarização vv para discriminar

algumas classes de interesse, cujas as intensidades médias são muito próximas, como é o caso das classes 3 e 4 e das classes 5 e 6, como mostra a Tabela 6.7.

Tabela 6.7 - Intensidade Média das Classes nas polarizações *hh*, *hv* e *vv*.

Classes	Intensidade Média ($\times 10^{-4}$) das classes utilizadas na simulação das imagens		
	<i>hh</i>	<i>hv</i>	<i>vv</i>
1	7,61	24,86	32,28
2	128,59	336,96	154,34
3	29,63	86,90	43,35
4	14,06	60,56	42,38
5	48,93	12,11	25,68
6	18,70	32,81	25,87

A Figura 6.26 apresenta as quantidades de regiões geradas em cada nível de compressão para cada módulo de processamento do PolSeg, nas segmentações individuais de cada polarização da imagem simulada selecionada.



Legenda dos módulos de processamentos:

1 : Segmentação	4 : Agrupamento de regiões
2 : Ajuste de bordas	5 : Agrupamento de pixels isolados
3 : Segmentação de regiões heterogêneas	6 : Área mínima

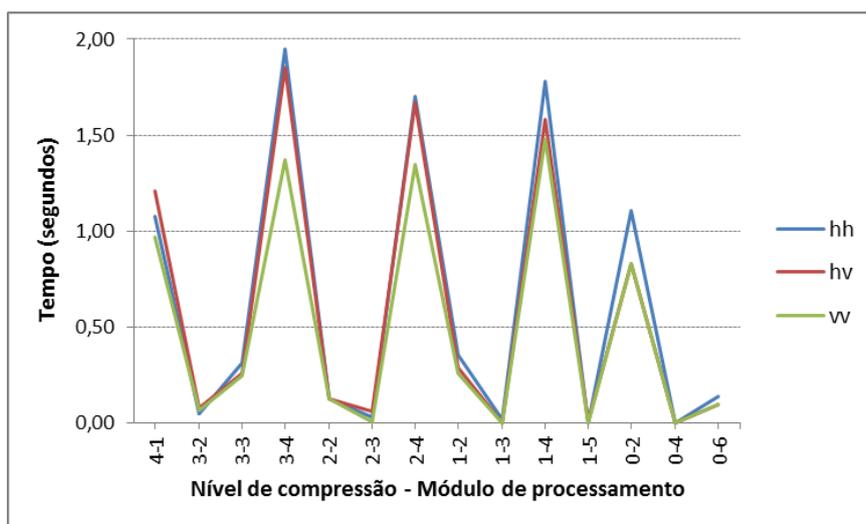
Figura 6.26 - Quantidade de regiões geradas para imagem simulada com as polarizações *hh*, *hv* e *vv* a cada nível de compressão pelos módulos de processamentos do PolSeg.

No início do processo, no nível de compressão igual a quatro, a imagem possui uma dimensão de 15 colunas por 15 linhas, onde é efetuada a primeira segmentação, o que justifica a quantidade pequena de segmentos iniciais apresentados na Figura 6.26. A cada descompressão em um nível a imagem é submetida ao ajuste de borda, à análise de homogeneidade, à segmentação de regiões heterogêneas e ao agrupamento de regiões. De modo geral, nota-se na Figura 6.26 que a cada execução dos módulos de ajuste de borda e segmentação de regiões heterogêneas ocorre um aumento na quantidade de regiões, enquanto que na execução do módulo de agrupamento de regiões ocorre uma diminuição desta quantidade. Tal comportamento está de acordo com o esperado para o funcionamento destes módulos. Isto porque tanto o módulo de ajuste de bordas como o de segmentação de regiões heterogêneas tem por característica a geração de novas regiões, enquanto que o módulo de agrupamento de regiões tem por finalidade agrupar regiões adjacentes consideradas estatisticamente iguais, o que diminui a quantidade de regiões geradas.

Outro comportamento notado a partir da Figura 6.26 é que com a diminuição do nível de compressão as quantidades de regiões geradas pelos módulos de ajuste de borda e de segmentação de regiões heterogêneas tende a ser maior. Isto ocorre porque na descompressão o número de *pixels* da imagem é aumentado exponencialmente, acarretando um aumento do ruído *speckle*, e uma diminuição do número equivalente de looks (*nel*). Isto faz com que o módulo de ajuste de bordas gere bordas mais fragmentadas deixando isolados alguns *pixels*, que passam a formar novas regiões. Além disso, faz com que o processamento executado pelo módulo de segmentação de regiões heterogêneas gere mais regiões, com menor quantidade de *pixels*. A primeira situação fica bem ilustrada quando o nível de compressão da imagem é igual a 0, *nel* igual a um, onde ocorre o maior aumento na quantidade de segmentos pelo módulo de ajuste de bordas. Pode-se notar também que a execução do módulo de área mínima, efetuada no nível zero, é responsável pela maior diminuição na quantidade de regiões durante todo o processo de segmentação. Isto evidencia que durante o processo de segmentação foi gerado uma grande

quantidade de regiões com menos de 15 *pixels*, limiar adotado na segmentação para eliminação de regiões pequenas.

A Figura 6.27 apresenta o tempo consumido em cada nível de compressão, para cada módulo de processamento do PolSeg, nas segmentações individuais realizadas com as polarizações da imagem simulada selecionada para análise.



Legenda dos módulos de processamentos:	
1 – Segmentação	4 – Agrupamento de regiões
2 – Ajuste de bordas	5 – Agrupamento de pixels isolados
3 – Segmentação de regiões heterogêneas	6 – Área mínima

Figura 6.27 - Tempo de processamento gasto para realizar a segmentação das polarizações *hh*, *hv* e *vv* da imagem simulada a cada nível de compressão pelos módulos de processamentos do PolSeg.

A partir da Figura 6.27 pode-se observar que o tempo de processamento gasto na segmentação inicial foi significativamente alto. Isto dá uma noção de como o processo de crescimento de regiões é computacionalmente custoso, pois cabe lembrar, que neste nível de compressão a imagem possui uma dimensão de apenas 15x15 *pixels*. Este fato justifica o uso da técnica de compressão por pirâmides hierárquicas, a qual tem por finalidade principal, a redução da dimensão da imagem para otimizar o tempo de processamento. Pode-se verificar também que para o módulo de ajuste de bordas o custo computacional tende a aumentar a cada descompressão. Tal comportamento é esperado, pois a cada descompressão as regiões geradas passam a possuir maior quantidade

de *pixels*, os quais quando posicionados nas bordas são analisados um a um pelo módulo de ajuste de bordas. Verifica-se ainda que o custo computacional apresentado pelo módulo de segmentação de regiões heterogêneas diminui até se anular no nível de compressão igual a um indicando que neste nível não há mais regiões heterogêneas para serem segmentadas novamente.

Nota-se também que o módulo de agrupamento de regiões apresenta grande custo computacional no algoritmo, o que pode ser observado pelos picos altos de tempo de processamento. Este fato pode ser encarado como algo similar ao que ocorre com o crescimento de regiões. Isto se deve porque o processo de agrupamento de regiões pode ser considerado um processo de crescimento a partir de uma região já formada. O custo computacional praticamente nulo do módulo agrupamento de *pixels* isolados indica que foram encontrados poucos *pixels* isolados dentro das regiões. Por fim o custo computacional relativamente baixo apresentado pelo módulo de área mínima, quando considerado a quantidade de regiões apresentadas na Figura 6.26, mostra que o módulo obteve bom desempenho.

6.1.4.2. Resultados obtidos com o SegSAR

Para ilustrar os resultados finais do processamento realizado pelo SegSAR, as polarizações da imagem selecionada foram segmentadas individualmente neste algoritmo. Os parâmetros de nível de compressão e nível de confiança usados na segmentação foram aqueles que apresentaram os melhores resultados para a medida de ajuste geral. A Tabela 6.8 apresenta os valores destes parâmetros bem como o valor obtido para a medida de ajuste geral.

Tabela 6.8 - Parâmetros de segmentação usados na segmentação com o SegSAR das imagens simuladas nas polarizações *hh*, *hv* e *vv* que apresentaram melhores resultados para a medida de ajuste geral (\bar{M}_{geral}).

Polarização da imagem	Nível máximo de compressão	Nível de confiança	Área mínima	\bar{M}_{geral}
<i>hh</i>	7	99,9%	15	0,6896
<i>hv</i>	5	99,9%	15	0,6821
<i>vv</i>	5	99,0%	15	0,6622

Os resultados das segmentações obtidas pelo SegSAR para as polarizações hh , hv e vv da imagem selecionada são ilustrados na Figura 6.28 (a), (d) e (g), respectivamente. Na Figura 6.28(b), (e) e (h) são apresentadas as respectivas imagens originais. Para fins de comparação as imagens segmentadas pelo PolSeg são reapresentadas nas Figura 6.28(c), (f) e (i).

As imagens apresentadas na Figura 6.28, mostram que de modo geral o SegSAR gerou como resultado uma super-segmentação para cada uma das três polarizações processadas. Como a imagem original possui 1-look, tal resultado está de acordo com o que foi constatado por Sousa Junior (2005), que verificou que a quantidade de segmentos gerados pelo SegSAR tende a aumentar no processamento de imagens SAR com número de looks reduzido, devido a maior quantidade de ruído existentes nestes dados.

Os resultados apresentados nesta subseção reforçam as conclusões apresentadas na subseção anterior, em relação à superioridade do algoritmo PolSeg na segmentação de imagens SAR em intensidade representadas por um único canal. Isto mostra que a modelagem estatística rigorosa adotada para o PolSeg, baseada na distribuição *Gama*, produz resultados superiores a aqueles obtidos pela modelagem adotada pelo SegSAR, baseada nas distribuições Gaussiana e *Gama*.

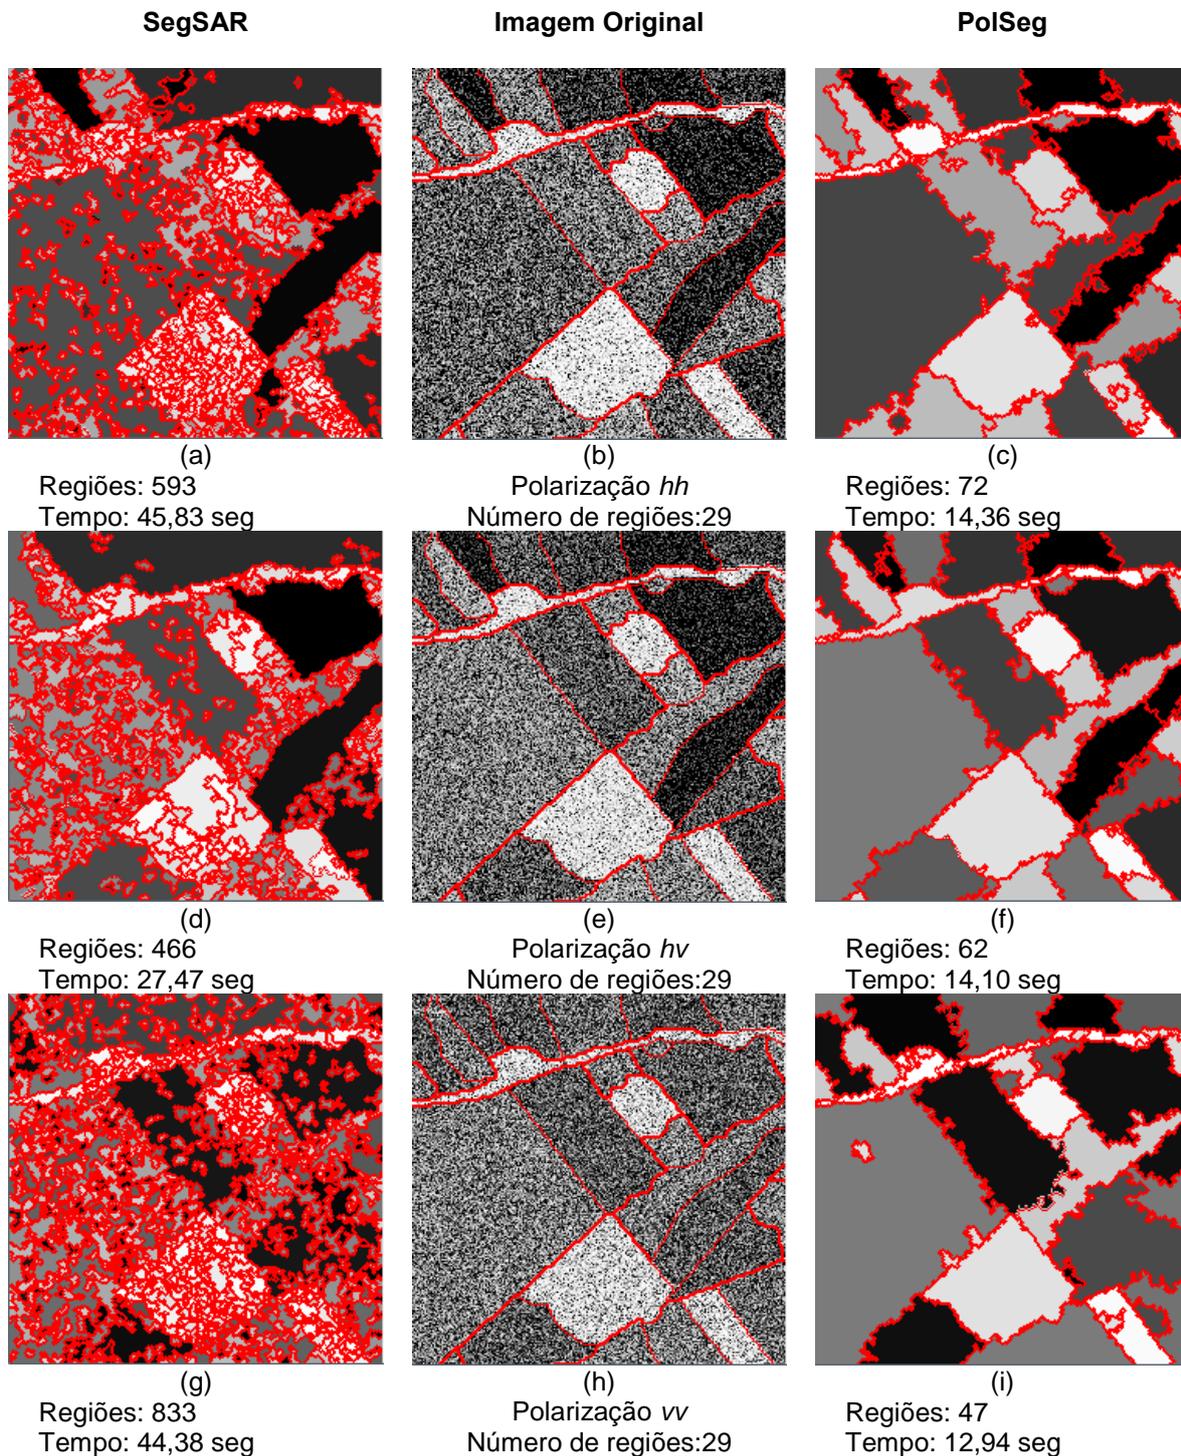


Figura 6.28 - Resultados de segmentação de uma imagem simulada: (a) SegSAR - polarização *hh*; (b) imagem original - polarização *hh*; (c) PolSeg - polarização *hh*; (d) SegSAR - polarização *hv*; (e) imagem original - polarização *hv*; (f) PolSeg - polarização *hv*; (g) SegSAR - polarização *vv*; (h) imagem original - polarização *vv*; e (i) PolSeg - polarização *vv*. Todas representadas em intensidade.

6.2. Avaliação dos resultados obtidos na segmentação de dados PolSAR e de dados multivariados polarizados em intensidade

Nesta seção é feita uma análise de duas funcionalidades do PolSeg: a segmentação através da matriz de covariância (dados PolSAR), e a segmentação através de somente os elementos da diagonal principal desta matriz (dados polarizados em intensidade). Como descrito no Capítulo 5, esta última funcionalidade permite que a segmentação seja feita utilizando os dados multivariados em intensidade. Os resultados são também comparados com os resultados obtidos pelo SegSAR utilizando os três canais de intensidade.

6.2.1. Dados PolSAR

Nesta seção são apresentados os processamentos dos dados PolSAR realizados com o PolSeg das 100 imagens simuladas, variando o número de compressão e o nível de confiança e fixando a área mínima em 15 *pixels*, a fim de analisar o comportamento do algoritmo com a alteração destes parâmetros. Também é apresentada uma descrição detalhada do processamento de uma imagem PolSAR para verificar o seu funcionamento com este tipo de informação. Além disso, é feita uma comparação dos resultados obtidos na segmentação desta imagem com os resultados gerados nos processamentos com os dados univariados em intensidade, a fim de investigar o comportamento das modelagens estatísticas adotadas para o algoritmo.

6.2.1.1. Dados PolSAR com três polarizações

Os resultados obtidos em termos de números de regiões e tempo de processamento da aplicação do algoritmo PolSeg na segmentação dos dados PolSAR formado com três polarizações, variando o nível máximo de compressão e os níveis de confiança disponíveis no algoritmo, são apresentados na Figura 6.29.

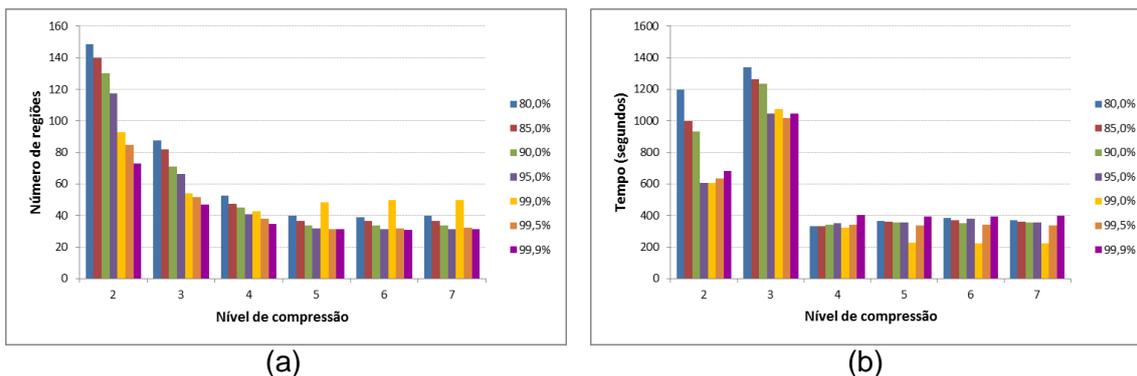


Figura 6.29 - Desempenho do PolSeg na segmentação dos dados PolSAR, segundo (a) a quantidade de regiões geradas e (b) tempo de processamento.

De modo geral percebe-se na Figura 6.29(a), para o PolSeg, com exceção para o nível de confiança de 99,0%, que com o aumento do nível de compressão e nível de confiança ocorre uma diminuição da quantidade de regiões. Este comportamento está de acordo com o que se espera do algoritmo e confirma o que já foi visto nas segmentações com dados univariados polarizados em intensidade. Na Figura 6.29(b) pode-se verificar com exceção do nível de confiança igual a 99,0%, que os tempos de processamento a partir do nível de compressão maior ou igual a quatro foram relativamente parecidos.

Os resultados da aplicação do algoritmo PolSeg com dados PolSAR em termos das medidas de ajuste definidas na Seção 3.3.1 são apresentados na Figura 6.30. Nesta figura as curvas ilustradas nos gráficos apresentam os valores calculados das medidas para cada nível de confiança ao variar o nível máximo de compressão. Os valores numéricos usados para gerar os gráficos apresentados nestas figuras podem ser encontrados no Anexo A.

Da inspeção visual dos gráficos ilustrados na Figura 6.30, nota-se que a partir do nível de compressão igual a quatro, o uso de níveis de confiança menores gerou valores mais altos para as medidas de ajuste e que a partir do nível de compressão igual a cinco os valores das medidas tenderam a se estabilizar. Além disso, nota-se que os melhores resultados dos valores das medidas de ajuste obtidas foram gerados a partir do nível de compressão igual a quatro.

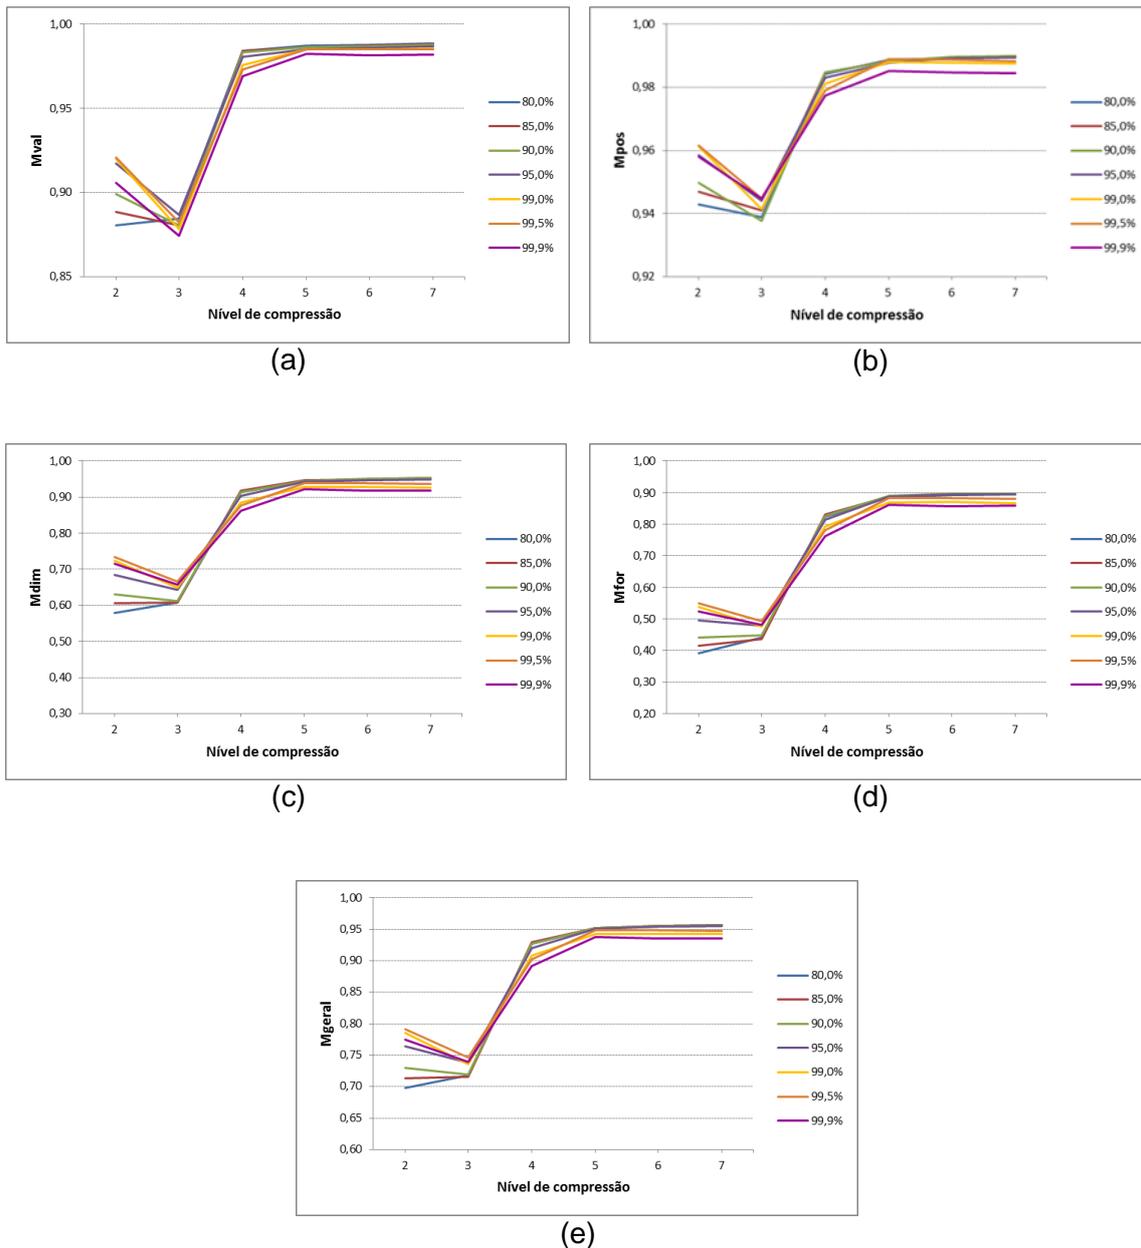


Figura 6.30 - Desempenho do PoISeg na segmentação dos dados PoISAR, segundo: (a) medida de ajuste de intensidade \bar{M}_{val} ; (b) medida de ajuste de posição \bar{M}_{pos} ; (c) medida de ajuste de dimensão \bar{M}_{dim} ; (d) medida de ajuste de forma \bar{M}_{for} ; e, (e) medida de ajuste geral \bar{M}_{geral} .

A fim de constatar estatisticamente a igualdade das medidas para os comportamentos apresentados nos valores das medidas variando o nível de compressão de quatro a sete, foram realizados testes de hipóteses (teste-Z) com nível de significância de 1%. A Tabela A.7 do Apêndice A mostram os resultados destes testes para as medidas \bar{M}_{val} , \bar{M}_{pos} , \bar{M}_{dim} , \bar{M}_{for} e \bar{M}_{geral} . Nestas tabelas as áreas em verde indicam os pares de níveis de compressão onde

para os quais as imagens segmentadas produzem valores médios das respectivas medidas, considerados estaticamente iguais ao nível de significância de 1%.

Dos resultados do teste-Z apresentados na Tabela A.7 pode-se notar que para o PolSeg os valores obtidos com as medidas de ajuste consideradas podem ser considerados estatisticamente iguais a partir de nível de compressão igual a cinco para os níveis de confiança variando de 99,0% a 99,9%. Este fato, associado aos valores altos apresentados pelas medidas de ajuste, a quantidade de regiões praticamente iguais para os níveis de compressão maiores que cinco (com níveis de confiança 99,5% e 99,9%), e ao tempo de processamento baixo (Figura 6.29), faz com que o nível de compressão igual a cinco seja considerado como o mais adequado para ser usado na segmentação com o PolSeg do conjunto de dados PolSAR.

6.2.1.1.1. Exemplo detalhado de processamento com o PolSeg

Para ilustrar o processo de segmentação executado no PolSeg, pelo qual a série de imagens PolSAR simuladas com três polarizações foi submetida, uma das imagens desta série foi selecionada e segmentada pelo algoritmo. Para esta segmentação foram usados os parâmetros que geraram os maiores valores para as medidas de ajuste analisadas, a saber, nível de compressão igual a sete, nível de confiança igual a 90,0% e área mínima de 15 *pixels*.

O resultado da segmentação da imagem selecionada está ilustrado na Figura 6.31, a qual apresenta as imagens de intensidade média das regiões geradas na segmentação para cada nível de compressão intermediário e a imagem original em intensidade submetida ao processamento, na composição $hh(R)$, $hv(G)$ e $vv(B)$.

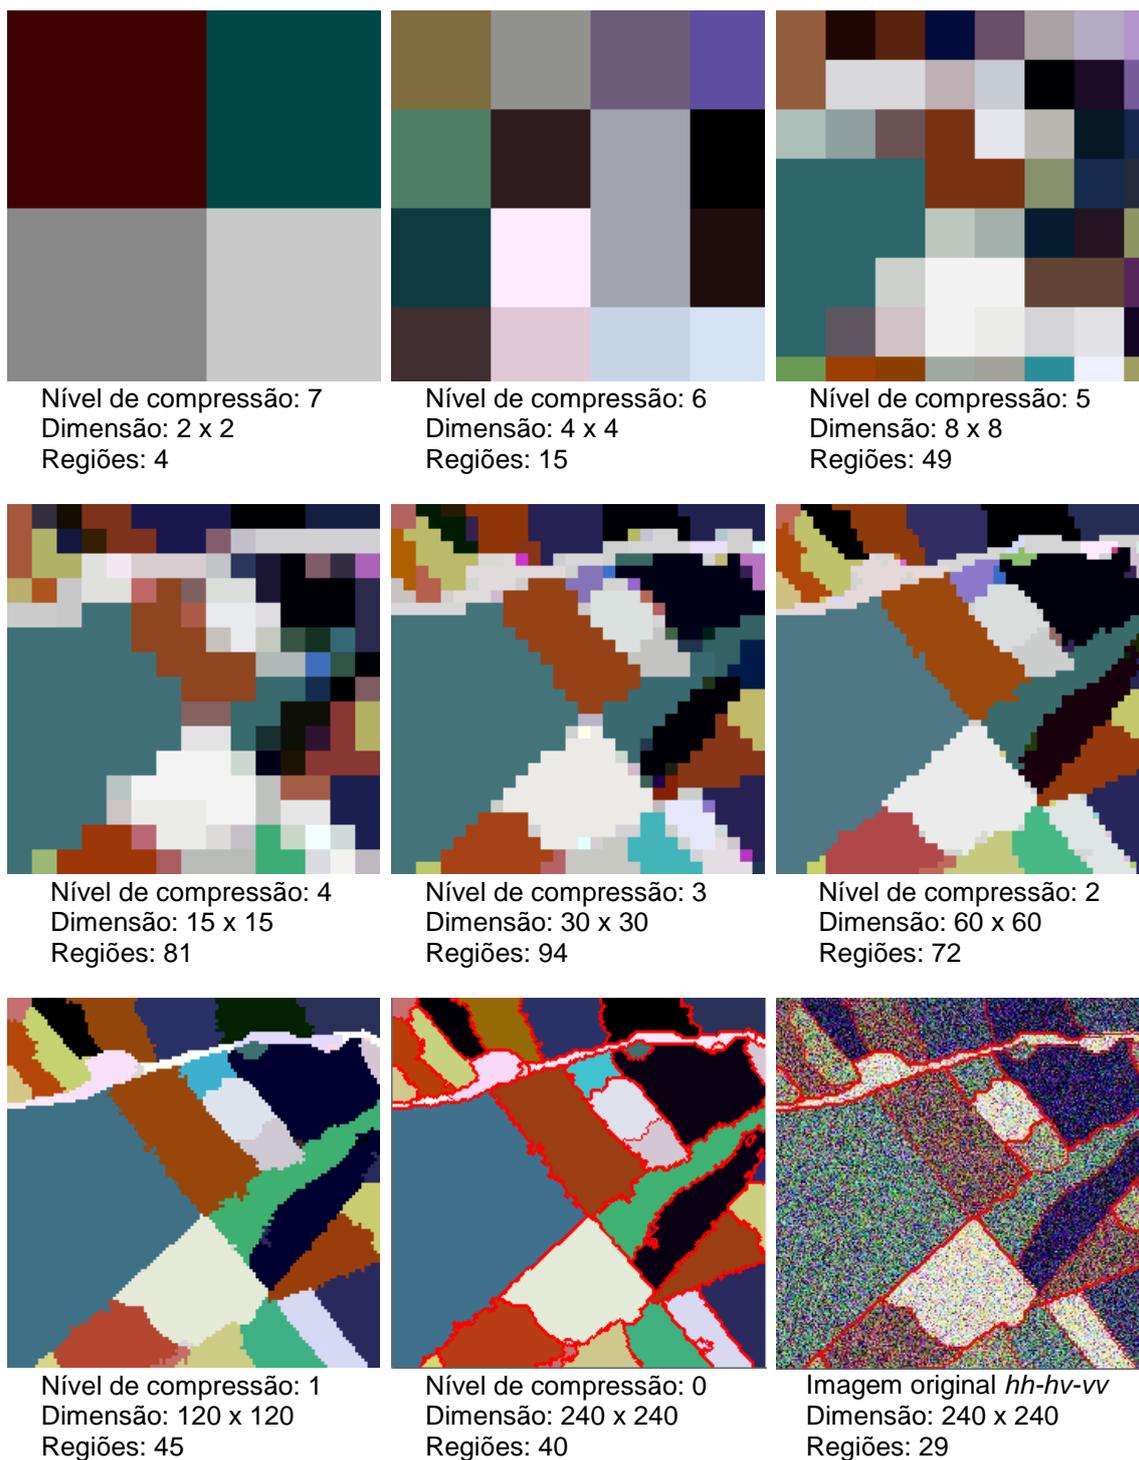


Figura 6.31 - Resultado obtido, a cada descompressão, no processo de segmentação realizado pelo PolSeg de uma imagem simulada polarimétrica formada com três polarizações, usando nível de compressão igual a sete, nível de confiança igual a 90,0% e área mínima de 15 *pixels*.

Da sequência de imagens apresentadas na Figura 6.31, pode-se notar que a obtenção da segmentação final, assim como foi visto nas segmentações dos

dados univariados polarizados em intensidade, se apresenta como um refinamento do resultado da segmentação realizada nos níveis de compressão mais altos. Pode-se verificar ainda que o resultado da segmentação da imagem polarimétrica com três polarizações foi melhor que os resultados obtidos anteriormente na segmentação de cada polarização individualmente. Isto vai de encontro com a teoria que prevê que o uso de mais atributos pode melhorar os resultados de processos de segmentação de imagens.

A Figura 6.32 apresenta as quantidades de regiões geradas, em cada nível de compressão para cada módulo de processamento do PolSeg, na segmentação da imagem PolSAR formada com as três polarizações.

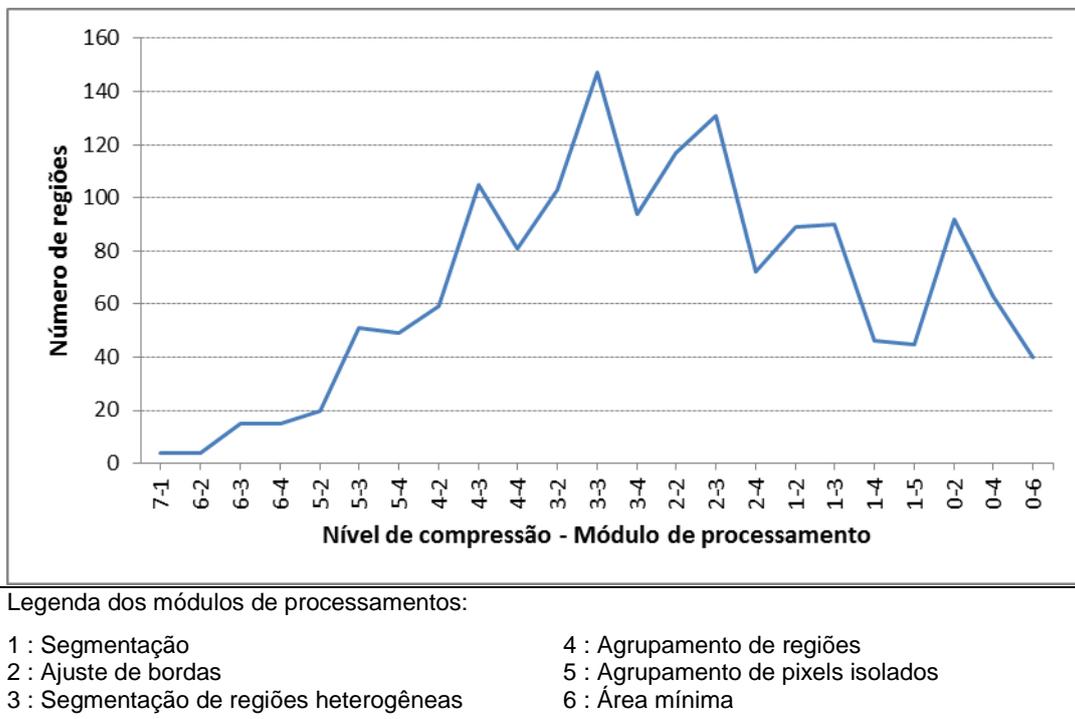


Figura 6.32 - Quantidade de regiões geradas na segmentação de uma imagem simulada polarimétrica com as três polarizações, a cada nível de compressão pelos módulos de processamentos do PolSeg, usando nível de compressão igual a sete, nível de confiança igual a 90,0% e área mínima de 15 *pixels*.

De modo geral a Figura 6.32 ilustra o mesmo comportamento apresentado na segmentação dos dados univariados polarizados em intensidade, onde foi visto que a cada execução dos módulos de ajuste de borda e segmentação de regiões heterogêneas ocorre um aumento na quantidade de regiões, enquanto

que na execução do módulo de agrupamento de regiões ocorre uma diminuição. O efeito do ruído *speckle* na segmentação executada pode ser notado após a descompressão em um nível nos níveis de compressão mais baixos, pelo aumento do número de regiões geradas nos módulos de ajuste de borda e de segmentação de regiões heterogêneas.

A Tabela 6.9 apresenta o tempo de processamento consumido em cada nível de compressão para cada módulo de processamento do PolSeg, na segmentação da imagem polarimétrica com três polarizações.

Tabela 6.9 - Tempo de processamento gasto, a cada nível de compressão pelos módulos de processamentos do PolSeg, para realizar a segmentação da imagem polarimétrica com três polarizações, com parâmetros de nível de compressão igual a sete, nível de confiança de 90,0% e área mínima de 15 *pixels*.

Nível de compressão	Módulo de processamento	Tempo (segundos)
7	segmentação	< 0,001
6	ajuste de borda	< 0,001
	segmentação de reg. heterog.	< 0,001
	agrupamento de regiões	< 0,001
5	ajuste de borda	0,032
	segmentação de reg. heterog.	0,015
	agrupamento de regiões	< 0,001
4	ajuste de borda	0,078
	segmentação de reg. heterog.	0,016
	agrupamento de regiões	0,015
3	ajuste de borda	0,265
	segmentação de reg. heterog.	0,046
	agrupamento de regiões	0,031
2	ajuste de borda	1,576
	segmentação de reg. heterog.	0,031
	agrupamento de regiões	0,125
1	ajuste de borda	15,241
	segmentação de reg. heterog.	0,016
	agrupamento de regiões	< 0,001
	agrupamento de <i>pixel</i> isolado	< 0,001
0	ajuste de borda	277,992
	agrupamento de regiões	< 0,001
	área mínima	0,016

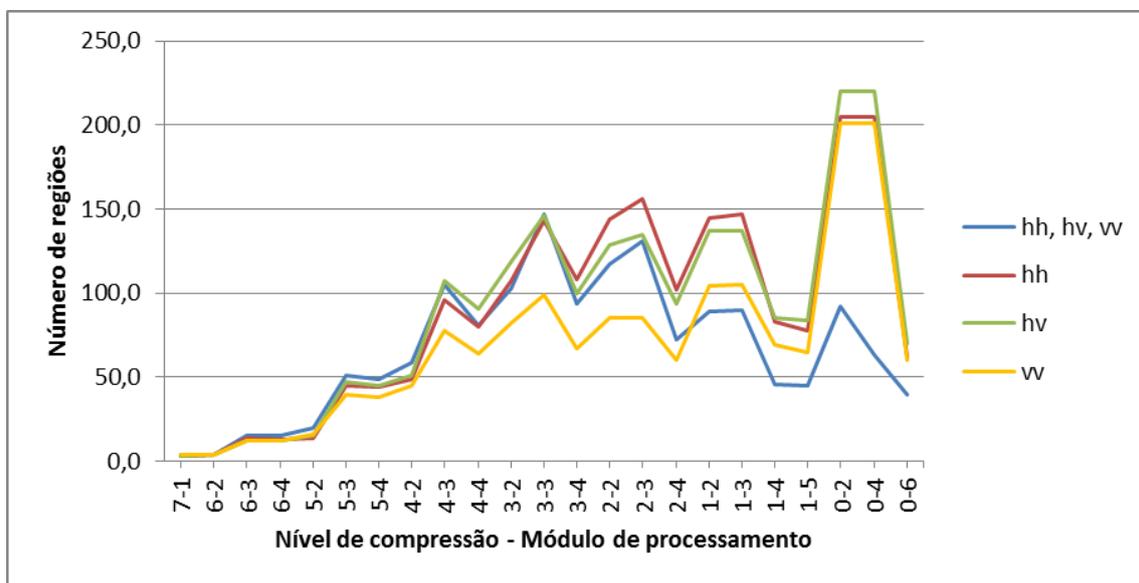
Verifica-se a partir da Tabela 6.9 que o tempo de processamento gasto na segmentação inicial foi pequeno ($< 0,001$ seg), o que decorre da pequena dimensão da imagem no nível de compressão igual a sete. Nota-se também que os custos computacionais, em termos de tempo, dos módulos de segmentação de regiões heterogêneas e agrupamento de regiões foram menores que o custo apresentado pelo módulo de ajuste de bordas, o que indica que este módulo de processamento tem maior contribuição no tempo total de processamento.

6.2.1.1.2. Comparação de resultados do PolSeg: dados PolSAR versus dados univariados polarizados em intensidade

A Figura 6.33 apresenta uma comparação da quantidade de regiões geradas nos módulos de processamento do PolSeg a cada descompressão, durante a segmentação da imagem polarimétrica com três polarizações e durante as segmentações das imagens univariadas polarizadas em intensidade. Os parâmetros de segmentação adotados para gerar os resultados contidos nesta figura foram os que geraram os maiores valores para as medidas de ajuste analisadas com o uso de três polarizações (nível de compressão igual a sete, nível de confiança igual a 90,0% e área mínima de 15 *pixels*).

Conforme ilustrado na Figura 6.33, o que se nota de modo geral é que os módulos de processamento do PolSeg apresentam comportamentos similares para a geração de regiões tanto para segmentação de dados PolSAR formados por três bandas como para dados univariados polarizados em intensidade. Além disso, nota-se que até o nível de compressão igual a quatro a quantidade de regiões geradas na segmentação da imagem PolSAR formada com três polarizações foi maior que as quantidades geradas nas segmentações das imagens univariadas polarizadas em intensidade. A partir deste nível de compressão verifica-se que os valores gerados na segmentação com dados PolSAR começam a diminuir. Nota-se ainda que nos níveis igual a um, o número de regiões ficou abaixo das quantidades geradas nas segmentações das três imagens em intensidade.

Os fatos observados na Figura 6.33 indicam que o uso dos dados PolSAR formado por três polarizações permitiu uma melhor definição dos segmentos existentes na imagem ao longo do processamento, resultando ao final deste em uma quantidade de regiões mais próxima a quantidade existente na imagem de referencia. Por sua vez, as quantidades de regiões relativamente próximas encontradas no final do processamento e o comportamento similar na criação de regiões durante o processamento, atesta a validade das duas modelagens estatísticas usadas no algoritmo para realizar a segmentação dos dados SAR.



Legenda dos módulos de processamentos:

1 : Segmentação	4 : Agrupamento de regiões
2 : Ajuste de bordas	5 : Agrupamento de pixels isolados
3 : Segmentação de regiões heterogêneas	6 : Área mínima

Figura 6.33 - Quantidade de regiões geradas na segmentação de uma imagem simulada com três bandas nas polarizações *hh-hv-vv* e na segmentação da mesma imagem simulada para cada polarização individualmente, com os parâmetros que apresentaram os melhores resultados para a medida de ajuste geral, a cada nível de compressão pelos módulos de processamentos do PolSeg.

Quando se compara o tempo de processamento gasto pelo módulo de ajuste de borda obtidos na segmentação dos dados PolSAR formada com três polarizações com os valores obtidos na segmentação das imagens polarizadas univariadas em intensidade (Tabela 6.10) verifica-se que a primeira demandou

mais tempo de processamento. Este tempo elevado é decorrente do uso de mais informações para serem processadas, pois deve se ter em mente que os cálculos para realizar o ajuste de borda sobre os dados PolSAR são realizados sobre as informações contidas nas matrizes de covariância complexa.

Tabela 6.10 - Tempo de processamento gasto, a cada nível de compressão pelos módulos de processamentos do PolSeg, para realizar a segmentação da imagem PolSAR formada com três polarizações e imagens univariadas polarizadas em intensidade com polarizações *hh*, *hv* e *vv*, com parâmetros de nível de compressão igual a sete, nível de confiança de 90,0% e área mínima de 15 *pixels*.

Nível de compressão	Módulo de processamento	Tempo (segundos)			
		<i>hh, hv, vv</i>	<i>hh</i>	<i>hv</i>	<i>vv</i>
7	segmentação	< 0,001	0,047	0,063	0,047
6	ajuste de borda	< 0,001	< 0,001	< 0,001	< 0,001
	segmentação de reg. heterog.	< 0,001	0,093	0,110	0,125
	agrupamento de regiões	< 0,001	0,281	0,296	0,281
5	ajuste de borda	0,032	< 0,001	< 0,001	< 0,001
	segmentação de reg. heterog.	0,015	0,327	0,296	0,266
	agrupamento de regiões	< 0,001	0,968	0,889	0,780
4	ajuste de borda	0,078	0,016	0,016	0,015
	segmentação de reg. heterog.	0,016	0,484	0,515	0,406
	agrupamento de regiões	0,015	1,450	1,607	1,248
3	ajuste de borda	0,265	0,047	0,047	0,047
	segmentação de reg. heterog.	0,046	0,328	0,359	0,187
	agrupamento de regiões	0,031	1,736	1,560	1,482
2	ajuste de borda	1,576	0,140	0,125	0,109
	segmentação de reg. heterog.	0,031	0,062	0,047	0,015
	agrupamento de regiões	0,125	1,186	1,404	1,264
1	ajuste de borda	15,241	0,468	0,296	0,265
	segmentação de reg. heterog.	0,016	< 0,001	< 0,001	< 0,001
	agrupamento de regiões	< 0,001	1,529	1,389	1,576
	agrupamento de <i>pixel</i> isolado	< 0,001	< 0,001	< 0,001	< 0,001
0	ajuste de borda	277,992	0,936	0,936	0,842
	agrupamento de regiões	< 0,001	< 0,001	< 0,001	< 0,001
	área mínima	0,016	0,128	0,125	0,109

Da análise realizada para a quantidade de regiões geradas em cada nível de compressão por cada módulo de processamento, pode-se constatar que os testes estatísticos usados pelo algoritmo para segmentar as dados PolSAR

formado com três polarizações e dados polarizados univariados em intensidade têm comportamentos similares durante o processamento. Constata-se ainda que a quantidade maior de informações usadas na segmentação, existentes nos dados PolSAR, interferiu significativamente no aumento de tempo de processamento do PolSeg.

6.2.1.2. Dados PolSAR com par de polarizações

Os resultados das três segmentações realizadas com o PolSeg com as três combinações de pares de polarizações das imagens PolSAR simuladas (*hh-hv*, *hh-vv* e *hv-vv*) em termos de números de regiões e tempo de processamento são apresentados na Figura 6.34.

Os resultados para as medidas de ajuste (Seção 3.3.1) obtidos na segmentação realizada com o PolSeg com as 100 imagens simuladas das três combinações de pares de polarizações *hh-hv*, *hh-vv* e *hv-vv* são apresentados respectivamente na Figura 6.35, Figura 6.36 e Figura 6.37. Os valores numéricos usados para gerar os gráficos apresentados nestas figuras podem ser encontrados no Anexo A.

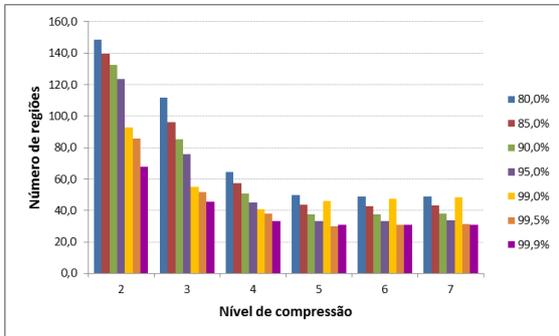
Dos gráficos apresentados na Figura 6.35, Figura 6.36 e Figura 6.37, pode-se notar que a partir do nível de compressão igual a cinco os valores das medidas tenderam a se estabilizar. Os testes de hipóteses realizados (teste-Z) com nível de significância de 1%, documentados nas Tabelas A.9, A.10 e A.11 do Apêndice, mostrou que pode-se supor que a partir do nível de compressão igual a cinco os valores das medidas de ajuste podem ser considerados estatisticamente iguais para todas as combinações de pares de polarizações. Este fato associado aos valores altos obtidos para as medidas de ajuste neste nível de compressão, a quantidade de pequena de regiões geradas e a estabilização do tempo de processamento, indicam o nível de compressão igual ou maiores que a cinco como os mais adequados para serem usados no PolSeg na segmentação das imagens PolSAR simuladas com os pares de polarizações *hh-hv*, *hh-vv* e *hv-vv*.

A Tabela 6.11 apresenta as combinações de parâmetros de segmentação que geraram os valores mais elevados para a medida de ajuste geral na segmentação das combinações dos pares de polarizações *hh-hv*, *hh-vv* e *hv-vv*, formados pelo conjunto das 100 imagens PolSAR simuladas.

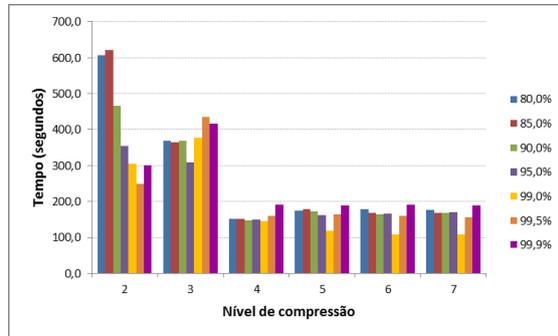
Tabela 6.11 - Parâmetros de segmentação do PolSeg usados na geração do melhor resultado para a medida de ajuste geral \bar{M}_{geral} , no processamento das imagens PolSAR simuladas com os pares de polarização *hh-hv*, *hh-vv* e *hv-vv*.

Polarizações da imagem	Nível de compressão	Nível de confiança	Área mínima	\bar{M}_{geral}
<i>hh-hv</i>	7	95,0%	15	0,9451
<i>hh-vv</i>	6	90,0%	15	0,9369
<i>hv-vv</i>	7	90,0%	15	0,9259

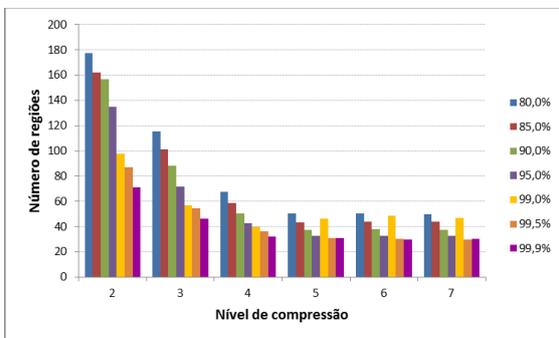
A realização do teste-Z, não apresentado aqui, mostrou que o a combinação de polarizações que gerou o valor mais elevado de ajuste para a medida de ajuste geral foi formada pelo par de polarizações *hh-hv*.



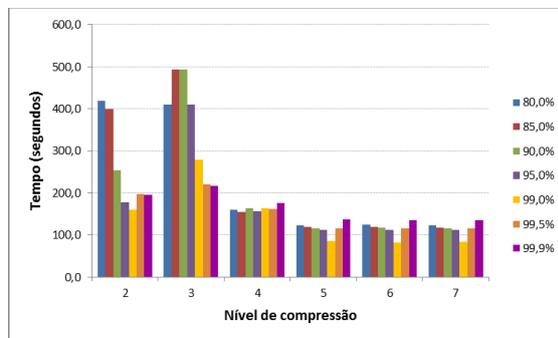
(a)



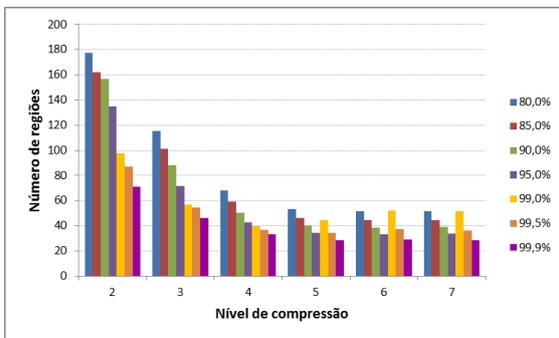
(b)



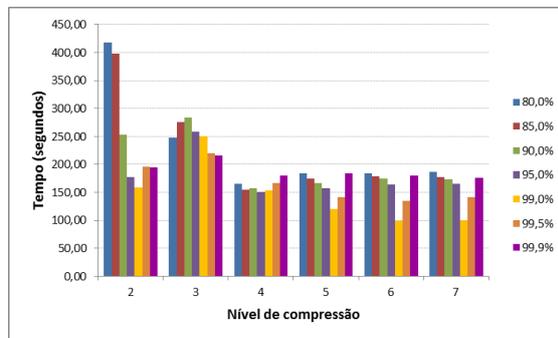
(c)



(d)



(e)



(f)

Figura 6.34 - Desempenho do PolSeg na segmentação dos dados polarimétricos com duas polarizações: (a) quantidade de regiões geradas e (b) o tempo de processamento, com par de polarizações $hh-hv$; (c) quantidade de regiões geradas e (d) o tempo de processamento, com par de polarizações $hh-vv$; (e) quantidade de regiões geradas e (f) o tempo de processamento, com par de polarizações $hv-vv$.

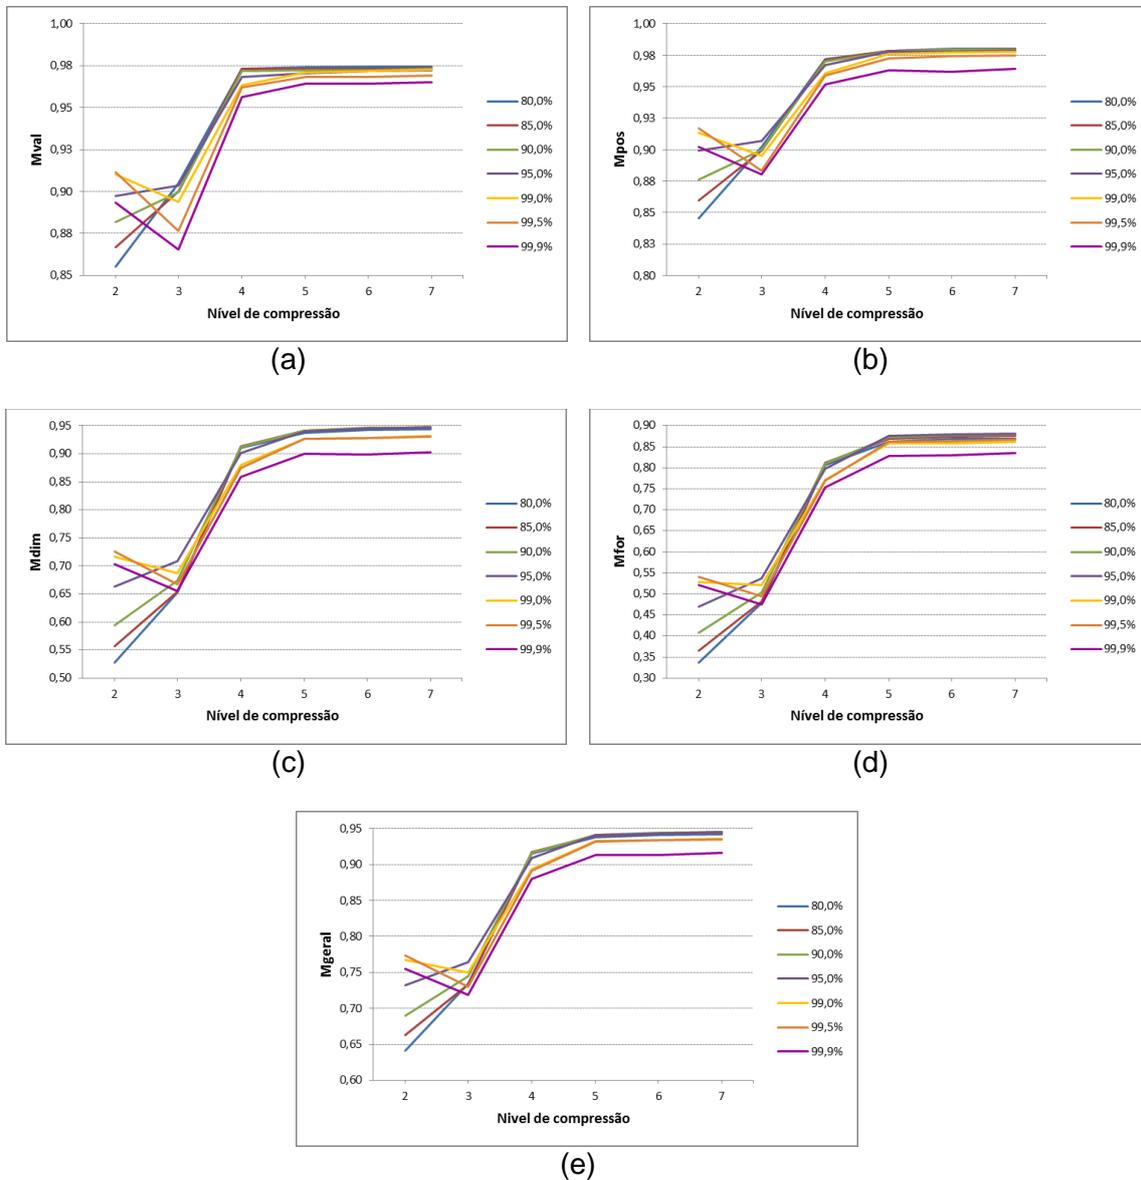


Figura 6.35 - Desempenho do PoISeg, segundo as medidas de ajuste de (a) intensidade \bar{M}_{val} , (b) posição \bar{M}_{pos} , (c) dimensão \bar{M}_{dim} , (d) forma \bar{M}_{for} e (e) geral \bar{M}_{geral} , na segmentação das imagens simuladas com duas bandas nas polarizações $hh-hv$.

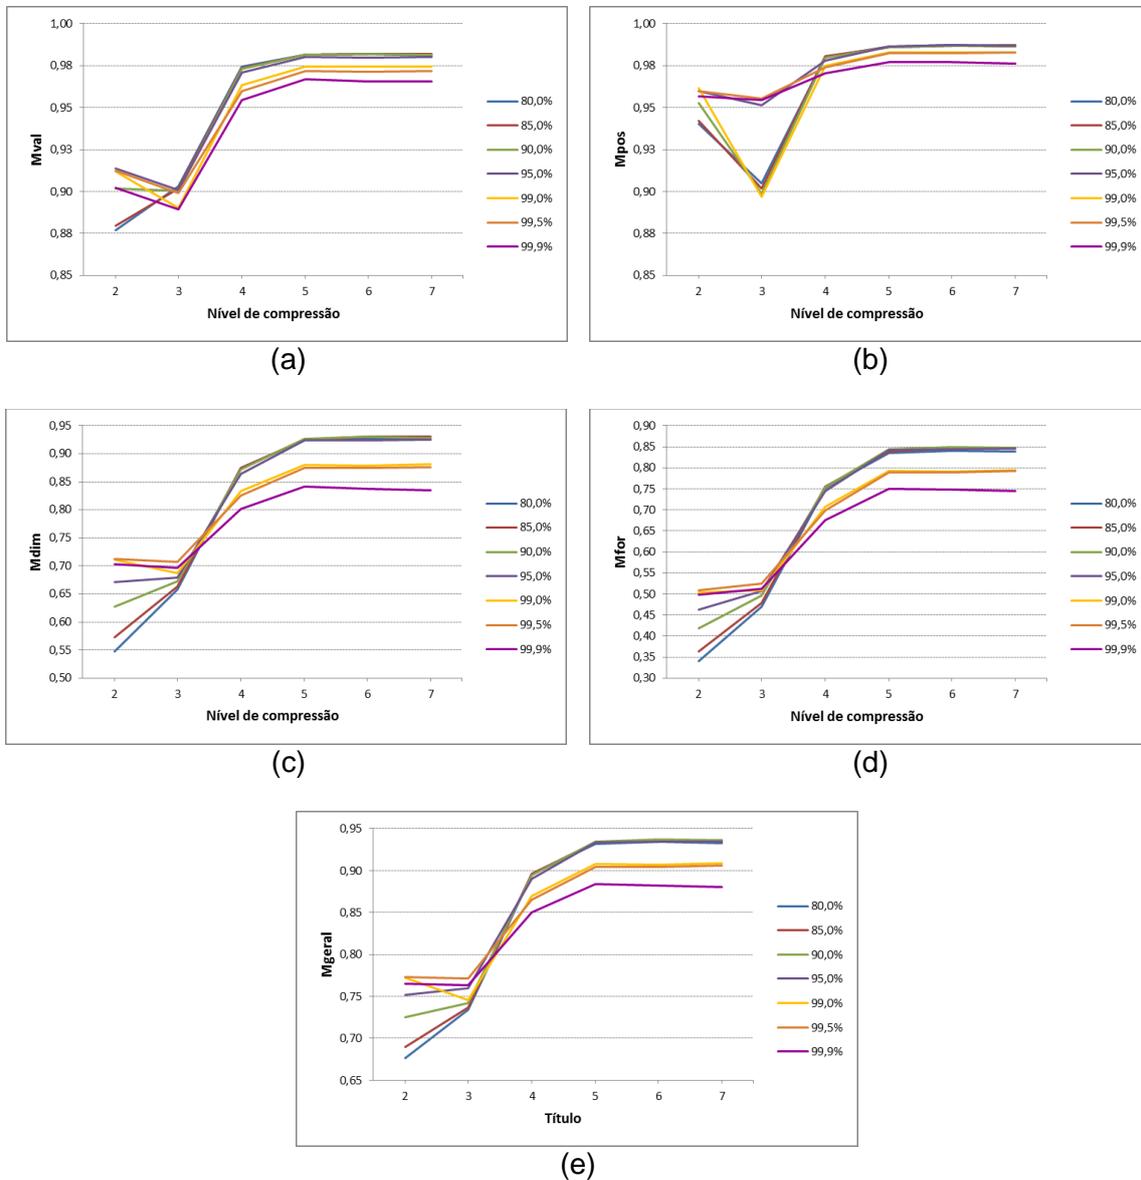


Figura 6.36 - Desempenho do PoISeg, segundo as medidas de ajuste de (a) intensidade \bar{M}_{val} , (b) posição \bar{M}_{pos} , (c) dimensão \bar{M}_{dim} , (d) forma \bar{M}_{for} e (e) geral \bar{M}_{geral} , das imagens simuladas com duas bandas nas polarizações hh - vv .

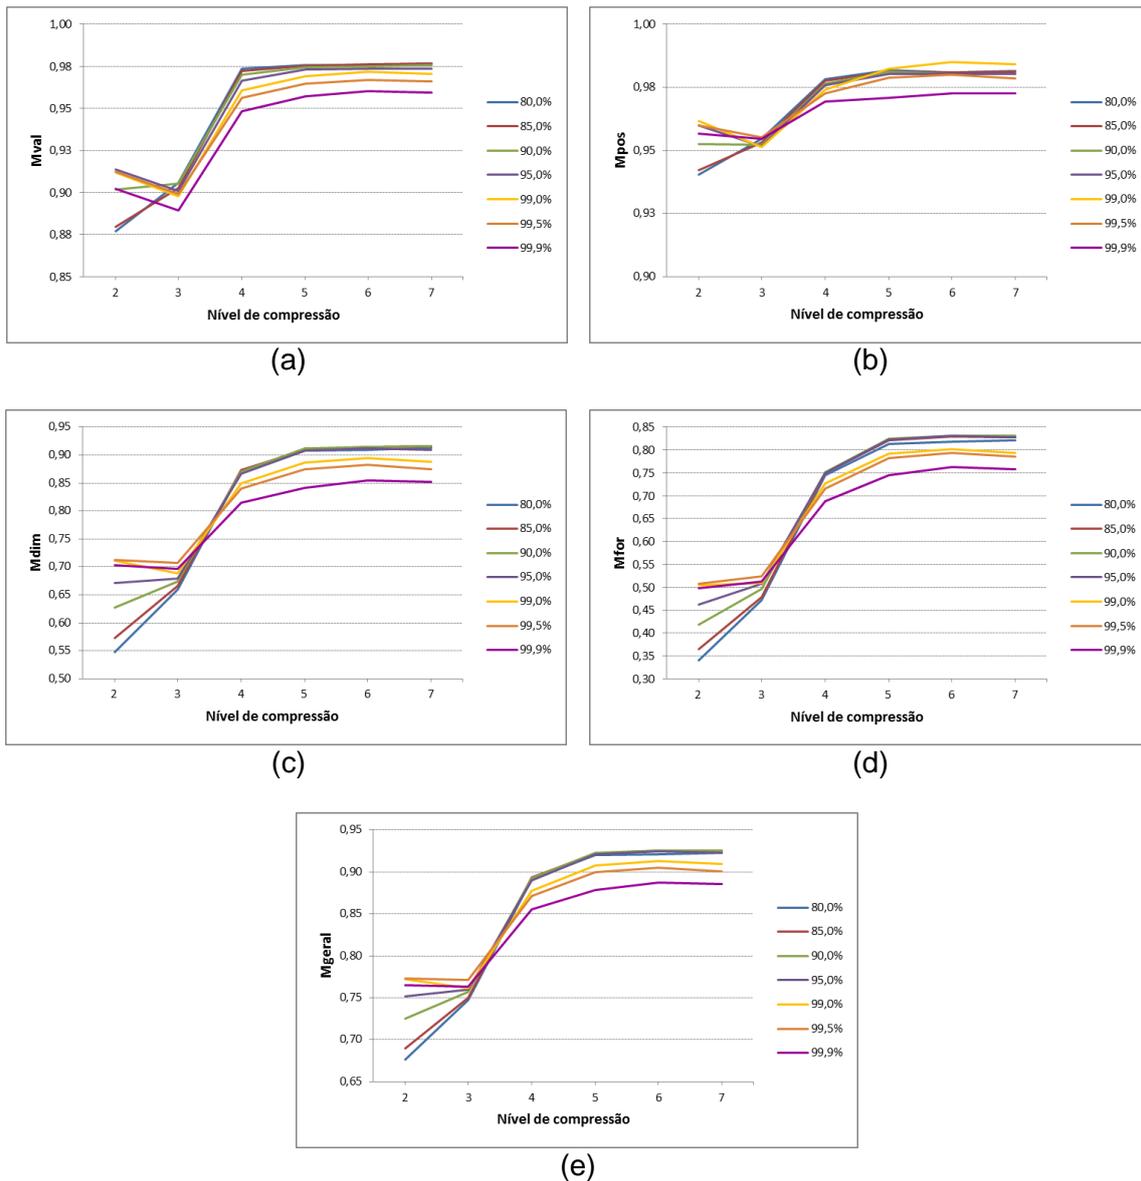


Figura 6.37 - Desempenho do PolSeg, segundo as medidas de ajuste de (a) intensidade \bar{M}_{val} , (b) posição \bar{M}_{pos} , (c) dimensão \bar{M}_{dim} , (d) forma \bar{M}_{for} e (e) geral \bar{M}_{geral} , na segmentação das imagens simuladas com duas bandas nas polarizações $hv-vv$.

6.2.1.2.1. Comparação de resultados do PolSeg: dados PolSAR com três polarizações versus par de polarizações

A Figura 6.38 ilustra o resultado da segmentação realizada no PolSeg de uma imagem PolSAR simulada selecionada formada com o par de polarizações $hh-hv$ e o resultado obtido na segmentação da imagem com três polarizações.

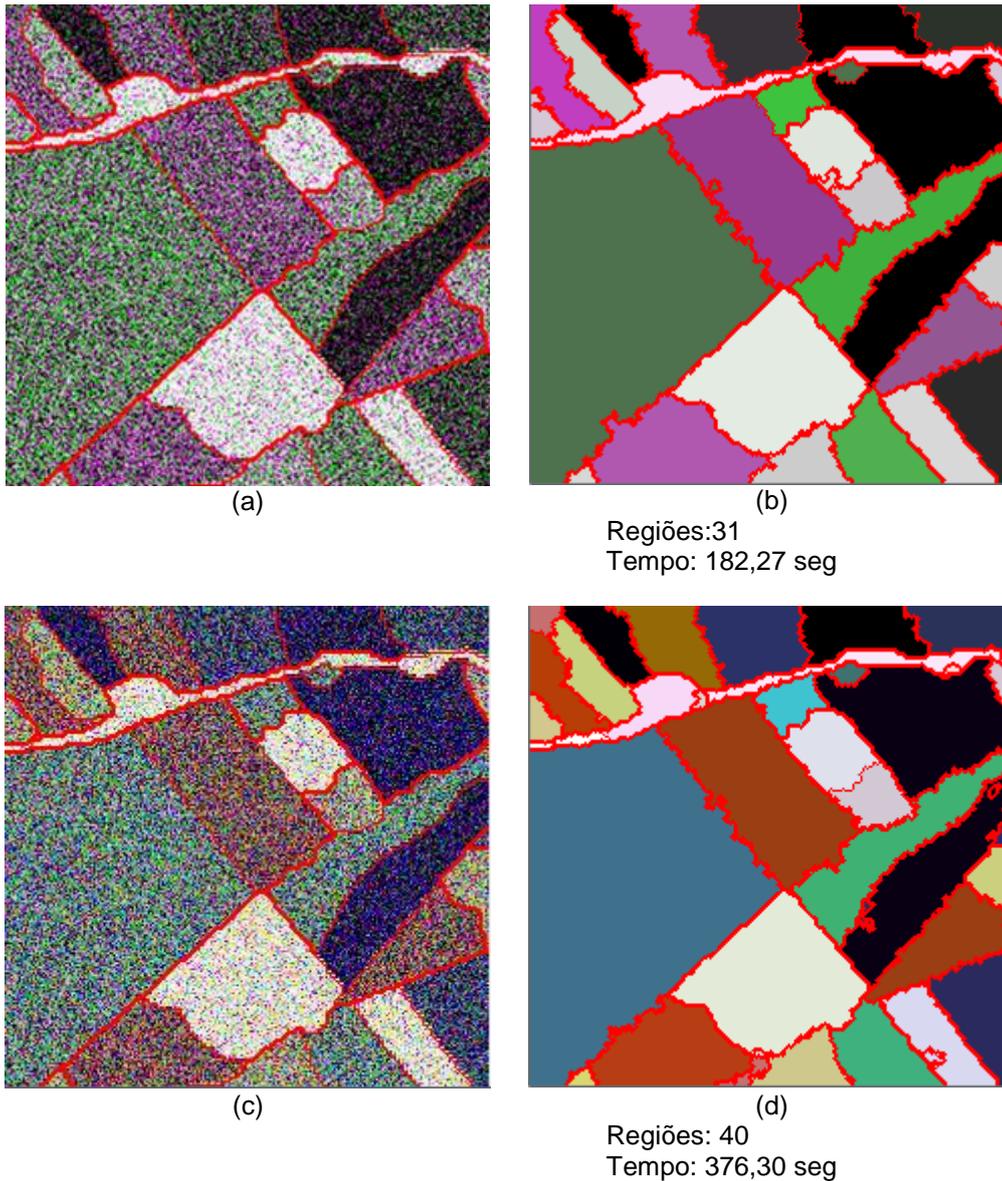


Figura 6.38 – Resultados de processamento obtidos com o PolSeg: (a) imagem polarimétrica simulada com o par de polarizações $hh-hv$ e respectiva (b) imagem segmentada, representada em intensidade na composição colorida $hh(R)$, $hv(G)$, $hh(B)$; e, (c) imagem polarimétrica com três polarizações e respectiva imagem segmentada, representada em intensidade na composição colorida $hh(R)$, $hv(G)$, $vv(B)$.

A Tabela 6.12 apresenta os maiores valores das medidas de ajuste obtidas na segmentação das imagens PolSAR com o par de polarizações $hh-hv$ e três polarizações.

Tabela 6.12 - Valores das medidas de ajuste obtidos na segmentação das imagens PolSAR com as polarizações *hh-hv* e *hh-hv-vv*, usando os parâmetros que geraram os valores mais elevados para a medida de ajuste geral.

Medida	<i>hh-hv</i>		<i>hh-hv-vv</i>	
	média	desv. pad.	média	desv. pad.
\bar{M}_{val}	0,9723	0,0064	0,9878	0,0034
\bar{M}_{pos}	0,9791	0,0086	0,9898	0,0029
\bar{M}_{dim}	0,9470	0,0208	0,9533	0,0142
\bar{M}_{for}	0,8820	0,0203	0,8980	0,0132
\bar{M}_{geral}	0,9451	0,0128	0,9572	0,0080

A realização do teste-Z com nível de significância de 1%, não apresentado aqui, mostrou que somente o valor da medida de ajuste pode ser considerado estatisticamente igual. Este fato mostra que o uso de duas polarizações na segmentação dos dados PolSAR simulados não foi capaz de gerar as regiões obtidas com a segmentação dos dados PolSAR com três polarizações. Entretanto, cabe ressaltar, que apesar disso, os resultados obtidos com o par de polarizações *hh-hv* foram significativos e geraram regiões consistentes conforme pode ser visto na Figura 6.1.

6.2.2. Dados multivariados polarizados em intensidade

Nesta subseção são apresentados os processamentos dos dados polarizados multivariados em intensidade realizados com os algoritmos PolSeg e SegSAR. Também é apresentada a comparação dos processamentos no PolSeg, usando dados PolSAR e dados multivariados polarizados em intensidade, e a comparação dos processamentos realizados no PolSeg e SegSAR. A primeira comparação foi feita com o intuito de verificar se os resultados obtidos com dados polarizados multivariados em intensidade são consistentes e se o uso da informação polarimétrica permite obter melhores resultados. A comparação com o SegSAR, por sua vez, foi realizada para verificar se a modelagem estatística adotada para o PolSeg acarreta em melhor desempenho na segmentação.

O objetivo destas análises, além de avaliar o desempenho do PolSeg com dados PolSAR e multivariados polarizados em intensidade, foi avaliar a relevância da informação adicional da fase, contida nos dados complexos, para a segmentação, e a importância da modelagem estatística mais rigorosa do PolSeg em comparação com a do SegSAR.

6.2.2.1. Comparação de resultados do PolSeg: dados PolSAR versus dados multivariados polarizados em intensidade

Após identificar para o PolSeg a configuração de parâmetros que apresentou melhores resultados para a segmentação do conjunto de dados PolSAR, realizou-se uma série de segmentações, usando estes parâmetros, para segmentar novamente o conjunto de imagens simuladas representadas agora por dados polarizados multivariados em intensidade. Este processamento foi realizado a fim de verificar a consistência dos resultados obtidos somente com imagens polarizadas em intensidade, uma vez que nem sempre os dados complexos estão disponíveis para uso.

Os resultados da aplicação do PolSeg com as imagens PolSAR e com as imagens polarizadas em intensidade, representadas pela matriz de covariância diagonal são apresentados na Tabela 6.13.

Tabela 6.13 - Valores para as medidas de ajuste de intensidade \bar{M}_{val} , de posição \bar{M}_{pos} , \bar{M}_{dim} , de forma \bar{M}_{for} e geral \bar{M}_{geral} obtidos a partir dos resultados da segmentação no PolSeg das imagens PolSAR simuladas e imagens polarizadas em intensidade, usando sete níveis de compressão, nível de confiança de 90,0% e área mínima de 15 *pixels*.

Medida de ajuste	Imagem PolSAR		Imagem polarizada multivariada em intensidade	
	média	desv. pad.	média	desv. pad.
\bar{M}_{val}	0,9878	0,0034	0,9815	0,0066
\bar{M}_{pos}	0,9898	0,0029	0,9850	0,0066
\bar{M}_{dim}	0,9533	0,0142	0,9336	0,0241
\bar{M}_{for}	0,8980	0,0132	0,8750	0,0226
\bar{M}_{geral}	0,9572	0,0080	0,9438	0,0143

Nota-se na Tabela 6.13 que os valores das medidas de ajuste obtidos na segmentação das imagens polarizadas em intensidade, apesar de serem menores, foram muito próximos aos obtidos na segmentação com dados PolSAR. A fim de verificar a igualdade estatística dos valores apresentados nesta tabela usou-se o teste-Z com nível de significância de 1%, cujo resultado é apresentado na Tabela 6.14.

Tabela 6.14 - Valores da estatística Z e valor-p para as medidas de ajuste de intensidade \bar{M}_{val} , de posição \bar{M}_{pos} , de dimensão \bar{M}_{dim} , de forma \bar{M}_{for} e geral \bar{M}_{geral} obtidas a partir dos resultados da segmentação no PolSeg dos dados PolSAR, e dados polarizados em intensidade, usando os parâmetros sete níveis de compressão, nível de confiança de 90,0% e área mínima de 15 pixels.

Estatística	Medida de ajuste				
	\bar{M}_{val}	\bar{M}_{pos}	\bar{M}_{dim}	\bar{M}_{for}	\bar{M}_{geral}
Z	8,475	6,539	7,039	8,752	8,192
valor-p	0,000	0,000	0,000	0,000	0,000

Os valores apresentados na Tabela 6.14 mostram que os resultados obtidos na segmentação dos dois dados, embora pareçam muito próximos, não podem ser considerados estatisticamente iguais. Mostram ainda que os valores obtidos na segmentação com o PolSeg dos dados PolSAR foram estatisticamente melhores que os resultados obtidos na segmentação com dados polarizados multivariados em intensidade. Este fato comprova que o uso da informação de fase contida nos dados PolSAR foi relevante para a definição das regiões existentes na imagem simulada.

Com relação a quantidade média de regiões geradas, a segmentação do conjunto das 100 imagens simuladas polarizadas em intensidade gerou a 29,6 regiões, enquanto o valor médio gerado na segmentação do conjunto de dados PolSAR simulados foi de 33,6 regiões. O tempo médio de processamento, por sua vez, foram respectivamente 340,59 e 357,81 segundos.

A Figura 6.39 apresenta uma imagem simulada PolSAR, selecionada do conjunto de dados processado, representada em intensidade na composição

colorida $hh(R)$, $hv(G)$, $vv(B)$, com os contornos das regiões, e os resultados das segmentações obtidos com o PolSeg, usando os dados PolSAR formados com três polarizações e os dados polarizados multivariados em intensidade.

A inspeção visual das imagens apresentadas na Figura 6.39 mostra que as definições das bordas das regiões obtidas nas segmentações em ambos os resultados, apesar do aspecto ruidoso, se aproximam muito dos contornos das regiões de referência. Este fato confere com os altos valores encontrados nas medidas de ajuste usadas na avaliação quantitativa para ambos os resultados.

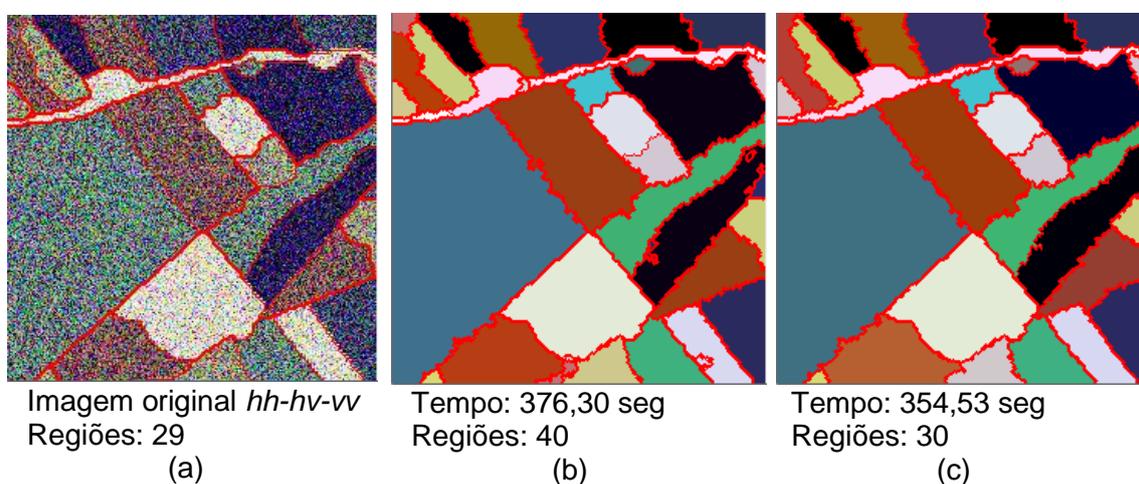
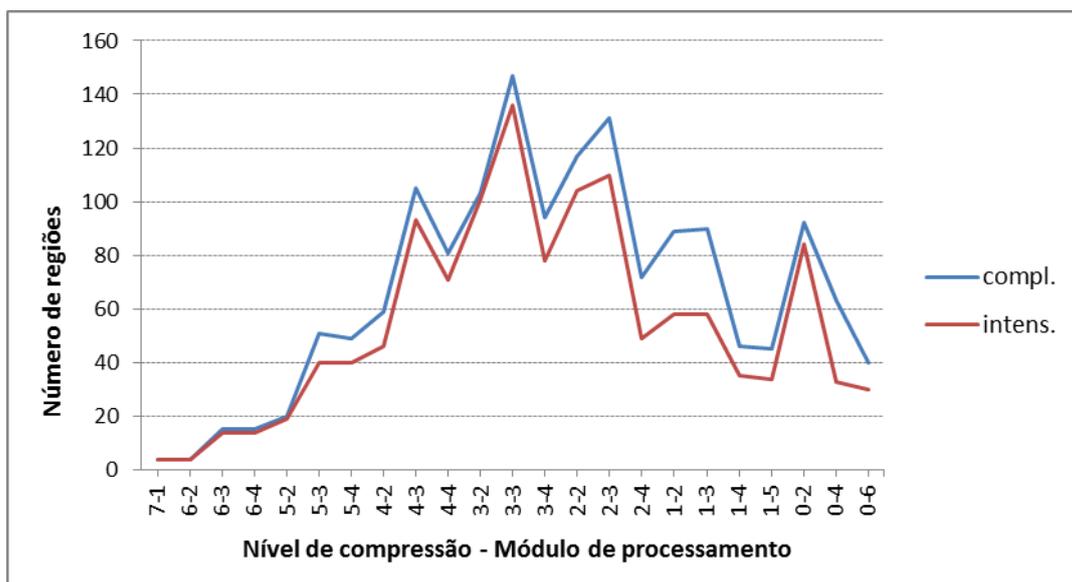


Figura 6.39 – Exemplo de (a) imagem simulada polarimétrica com três polarizações, com os contornos das regiões, submetida a segmentação e resultados da segmentação no PolSeg (b) usando os dados PolSAR, e (c) usando dados polarizados em intensidade, com parâmetros de nível de compressão igual a sete, nível de confiança de 90,0% e área mínima de 15 pixels.

Em termos de número de regiões, a Figura 6.39 mostra que a segmentação realizada com imagens multivariadas polarizadas em intensidade foi mais eficiente, pois a quantidade de regiões geradas (30) foi mais próxima a quantidade de regiões existente na imagem de referência (29 regiões). Este fato mostra que a imagem PolSAR tende a gerar uma segmentação com mais regiões, devido à influência da informação contida nos canais fora da diagonal principal da matriz de covariância complexa.

A inconsistência verificada entre a quantidade de regiões geradas e os valores das medidas de ajuste, mostra que há a necessidade de explorar o uso de outras medidas de avaliação quando se pretende levar em consideração na avaliação a quantidade de regiões geradas na segmentação. Isto se deve porque as medidas de ajuste desenvolvidas por Delves et al (1992) não leva em consideração este parâmetro de avaliação para computar os valores finais das medidas.

A Figura 6.40 apresenta as quantidades de regiões geradas em cada nível de compressão para cada módulo de processamento do PolSeg, para a imagem selecionada, na segmentação realizada com os dados PolSAR e dados polarizados em intensidade.



Legenda dos módulos de processamentos:	
1 : Segmentação	4 : Agrupamento de regiões
2 : Ajuste de bordas	5 : Agrupamento de pixels isolados
3 : Segmentação de regiões heterogêneas	6 : Área mínima

Figura 6.40 - Quantidade de regiões geradas, a cada nível de compressão pelos módulos de processamentos do PolSeg, na segmentação da imagem simulada polarimétrica e imagem polarizada em intensidade, ambas

com três polarizações, usando nível de compressão igual a 7, nível de confiança de 90,0% e área mínima de 15 *pixels*.

A Figura 6.40 mostra que a quantidade de regiões geradas na segmentação da imagem PolSAR foi maior que a quantidade de regiões geradas na segmentação da imagem polarizada em intensidade para os níveis de compressão menores que sete. Isto indica que nestes níveis o dado polarimétrico apresentou menor homogeneidade fazendo com que fossem obtidas mais regiões durante o processo de segmentação. Como o vetor de espalhamento é usado para formar a matriz de covariância, que é a informação segmentada, o prejuízo no desempenho pode estar relacionado aos elementos localizados fora da diagonal principal desta matriz. Estes elementos geralmente possuem valores pequenos quando comparados com os elementos da diagonal, entretanto, conforme constatado no resultado final da segmentação, podem acarretar em um aumento do ruído na imagem o que gerou um número maior de regiões ao término do processamento.

A Tabela 6.15 apresenta o tempo de processamento consumido em cada nível de compressão para cada módulo de processamento do PolSeg, para a imagem simulada selecionada, na segmentação realizada com os dados PolSAR e dados polarizados em intensidade.

Os resultados apresentados na Tabela 6.15 mostram que os tempos de processamento obtidos na segmentação foram relativamente baixos até o nível de compressão igual a dois. Percebe-se até este nível que o maior tempo foi obtido no módulo de ajuste de borda, o qual nos níveis de compressão igual a um e zero assumiu valores expressivamente altos.

Quando comparado o tempo total de processamento obtido na segmentação dos dados PolSAR (376,30 segundos) e polarizados em intensidade (354,53 segundos), se verifica que a segmentação com dados polarimétricos demandou uma maior quantidade de tempo. Este fato está de acordo com a quantidade de regiões geradas e agrupadas durante o processo de segmentação do dado PolSAR.

Tabela 6.15 - Tempo de processamento demandado a cada nível de compressão pelos módulos de processamentos do PolSeg, para realizar a segmentação da imagem PolSAR e multivariada polarizada em intensidade, ambas com três polarizações, com nível de compressão igual a sete, nível de confiança de 90,0% e área mínima de 15 *pixels*.

Nível de compressão	Módulo de processamento	Tempo (segundos)	
		PolSAR.	intens.
7	Segmentação	< 0,001	< 0,001
6	ajuste de borda	< 0,001	< 0,001
	segmentação de reg. heterog.	< 0,001	< 0,001
	agrupamento de regiões	< 0,001	< 0,001
5	ajuste de borda	0,032	0,016
	segmentação de reg. heterog.	0,015	0,000
	agrupamento de regiões	< 0,001	< 0,001
4	ajuste de borda	0,078	0,063
	segmentação de reg. heterog.	0,016	0,031
	agrupamento de regiões	0,015	0,016
3	ajuste de borda	0,265	0,312
	segmentação de reg. heterog.	0,046	0,031
	agrupamento de regiões	0,031	0,047
2	ajuste de borda	1,576	1,731
	segmentação de reg. heterog.	0,031	0,016
	agrupamento de regiões	0,125	0,109
1	ajuste de borda	15,241	14,508
	segmentação de reg. heterog.	0,016	< 0,001
	agrupamento de regiões	< 0,001	< 0,001
	agrupamento de <i>pixel</i> isolado	< 0,001	< 0,001
0	ajuste de borda	277,992	257,650
	agrupamento de regiões	< 0,001	< 0,001
	área mínima	0,016	< 0,001

A avaliação dos resultados obtidos na segmentação do conjunto de imagens simuladas no PolSeg mostrou que o uso dos dados polarimétricos gerou para as medidas de ajuste de intensidade, posição, dimensão e forma valores, respectivamente, 0,6%, 0,4%, 2,0% e 2,6%, superiores aos gerados com o uso dos dados multivariados polarizados em intensidade. Tem-se ainda, que o uso dos dados polarimétricos multivariados gerou número de regiões levemente

maior que o obtido com dados multivariados polarizados em intensidade, em média 0,14 regiões a mais, e consumiu um tempo de processamento, em média 0,05 maior.

6.2.2.2. Resultados obtidos com o SegSAR

Antes de realizar as segmentações com o SegSAR, foi definido para este algoritmo o valor do parâmetro similaridade. Isto foi feito por meio da seleção do melhor resultado para a medida de ajuste geral, calculada a partir de uma série de segmentações realizadas com uma das imagens simuladas, fixando-se os parâmetros nível de compressão em cinco, nível de confiança em 95,0%, área mínima em 15 pixels e variando a similaridade de 0,1 a 2,0 dB. O valor do parâmetro encontrado para esta série de segmentações e adotado para a segmentação no SegSAR foi de 0,8 dB.

Os resultados obtidos em termos de números de regiões e tempo de processamento da aplicação do algoritmo SegSAR na segmentação dos dados polarizados em intensidade, variando o nível máximo de compressão e os níveis de confiança disponíveis no algoritmo, são apresentados na Figura 6.41.

De modo geral percebe-se na Figura 6.41, para o SegSAR que ao variar o nível máximo de compressão ocorreu uma oscilação na quantidade de regiões geradas e tempo de processamento, e que os menores valores foram obtidos para os níveis de compressão ímpares.

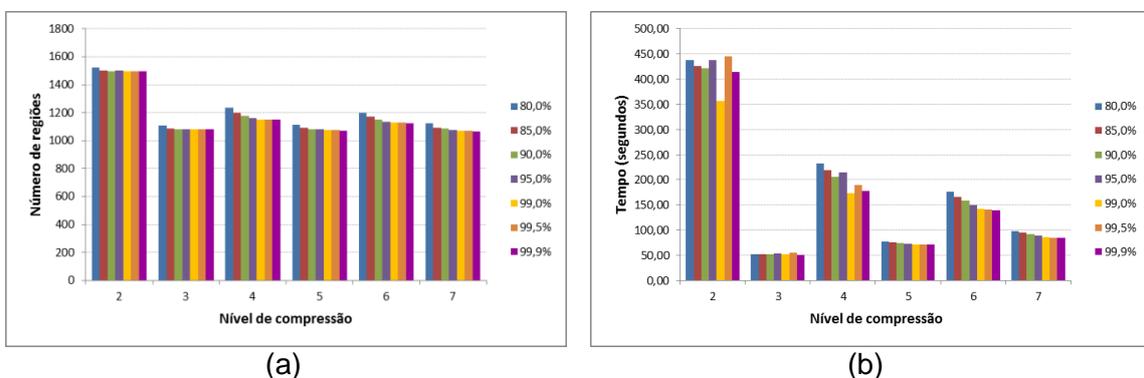


Figura 6.41 - Desempenho do SegSAR na segmentação das imagens simuladas polarizadas em intensidade, segundo (a) a quantidade de regiões geradas e (b) tempo de processamento.

Os resultados da aplicação do algoritmo SegSAR com as imagens polarizadas em intensidade são apresentados na Figura 6.42. Nestas figuras as curvas ilustradas nos gráficos apresentam os valores calculados das medidas de ajuste, definidas na Seção 3.3.1, para cada nível de confiança ao variar o nível máximo de compressão. Os valores numéricos usados para gerar os gráficos apresentados nestas figuras podem ser encontrados no Anexo A.

Da inspeção visual dos gráficos ilustrados na Figura 6.42 nota-se que, as medida de ajuste de intensidade \bar{M}_{val} e de posição \bar{M}_{pos} , apresentaram maiores valores no nível de compressão iguala a dois, nível de compressão onde as demais medidas apresentaram os menores valores.

A fim de constatar estatisticamente a igualdade das medidas para os comportamentos apresentados nos valores das medidas variando o nível de compressão de quatro a sete, foram realizados testes de hipóteses (teste-Z) com nível de significância de 1%. A Tabela A.8 do Apêndice A, mostram os resultados destes testes para as medidas \bar{M}_{val} , \bar{M}_{pos} , \bar{M}_{dim} , \bar{M}_{for} e \bar{M}_{geral} . Nestas tabelas as áreas em verde indicam os pares de níveis de compressão onde para os quais as imagens segmentadas produzem valores médios das respectivas medidas, considerados estaticamente iguais ao nível de significância de 1%.

Para o SegSAR, a partir dos resultados apresentados na Tabela A.8, percebe-se que não há uma tendência que permita considerar a igualdade estatística das medidas de ajuste tomando por base a variação do nível de compressão.

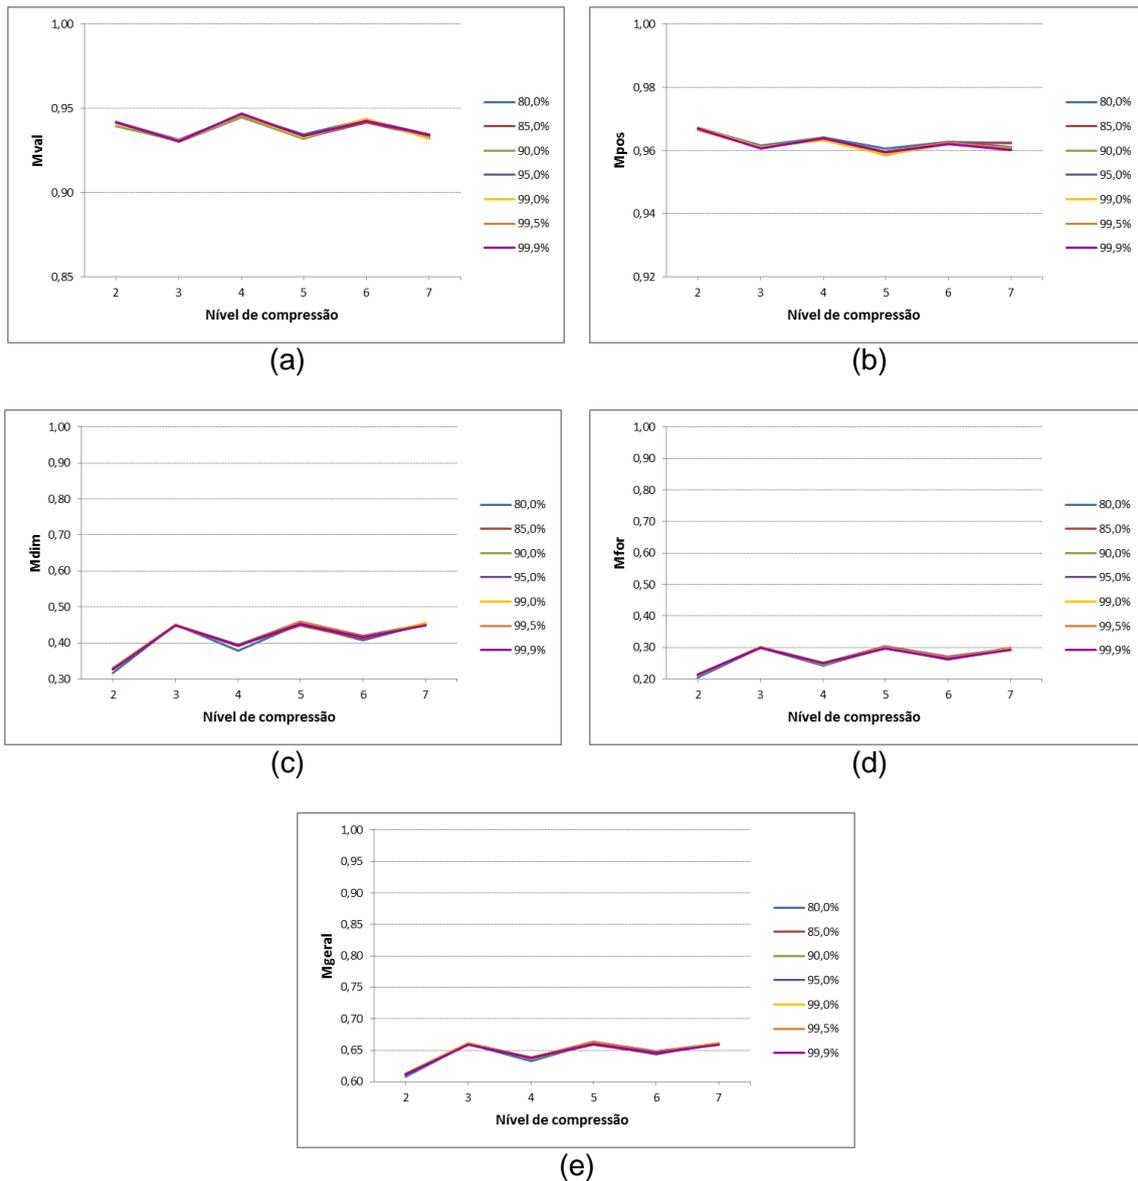


Figura 6.42 - Desempenho do SegSAR na segmentação das imagens polarizadas em intensidade, segundo: (a) medida de ajuste de intensidade \bar{M}_{val} ; (b) medida de ajuste de posição \bar{M}_{pos} ; (c) medida de ajuste de dimensão \bar{M}_{dim} ; (d) medida de ajuste de forma \bar{M}_{for} ; e, (e) medida de ajuste geral \bar{M}_{geral} .

6.2.2.2.1. Exemplo detalhado de processamento com o SegSAR

Para ilustrar o resultado final da segmentação usando o SegSAR foi selecionada uma imagem do conjunto de dados simulados (a mesma processada pelo PoISeg na Seção 6.2.1.1.1.), a partir da qual foi gerada a matriz de covariância e extraído os canais polarizados em intensidade para

serem segmentados nesse algoritmo. Os parâmetros de nível de compressão e nível de confiança usados na segmentação foram aqueles que apresentaram os maiores valores para a medida de ajuste geral, a saber, nível de compressão igual a cinco, nível de confiança igual a 95,0%, área mínima de 15 pixels e similaridade de 0,8 *dB*.

A Figura 6.43 apresenta a imagem original selecionada e o resultado da segmentação realizada pelo SegSAR, representada pela intensidade média das regiões, ambas na composição colorida $hh(R)$, $hv(G)$, $vv(B)$.

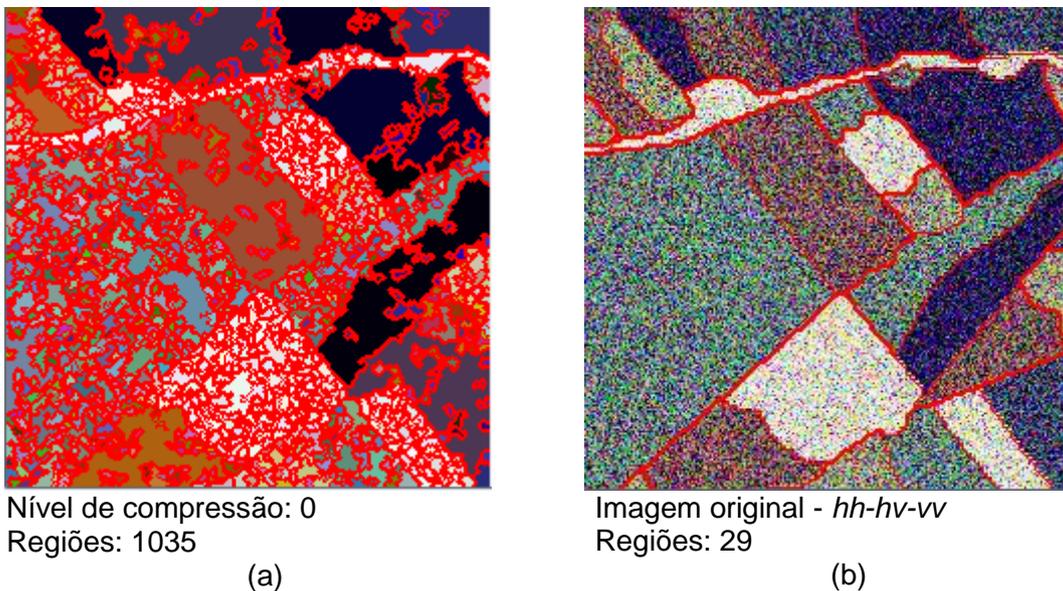
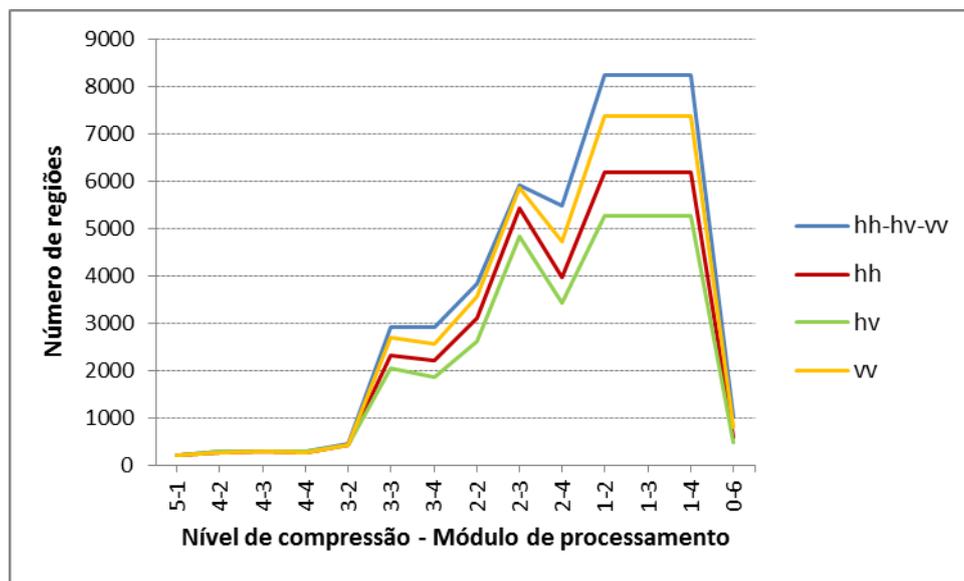


Figura 6.43 - Resultado obtido na segmentação com o SegSAR de uma imagem multivariada polarizada em intensidade, com nível de compressão igual a cinco, nível de confiança de 95,0% e área mínima de 15 *pixels*: (a) imagem segmentada; e, (b) a imagem original submetida a segmentação, ambas em intensidade e representadas na composição colorida $R(hh)$, $G(hv)$, $B(hh)$.

A Figura 6.43, mostra que o SegSAR gerou como resultado uma super-segmentação da imagem selecionada. Como a imagem usada possui 1-*look*, tal resultado está de acordo com o constatado por Sousa Junior (2005), que verificou o aumento da quantidade de segmentos com imagens de número de *looks* pequenos.

A Figura 6.44 apresenta as quantidades de regiões geradas em cada nível de compressão para cada módulo de processamento do SegSAR, na segmentações realizadas com a imagem multivariada em intensidade e com a imagens univariadas em intensidade. Os parâmetros usados para obter os resultados mostrados na figura foram aqueles que apresentaram os maiores valores para a medida de ajuste geral, com o uso dos dados multivariados polarizados em intensidade (nível de compressão igual a cinco, nível de confiança igual a 95,0% e área mínima de 15 *pixels*).



Legenda dos módulos de processamentos:

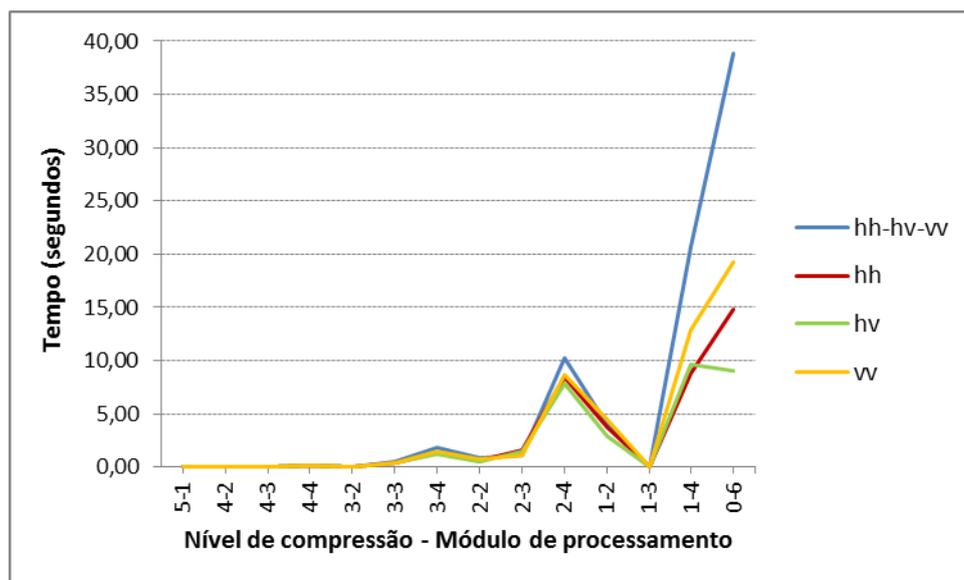
1 : Segmentação	4 : Agrupamento de regiões
2 : Ajuste de bordas	5 : Agrupamento de pixels isolados
3 : Segmentação de regiões heterogêneas	6 : Área mínima

Figura 6.44 - Quantidade de regiões geradas a cada nível de compressão pelos módulos de processamentos do SegSAR, na segmentação de uma imagem simulada multivariada em intensidade (*hh-hv-vv*) e imagens univariadas polarizadas em intensidade (polarizações *hh*, *hv* e *vv*), usando os parâmetros que apresentaram os melhores valores para a medida de ajuste geral.

A Figura 6.44 mostra para o SegSAR, que o aumento mais significativo da quantidade de regiões ocorre partir do nível de compressão menor ou igual a três. Isto pode indicar que até este nível de compressão a formação de novas regiões não vinha sendo influenciada pelo efeito do ruído *speckle*. Verifica-se também que no nível de compressão igual a um o módulo de segmentação de

regiões heterogêneas não é acionado, pois não é gerada nenhuma região e o tempo de processamento é praticamente nulo. Isto pode indicar que neste nível de compressão, devido ao grande número de regiões, o algoritmo entenda que todas elas são homogêneas. Verifica-se ainda que o módulo de área mínima é responsável durante processamento pela maior redução na quantidade de regiões.

A Figura 6.45 apresenta o tempo de processamento consumido em cada nível de compressão para cada módulo de processamento do SegSAR, nas segmentações realizadas com a imagem multivariada polarizada em intensidade e as imagens univariadas. Os resultados apresentados nesta figura foram gerados usando os parâmetros de segmentação que apresentaram os maiores valores para a medida de ajuste geral.



Legenda dos módulos de processamentos:

1 : Segmentação	4 : Agrupamento de regiões
2 : Ajuste de bordas	5 : Agrupamento de pixels isolados
3 : Segmentação de regiões heterogêneas	6 : Área mínima

Figura 6.45 – Tempo de processamento demandado a cada nível de compressão pelos módulos de processamentos do SegSAR, na segmentação de uma imagem simulada multivariada em intensidade (*hh-hv-vv*) e imagens univariadas polarizadas em intensidade (polarizações *hh*, *hv* e *vv*), usando os parâmetros que apresentaram os melhores valores para a medida de ajuste geral.

Os resultados apresentados na Figura 6.45, mostram de modo geral para o SegSAR, que até o nível de compressão igual a três o tempo de processamento consumido pelo algoritmo foi praticamente nulo. A partir deste nível de compressão, entretanto o que se nota é que o tempo de processamento tende a um rápido crescimento, sendo que os módulos de agrupamento de regiões e área mínima os principais responsáveis por este crescimento. Isto indica que a maior parte do custo computacional apresentado pelo SegSAR se deve aos processamentos realizados nos últimos níveis de compressão. Da comparação com os resultados obtidos nas segmentações com dados univariados polarizados em intensidade, observa-se que o aumento no número de canais ocasiona um aumento expressivo no tempo de computação para os últimos módulos de processamento.

6.2.2.3. Comparação de resultados obtidos com o PolSeg e o SegSAR

Os melhores resultados obtidos para as medidas de ajuste usando o PolSeg e o SegSAR, na segmentação dos dados multivariados polarizados em intensidade, variando os níveis máximos de compressão e os níveis de confiança, são apresentados na Tabela 6.16.

Tabela 6.16 – Melhores valores obtidos para as medidas de ajuste de intensidade \bar{M}_{val} , de posição \bar{M}_{pos} , \bar{M}_{dim} , de forma \bar{M}_{for} e geral \bar{M}_{geral} gerados a partir dos resultados da segmentação no PolSeg e no SegSAR das imagens simuladas polarizadas em intensidade, variando os valores de níveis máximos de compressão e níveis de significância.

Medida de ajuste	PolSeg		SegSAR	
	média	desv. pad.	média	desv. pad.
\bar{M}_{val}	0,9815	0,0066	0,9337	0,0123
\bar{M}_{pos}	0,9850	0,0066	0,9596	0,0074
\bar{M}_{dim}	0,9336	0,0241	0,4595	0,0334
\bar{M}_{for}	0,8750	0,0226	0,3036	0,0301
\bar{M}_{geral}	0,9438	0,0143	0,6641	0,0183

Nota-se na Tabela 6.16 que os valores das medidas obtidos na segmentação das imagens multivariadas polarizadas em intensidade obtidas com o PolSeg

são maiores que os obtidos pelo SegSAR. A fim de verificar a igualdade estatística dos valores apresentados nesta tabela usou-se o teste-Z com nível de significância de 1%, cujo resultado é apresentado na Tabela 6.17.

Tabela 6.17 - Valores da estatística Z e valor-p para as medidas de ajuste de intensidade \bar{M}_{val} , de posição \bar{M}_{pos} , de dimensão \bar{M}_{dim} , de forma \bar{M}_{for} e geral \bar{M}_{geral} obtidas a partir dos resultados da segmentação no PolSeg e no SegSAR das imagens polarizadas em intensidade.

Estatística	Medida de ajuste				
	\bar{M}_{val}	\bar{M}_{pos}	\bar{M}_{dim}	\bar{M}_{for}	\bar{M}_{geral}
Z	34,243	25,616	115,109	151,807	120,433
valor-p	0,000	0,000	0,000	0,000	0,000

Os valores apresentados na Tabela 6.17 mostram que os resultados obtidos com na segmentação dos dois dados não podem ser considerados estatisticamente iguais ao nível de significância de 1%. Mostram ainda que os valores obtidos para as medidas de ajuste na segmentação com o PolSeg foram significativamente superiores que os resultados obtidos com o SegSAR. Este fato salienta que a modelagem estatística rigorosa adotada no PolSeg foi capaz de representar melhor os dados multivariados polarizados para fim de segmentação da imagem, que a adotada pelo SegSAR.

Com relação a quantidade média de regiões geradas, a segmentação do conjunto das 100 imagens simuladas multivariadas polarizadas em intensidade no PolSeg gerou 29,6 regiões, enquanto o valor gerado na segmentação do conjunto de dados no SegSAR foi de 1081,1 regiões. O tempo médio de processamento, por sua vez, foram respectivamente 340,59 e 214,58 segundos.

A Figura 6.46 apresenta uma imagem simulada multivariada polarizada em intensidade selecionada do conjunto de dados processados (a mesma que tem sido usada ao longo deste capítulo), com os contornos das regiões, e os resultados obtidos nas segmentações realizadas respectivamente com o PolSeg e o SegSAR, todas em composição colorida $hh(R)$, $hv(G)$, $vv(B)$.

A inspeção visual das imagens apresentadas na Figura 6.46 mostra que em termos de geração de regiões que a segmentação realizada com o PolSeg foi nitidamente superior a executada com o SegSAR. A grande quantidade de regiões geradas no processamento com o SegSAR pode estar associada à regra estabelecida para o processo de crescimento de regiões realizado no algoritmo. Segundo esta regra, o crescimento de regiões somente ocorre se o teste adotado para o agrupamento de *pixel-pixel* e região-*pixel* for aceito para todas as bandas que compõe a imagem. Como a possibilidade de rejeição aumenta com o aumento da quantidade de bandas as regiões tendem a crescer pouco gerando uma maior quantidade de regiões durante o processamento e na segmentação final.

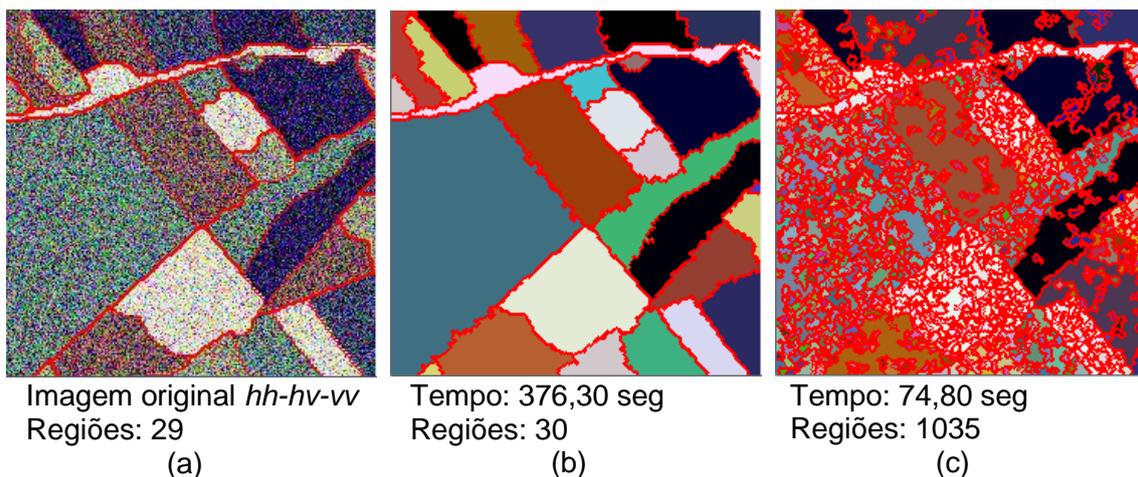


Figura 6.46 – Exemplo de (a) imagem simulada multivariada em intensidade com os contornos das regiões e segmentações geradas com os algoritmo (b) PolSeg e (c) SegSAR, todas representadas na composição colorida *hh(R)*, *hv(G)*, *vv(B)*.

A comparação dos resultados obtidos na segmentação do conjunto de imagens simuladas multivariadas polarizadas em intensidade no SegSAR e PolSeg mostrou que o PolSeg apresentou para as medidas de ajuste de intensidade, posição, dimensão e forma valores, respectivamente, 5,1%, 2,7%, 103,2% e 188,2%, superiores aos gerados no SegSAR. Tem-se ainda que o PolSeg gerou um número de regiões mais próximo do existente na imagem de referência, em média 35 vezes menor que o gerado pelo SegSAR, e consumiu

mais tempo de processamento, em média 0,6 vezes a mais, que o tempo consumido pelo SegSAR.

6.3. Síntese dos resultados obtidos na segmentação dos dados SAR simulados

A seguir é apresentada uma síntese comparativa dos processamentos realizados no PolSeg e SegSAR dos dados SAR simulados. O objetivo desta comparação é ressaltar os resultados obtidos na segmentação realizada com o PolSeg e salientar qual combinação de imagens e parâmetros foi capaz de gerar uma segmentação mais próxima da imagem de referência.

A Figura 6.47 apresenta os melhores resultados obtidos na segmentação de uma das imagens do conjunto de dados simulados, usando os parâmetros de segmentação para cada situação, que apresentaram os melhores valores para as medidas de ajuste geral.

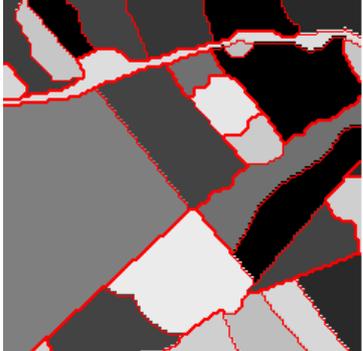
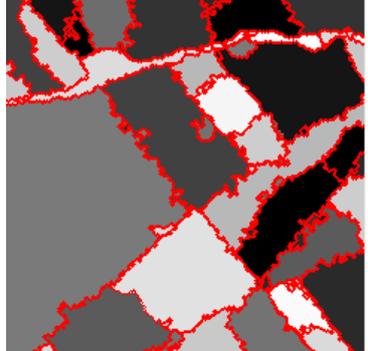
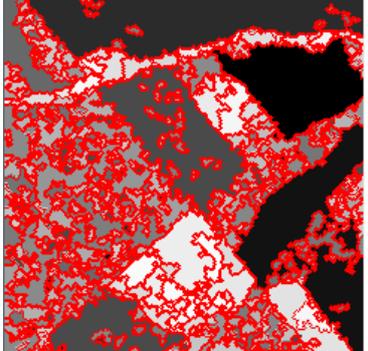
Imagem original (29 regiões)	PolSeg	SegSAR
 <p data-bbox="225 1525 588 1617">Univariada polarizada em intensidade - polarização hv. Regiões: 29</p>	 <p data-bbox="699 1525 922 1617">Regiões: 62 Tempo: 14,10 seg \bar{M}_{geral}: 0,8877</p>	 <p data-bbox="1090 1525 1313 1617">Regiões: 466 Tempo: 27,47 seg \bar{M}_{geral}: 0,6821</p>

Figura 6.47 - Síntese dos resultados das segmentações realizadas com o PolSeg e SegSAR.

(Continua)

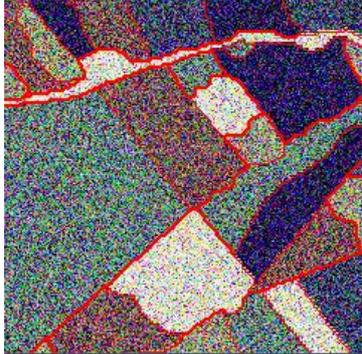
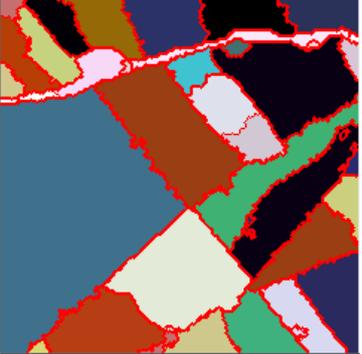
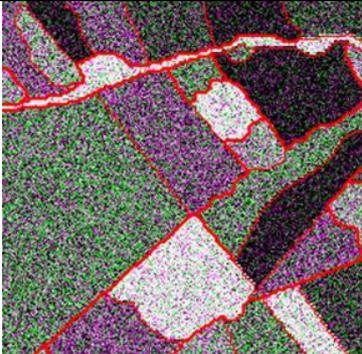
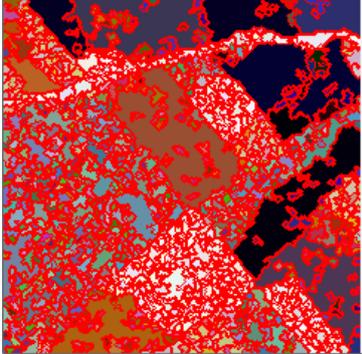
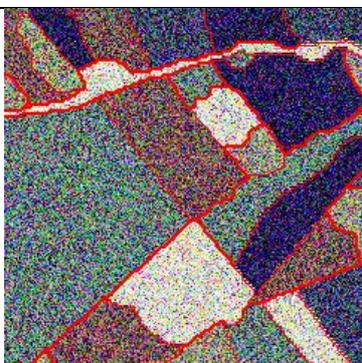
		<p>não processa este tipo de dado</p>
<p>Imagem PolSAR formada com três polarizações.</p>	<p>Regiões: 41 Tempo: 376,30 seg \bar{M}_{geral}: 0,9572</p>	<p>não processa este tipo de dado</p>
		<p>não processa este tipo de dado</p>
<p>Imagem PolSAR formada por par de polarizações <i>hh-hv</i>.</p>	<p>Regiões:31 Tempo: 182,27 seg \bar{M}_{geral}: 0,9451</p>	
		<p>Tempo: 74,80 seg Regiões: 1035 \bar{M}_{geral}: 0,6641</p>
<p>Imagem multivariada polarizada em intensidade com três polarizações.</p>	<p>Tempo: 354,53 seg Regiões: 30 \bar{M}_{geral}: 0,9438</p>	

Figura 6.47 - Conclusão

A partir da análise visual das imagens originais e segmentadas apresentadas na Figura 6.47, pode-se notar que os resultados obtidos com o PolSeg foram de modo geral melhores aos obtidos com o SegSAR. Verifica-se ainda que o resultados obtidos com o PolSeg, em termos de número de regiões e valores para a medida de ajuste geral, também foram superiores aos obtidos com SegSAR. Por sua vez, nota-se que dentre os resultados das segmentação

gerados com o PolSeg, aquele que apresentou o melhor índice para a medida de ajuste geral foi o obtido na segmentação do dado PolSAR formado com três polarizações.

7 AVALIAÇÃO DO ALGORITMO POLSEG COM IMAGENS POLSAR REAIS

Este capítulo tem por finalidade apresentar algumas segmentação realizadas com dados reais de sensores PolSAR embarcados em plataformas orbitais e aerotransportados. As avaliações das segmentações apresentadas nas seções seguintes foram realizadas tomando por base a inspeção visual e informações de tempo de processamento e quantidade de regiões geradas.

Nestas segmentações foram usados os dados PolSAR, representados pela matriz de covariância complexa, e os dados multivariados polarizados em intensidade, representados pela matriz de covariância contendo somente os dados da diagonal principal. Adicionalmente, os dados em intensidade também foram processados com o segmentador SegSAR, para que pudesse ser feita uma comparação entre os resultados obtidos com os dois algoritmos.

Os parâmetros adotados para as segmentações realizadas com o PolSeg foram aqueles que geraram os melhores valores para as medidas de ajuste durante a análise dos dados simulados PolSAR, a saber, nível de compressão igual a sete, nível de confiança de 90,0% e área mínima de 15 *pixels*. Além disso, foi habilitada no PolSeg, para estas segmentações, a saída de resultados finais da segmentação no nível de compressão igual a um, conforme previsto em sua concepção original. Já para o SegSAR, os parâmetros foram nível de compressão igual a cinco, nível de confiança de 95,0%, área mínima de 15 *pixels* e similaridade de 0,8dB.

7.1. Processamento da imagem do sensor SIR-C - banda L

O algoritmo PolSeg foi utilizado para segmentar a imagem PolSAR na banda L do sensor SIR-C, que funcionou instalado no ônibus espacial *Endeavour* em missões de imageamento da superfície terrestre, no ano de 1994 (Seção 4.4). O número equivalente de *look* desta imagem foi estimado em 2,97, levando-se em conta todos os canais polarizados em intensidade e o uso do método descrito em Frery et al. (2007).

A Figura 7.1 mostra os resultados da segmentação da imagem polarimétrica na banda L do sensor SIR-C obtidos com o PolSeg, usando os dados PolSAR e dados multivariados polarizados em intensidade, e com o SegSAR, usando os dados multivariados em intensidade.

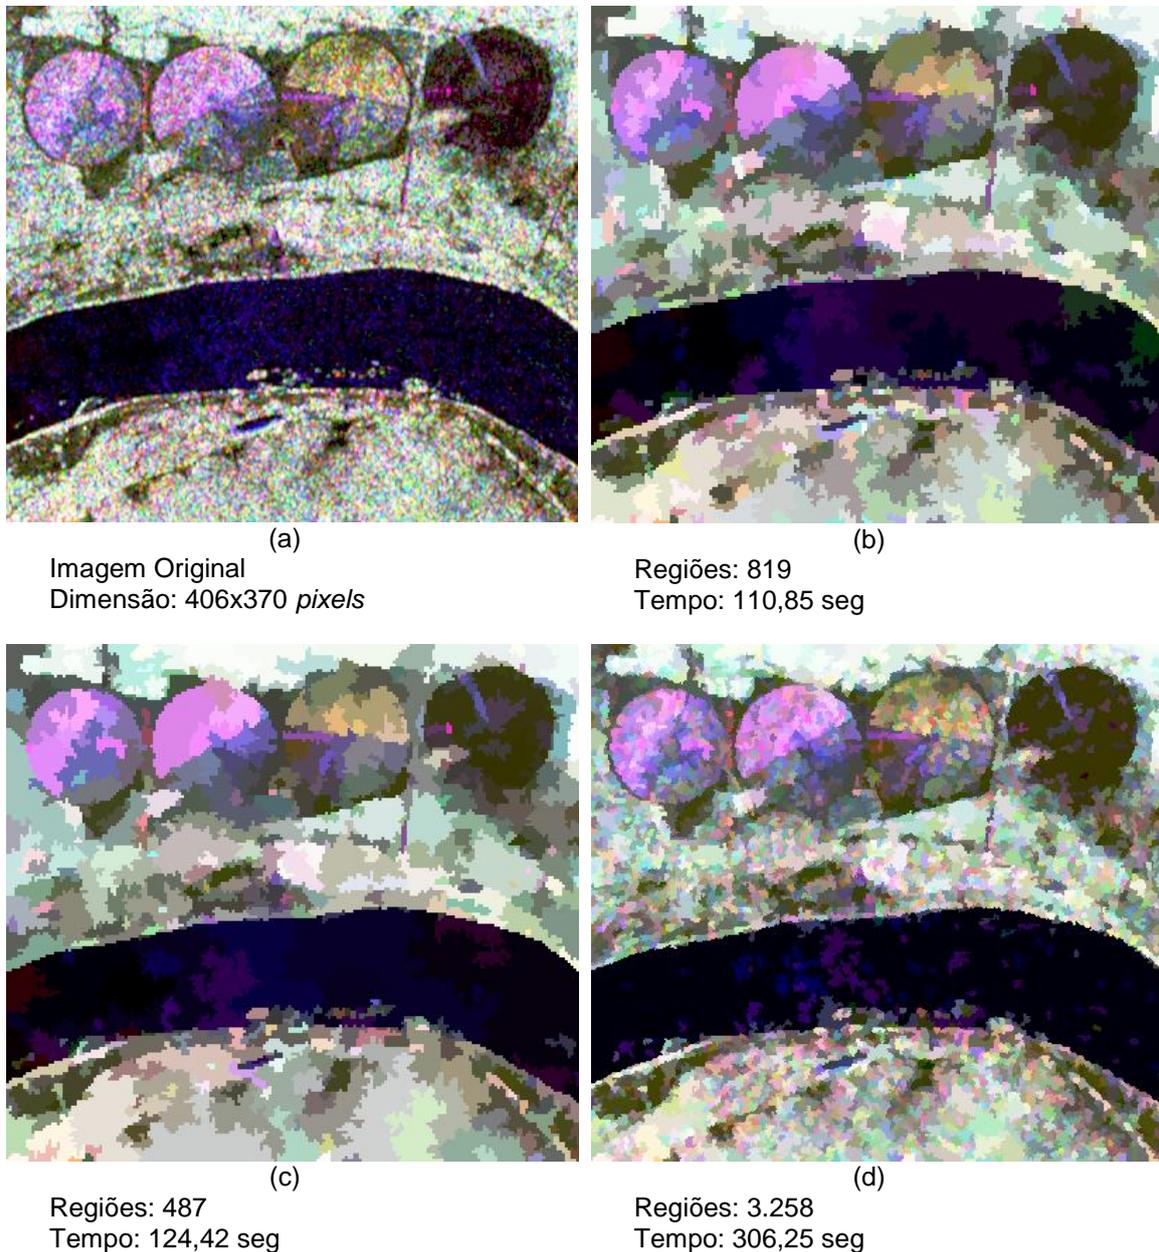


Figura 7.1 - Resultados da segmentação da (a) imagem PolSAR do sensor SIR-C, banda L, obtidos com: (b) PolSeg, usando as imagens PolSAR; (c) PolSeg, usando as imagens polarizadas em intensidade; e , (d) SegSAR, usando as imagens em intensidade. Todos representados em intensidade na composição colorida $hh(R)$, $hv(G)$, $vv(B)$.

A Figura 7.1 mostra que praticamente todas as classes de uso do solo que aparecem na imagem original foram representadas nas imagens segmentadas pelos dois algoritmos. Pode-se verificar, porém para o SegSAR que houve uma supersegmentação para todas as classes.

Com relação à quantidade de regiões geradas nos processamentos, observa-se que a quantidade de regiões geradas pelo SegSAR foi cerca de 4,0 vezes maior que a quantidade de regiões geradas na segmentação com o PolSeg, usando os dados PolSAR, e de cerca de 6,7 vezes maior que a quantidade de regiões geradas pelo PolSeg, usando os dados polarizados em intensidade. Este fato reforça o que já foi visto na segmentação com os dados simulados e mostra que a modelagem estatística adotada para o PolSeg permite uma melhor definição das regiões no processo de segmentação.

Os tempos de processamentos demandados mostram que o SegSAR foi mais demorado em sua segmentação que o PolSeg. O tempo de processamento do SegSAR foi cerca de 2,7 maior que o tempo usado pelo PolSeg, na segmentação dos dados PolSAR, e cerca de 2,5 maior que o tempo usado por este algoritmo, na segmentação dos dados polarizados em intensidade. Como a quantidade de segmentos gerados pelo SegSAR foi muito maior que a quantidade e segmentos gerados pelo PolSeg, nos dois processamentos executados com este algoritmo, é de se esperar que o tempo de processamento seja realmente alto.

Da análise da segmentação realizada com a imagem na banda L do sensor SIR-C pode ser verificado que os resultados gerados pelo PolSeg foram superiores aos obtidos pelo SegSAR, tanto em quantidade de regiões, tempo de processamento e representação das classes de uso do solo existentes na imagem. Por sua vez, a partir do número de segmentos gerados nas segmentações com os dois algoritmos pode-se afirmar que o SegSAR gerou uma supersegmentação da imagem. Isto indica que o teste estatístico usado pelo SegSAR é mais restritivo que o teste de igualdade de matrizes de covariância usado no PolSeg.

7.2. Processamento da imagem do sensor R99B - banda L

O algoritmo PolSeg também foi utilizado para segmentar a imagem PolSAR *multilook* na banda L do sensor R99B da Força Aérea Brasileira (Seção 4.4). O número equivalente de *look* desta imagem foi estimado em 2,63, conforme método descrito em Frery et al. (2007).

A Figura 7.2 mostra os resultados da segmentação da imagem na banda L do sensor SIR-C obtidos com o PolSeg, usando os dados PolSAR e dados multivariados polarizados em intensidade, e com o SegSAR, usando os dados multivariados em intensidade. Nesta figura pode se verificar que as classes de uso do solo que aparecem na imagem original foram supersegmentadas no SegSAR. Pode-se verificar ainda, que essas classes aparecem mais uniformes na segmentação realizada como PolSeg, usando dados multivariados polarizados em intensidade. A segmentação realizada com os dados PolSAR, por sua vez, quando comparada a realizada com dados polarizados em intensidade apresenta maior quantidade de pequenas regiões. Este resultado reforça o que foi visto na segmentação das imagens simuladas, onde se constatou que os elementos fora da diagonal da matriz de covariância ocasionaram em uma maior geração de regiões.

As quantidades de regiões geradas mostram que o resultado gerado com o PolSeg, usando dados multivariados polarizados foi o que obteve menor número de regiões. A quantidade de regiões geradas pelo SegSAR, por sua vez, foi cerca de 2,2 vezes maior que a quantidade de regiões geradas na segmentação com o PolSeg, usando os dados PolSAR, e de cerca de 6,7 vezes maior que a quantidade de regiões geradas pelo PolSeg, usando os dados polarizados em intensidade.

Os tempos de processamentos demandados mostram que o SegSAR necessitou de mais tempo para realizar a segmentação que o PolSeg. O tempo de processamento do SegSAR foi cerca de 6,2 vezes maior que o tempo usado pelo PolSeg, na segmentação dos dados PolSAR, e cerca de 4,9 vezes

maior que o tempo usado pelo PolSeg, na segmentação dos dados polarizados em intensidade.

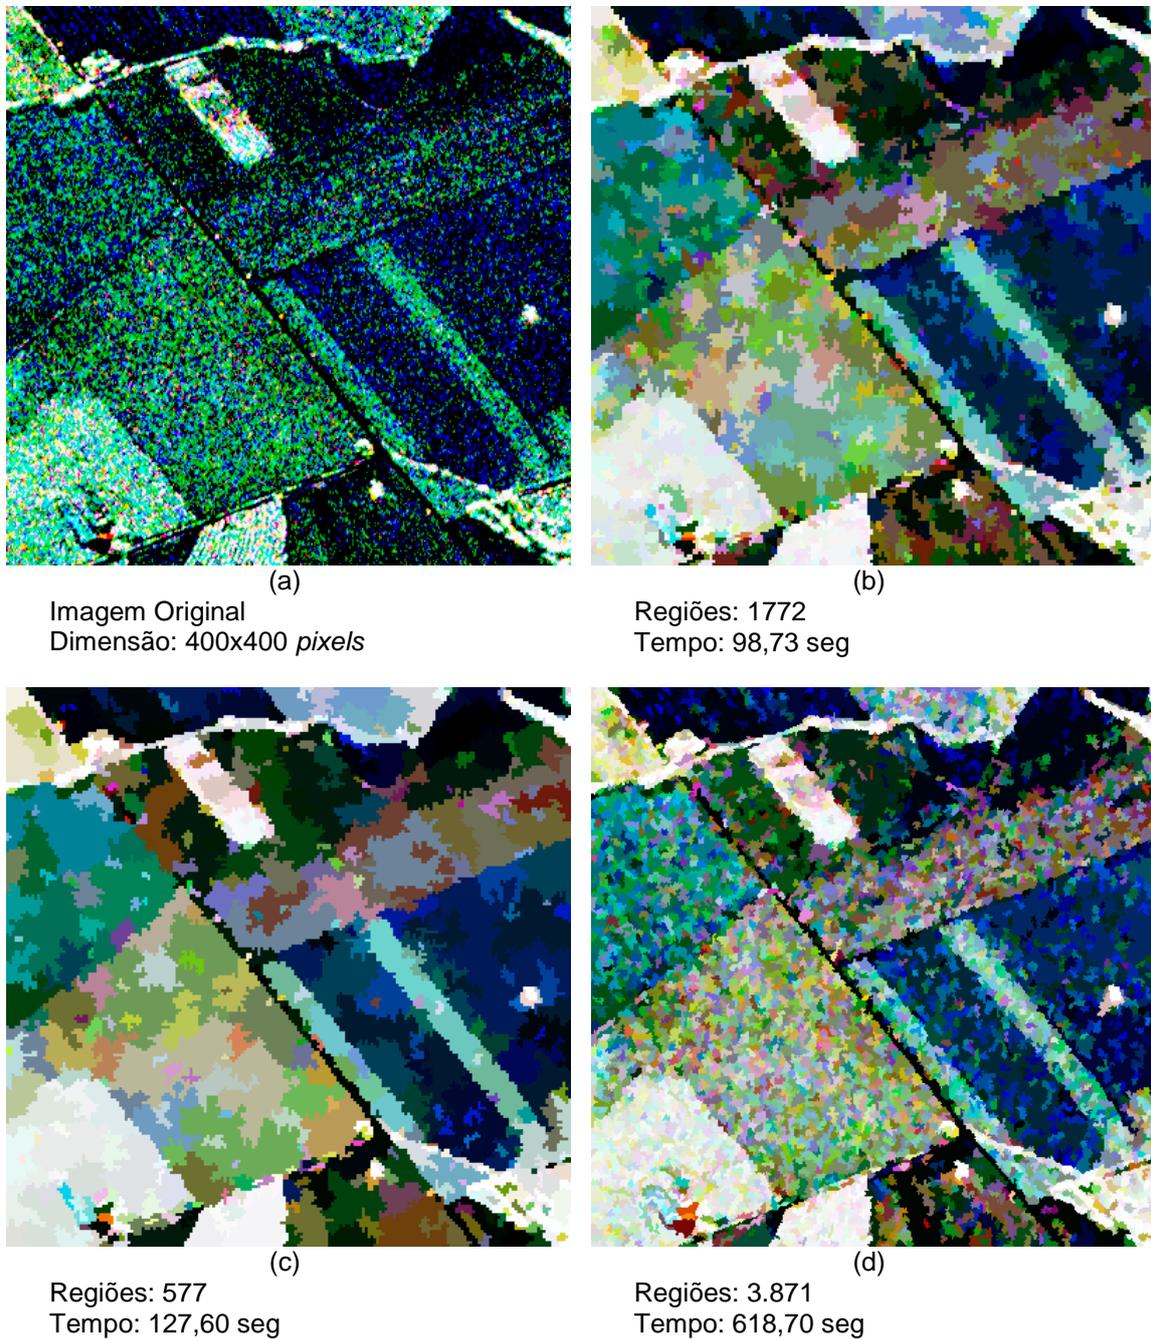


Figura 7.2 - Resultados da segmentação da (a) imagem PolSAR do sensor R99B, banda L, obtidos com: (b) PolSeg, usando as imagens PolSAR; (c) PolSeg, usando as imagens polarizadas em intensidade; e , (d) SegSAR, usando as imagens polarizadas em intensidade; e , (d) SegSAR, usando as imagens em intensidade. Todos representados em intensidade na composição colorida $hh(R)$, $hv(G)$, $vv(B)$.

Da análise da segmentação realizada com a imagem na banda L do sensor R99B verificou-se que os resultados gerados pelo PolSeg, tomando por base o tempo de processamento e número de regiões, foram superiores aos gerados pelo SegSAR.

8 CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

O presente trabalho teve como objetivo principal apresentar a concepção, o desenvolvimento e a avaliação de um novo segmentador para dados PolSAR. Teve ainda como objetivo secundário investigar o uso da informação polarimétrica na segmentação de imagens SAR. A seguir são apresentadas as conclusões do trabalho desenvolvido, bem como, as sugestões para pesquisas futuras que visem o aprofundamento dos estudos realizados.

8.1. Conclusões

Para atingir o objetivo geral proposto, foram realizadas revisões bibliográficas de diversos trabalhos relacionados à modelagem estatística e à segmentação de imagens SAR, assunto abordado no Capítulo 2. A partir destas revisões foi possível obter detalhes importantes a respeito da estrutura usada para representar as imagens PolSAR, sua modelagem estatística e informações a respeito das mais variadas técnicas de segmentação que vem sendo empregadas para processar este tipo de dado. Tal estudo permitiu a obtenção de uma visão mais abrangente dos problemas relacionados à segmentação e respectivas soluções adotadas para resolvê-los ou minimizá-los. Esta fase do trabalho foi de importância fundamental, pois auxiliou na definição dos mecanismos a serem usados para realizar a segmentação e no contorno das dificuldades encontradas durante o desenvolvimento do algoritmo.

O algoritmo foi concebido de forma a usar como informação polarimétrica para ser processada a matriz de covariância complexa. A distribuição estatística adotada para modelar esta matriz e fundamentar os testes de hipóteses usados na segmentação foi à distribuição *Wishart* complexa. Foi verificada ainda, na sua concepção, a necessidade de processar dados univariados, para atender o caso onde a matriz de covariância possui um único elemento. Para este caso, adotou-se a distribuição *Gama* ($\Gamma(L, \beta)$) para fundamentar os testes de hipóteses. Dessa forma, quando se leva em consideração os testes estatísticos adotados, pode-se supor que o segmentador apresentado reúne em uma mesma estrutura de processamento dois algoritmos distintos. Constatou-se

ainda para o algoritmo a viabilidade de usar o teste estatístico para dados polarimétricos na segmentação de dados multivariados polarizados em intensidade.

Da análise dos trabalhos apresentados no Capítulo 3, foi adotado ainda, na concepção do algoritmo, o uso da característica de similaridade encontrada nas imagens e a adoção do modelo multiplicativo. Adicionalmente foi adotada a técnica de segmentação por crescimento de regiões como ferramenta principal para a obtenção dos segmentos, pelo fato da mesma ter apresentado bons resultados em algoritmos consagrados, tais como o MUM (OLIVER e QUEGAN, 2004), a versão do MUM adaptada para dados polarimétricos (SKRIVER et. al, 2002) e o SegSAR (SOUSA JUNIOR, 2005), dentre outros.

O algoritmo foi concebido de forma a possuir uma estrutura de processamento híbrida similar a usada pelo SegSAR (Sousa Junior, 2005). Devido a este fato, o algoritmo desenvolvido pode ser considerado uma extensão do SegSAR para o processamento de dados PolSAR. Apesar disso, a maneira como o algoritmo foi concebido e as funcionalidades inseridas durante seu desenvolvimento, tais como: tipo de dado processado; modelagem estatística adotada; maneira como os testes estatísticos são aplicados; possibilidade de uso de níveis de confiança diferentes para os módulos de processamento de segmentação e agrupamento de regiões; maior interatividade com o usuário permitindo alterações de parâmetros de segmentação durante o processamento a cada nível de descompressão, e a geração de saídas de resultados intermediários; e ambiente de desenvolvimento e execução, o distancia desse último algoritmo, tornando-o único e inovador em vários aspectos relativos ao processamento executado. Cabe ressaltar, que a associação destas características é uma contribuição até então pouco explorada nas ferramentas de segmentação de dados SAR e confere ao algoritmo um diferencial não encontrado nos trabalhos verificados na literatura pesquisada.

Uma característica, encontrada no SegSAR e usada no algoritmo desenvolvido, pouco explorada, conforme pôde ser verificado na literatura pesquisada, é o uso de um módulo de análise e ajuste de bordas das regiões geradas na

segmentação por crescimento de regiões. Este módulo em particular dentro da estrutura de processamento mostrou ser fundamental para a obtenção dos bons resultados finais da segmentação. Isto se deveu porque por intermédio do processamento executado por ele foi possível se obter uma melhor definição das regiões geradas a cada nível de descompressão. Neste trabalho a potencialidade deste módulo de proporcionar uma boa definição das bordas das regiões foi verificada nos resultados obtidos no nível de compressão da imagem original, considerada como mais desfavorável por possuir um número de *look* igual a um.

O algoritmo foi desenvolvido em linguagem de programação IDL 7.1. Este fato permite que o PolSeg seja executado no ambiente nativo do IDL, quando o mesmo estiver disponível, e no ambiente IDL *Virtual Machine* (IDL VM), um utilitário multi-plataforma de distribuição gratuita para rodar dados compilados em código da linguagem IDL, bastando para este último que seja gerado o arquivo .sav. O IDL VM pode ser instalado em todas as plataformas suportadas pelo IDL (Windows, Linx, Mac OS X e Sistemas Operacionais UNIX).

Para o desenvolvimento do algoritmo foram adotadas três etapas principais de processamento, as quais são formadas por diversos módulos individuais, descritos detalhadamente no Capítulo 3. Esta peculiaridade possibilitou durante o desenvolvimento uma maior flexibilidade na programação da estrutura de processamento planejada, facilitando a integração dos módulos elaborados para tratamento da imagem. Tal característica possibilitará que trabalhos futuros de aprimoramento do algoritmo possam ser realizados de forma mais eficiente e rápida, uma vez que os módulos podem ser tratados individualmente. Além disso, auxiliará no desenvolvimento de novos algoritmos, pois os módulos desenvolvidos poderão ser aproveitados por usuários desenvolvedores em outros aplicativos.

Com relação à avaliação do desempenho do algoritmo PolSeg e a análise comparativa realizada com o SegSAR (SOUSA JUNIOR, 2005), tomando por base as medidas de ajuste desenvolvidas por Delves et.al. (1992), apresentada no Capítulo 3, pode-se concluir que:

- 1) Nas segmentações realizadas com o PolSeg e SegSAR das imagens simuladas univariadas em intensidade com 1-look, nas polarizações *hh*, *hv* e *vv*, verificou-se que:
 - a) para ambos os algoritmos os menores valores de medida de ajuste foram obtidos para o nível de compressão igual a dois e que a partir deste nível os valores das medidas tenderam a uma menor variação;
 - b) no PolSeg o nível de confiança com valores mais baixos acarretou maiores valores para as medidas de ajuste independente do nível de compressão usado e que o aumento do nível de compressão ocorreu um aumento nos valores das medidas, os quais tenderam a se estabilizar apresentando valores estatisticamente iguais a partir do nível de compressão igual a quatro;
 - c) no SegSAR a variação do nível de confiança aparentemente não interferiu nos resultados das medidas, independentemente do nível de compressão adotado e que o aumento do nível de compressão acarretou uma leve variação nos valores das medidas de ajuste, porém sem acusar nenhuma tendência de comportamento;
 - d) os valores das medidas de ajuste obtidos com o PolSeg foram estatisticamente superiores ou iguais aos valores obtidos com o SegSAR para a maioria das combinações de variações de parâmetros analisados;
 - e) a comparação dos resultados obtidos na segmentação de uma imagem simulada usando os parâmetros que geraram os melhores resultados para as medidas de ajuste em ambos os algoritmos mostrou que:
 - o PolSeg gerou medidas de ajuste de intensidade, posição, dimensão e forma superiores aos obtidos com o SegSAR para as polarizações *hh* (em média 3,6%, 0,3%, 60,8% e 110,9%) e *hv* (em média 3,2%, 1,2%, 67,1% e 122,4%);

- para a polarização *vv* o PolSeg gerou medidas de ajuste de dimensão e forma com valores, respectivamente, 38,6% e 109,1%, superiores aos gerados no SegSAR;
 - a quantidade de regiões geradas pelo PolSeg na segmentação dos dados nas polarizações *hh*, *hv* e *vv*, foram respectivamente, 7,7, 7,3 e 61,8 vezes menor que a gerada pelo SegSAR;
 - o tempo de processamento do PolSeg para as polarizações *hh*, *hv* e *vv* foram, respectivamente, 4, 2,1 e 0,7 vezes mais rápido que do SegSAR.
- f) a obtenção da segmentação final no PolSeg foi o resultado do refinamento da segmentação da imagem realizada no nível máximo de compressão, enquanto a segmentação final obtida pelo SegSAR gerou como resultado uma super-segmentação das imagens SAR simuladas submetidas a processamento.
- 2) Nas segmentações realizadas com o PolSeg das imagens simuladas PolSAR, representadas pela matriz de covariância com três polarizações, verificou-se que:
- a) a partir do nível de compressão igual a quatro, o uso de níveis de confiança menores gerou valores mais altos para as medidas de ajuste e que a partir do nível de compressão igual a cinco os valores destas medidas tenderam a se estabilizar apresentando valores estatisticamente iguais;
 - b) a obtenção da segmentação final se apresentou como um refinamento do resultado da segmentação realizada nos níveis de compressão mais altos e que ao se aproximar do nível de compressão igual a zero as bordas das regiões se tornaram mais serrilhadas.

- 3) Nas segmentações realizadas com o PolSeg das imagens simuladas PolSAR e as comparações com os resultados obtidos com as imagens univariadas em intensidade, verificou-se que:
- a) o resultado da segmentação da imagem PolSAR foi melhor que os resultados obtidos na segmentação das imagens univariadas em intensidade;
 - b) a quantidade de regiões geradas a cada descompressão em um nível por módulo de processamento foi menor que as quantidades geradas nas segmentações das imagens univariadas em intensidade com polarizações *hh* e *hv*, e que no nível de compressão igual a um foi menor que as segmentação das imagens univariadas em intensidade para as três polarizações;
 - c) a análise da quantidade de regiões geradas em cada nível de compressão por módulo de processamento, mostrou que os testes estatísticos usados para segmentar dados com uma banda e três bandas possuem comportamentos similares durante o processo de segmentação da imagem, e que a quantidade maior de bandas usadas na segmentação interfere significativamente no aumento de tempo de processamento do algoritmo.
- 4) Nas segmentações realizadas com o PolSeg com imagens PolSAR simuladas formadas por pares de polarizações, resultantes das combinações das polarizações *hh*, *hv* e *vv*, verificou-se que:
- a) de modo geral no nível de compressão igual a dois os resultados obtidos para as medidas de ajuste apresentaram maior variação de valores;
 - b) que a partir do nível de compressão igual a cinco os valores das medidas tenderam a se estabilizar podendo ser considerados estatisticamente iguais ao nível de significância de 1%.

- c) os resultados finais obtidos com as segmentações realizadas com duas bandas quando comparados aos obtidos com uma banda apresentou uma melhora significativa na qualidade das imagens segmentadas;
 - d) que o melhor resultado de segmentação foi obtido com o par de polarizações *hh-hv*;
 - e) que os resultados obtidos nas segmentações usando imagens PolSAR com o par de polarizações *hh-hv* foi levemente inferior aos resultados obtidos na segmentação da imagem polarimétrica com três polarizações;
- 5) Nas segmentações realizadas com o PolSeg das imagens simuladas PolSAR, representados pela matriz de covariância com três polarizações, e imagens multivariadas polarizadas em intensidade, representada pela matriz diagonal, verificou-se que:
- a) os valores das medidas de ajuste obtidas com a segmentação das imagens PolSAR foram, ao nível de significância de 1,0%, estatisticamente superiores aos valores obtidos na segmentação dos dados polarizados em intensidade;
 - b) a quantidade de regiões geradas na segmentação dos dados polarizados em intensidade foi menor e mais próxima a quantidade existente na imagem de referência, que a quantidade gerada na segmentação dos dados PolSAR (o número de regiões geradas com dados PolSAR foi em média 1,14 vezes maior);
 - c) o tempo de processamento gasto na segmentação da imagem PolSAR foi levemente mais elevado que o gasto com o processamento da imagem polarizada em intensidade (em média 1,05 vezes maior);
 - d) os resultados obtidos na segmentação de uma imagem simulada usando os parâmetros que geraram os melhores índices para as medidas de ajuste mostraram que:

- os resultados usando dados PolSAR simulados para as medidas de ajuste de intensidade, posição, dimensão e forma, foram em média respectivamente, 0,6%, 0,4%, 2,0% e 2,6% superiores, aos resultados obtidos usando dados polarizados em intensidade;

- o número de regiões geradas e o tempo de processamento dos dados PolSAR foram em média, respectivamente, 1,14 e 1,05 maior que o obtido com dados multivariados polarizados em intensidade.

6) Nas segmentações realizadas com o PolSeg o SegSAR das imagens multivariada polarizadas em intensidade, verificou-se que:

a) ambos os algoritmos apresentaram os menores valores de medidas de ajuste de forma, dimensão e geral no nível de compressão igual a dois;

b) o desempenho apresentado pelo PolSeg nos níveis de compressão maiores ou igual a quatro, para as medidas de dimensão, de forma e geral foi muito superior ao desempenho apresentado pelo SegSAR, e apresentou desempenho superior ou no mínimo estatisticamente igual ao obtido com o SegSAR para as medidas de intensidade e de posição;

c) as quantidades de regiões geradas na segmentação com o PolSeg foram mais próximas a quantidade de regiões existente na imagem simulada e que o tempo de processamento do SegSAR foi menor que do PolSeg;

d) o aumento do número de bandas no SegSAR ocasionou a geração de uma grande quantidade de regiões, caracterizando uma super-segmentação das imagens SAR simuladas submetidas a processamento.

e) os resultados obtidos na segmentação de uma imagem simulada usando os parâmetros que geraram os melhores índices para as medidas de ajuste mostraram que:

- o PolSeg gerou medidas de ajuste de intensidade, posição, dimensão e forma com valores, respectivamente, 5,1%, 2,7%, 103,2% e 188,2% superiores aos gerados no SegSAR;

- o PolSeg gerou um número de regiões mais próximo do existente na imagem de referência, em média 35 vezes menor que o gerado pelo SegSAR, e consumiu mais tempo de processamento, em média 0,6 vezes a mais, que o tempo consumido pelo SegSAR.

7) Nas segmentações realizadas com o PolSeg e SegSAR das imagens PolSAR reais dos sensores SIR-C e R99B, verificou-se que:

a) de modo geral os resultados obtidos na segmentação com o PolSeg foram superiores, em termo de tempo de processamento e numero de reigões geradas, aos resultados obtidos com o SegSAR;

b) as segmentações realizadas no PolSeg com dados multivariados polarizados em intensidade gerou a menor quantidade de regiões;

c) o SegSAR gerou uma supersegmentação como resultado final do processamento;

Os resultados das segmentações realizadas mostraram ainda, que o PolSeg necessita de um número de compressões mínimo para obter bons resultados na segmentação das imagens. Além disso, observou-se que o número mínimo de compressões tende a ser mais alto quando se aumenta o número de bandas usadas na segmentação, conforme pode ser verificado na segmentação dos dados com duas e três bandas do vetor de espalhamento complexo (Capítulo 6). Tal característica está diretamente ligada ao teste estatístico usado no módulo de crescimento de regiões para realizar a segmentação inicial. O teste de hipótese empregado neste módulo tende a aceitar com mais facilidade a hipótese nula (igualdade entre as matrizes de covariância) quando o número equivalente de *looks* calculado para a imagem é

pequeno. Isto faz com que um número maior de compressões seja necessário para que o algoritmo apresente um bom desempenho.

A partir dos resultados obtidos na segmentação das imagens simuladas pode-se assumir que o algoritmo PolSeg possui grande potencial de uso para as atividades de processamento de imagens PolSAR pois apresentou medidas de ajuste com valores elevados. A comparação dos resultados obtidos na segmentação dessas imagens usando o PolSeg e o SegSAR, por sua vez, mostrou que o primeiro foi superior em praticamente todas as combinações de parâmetros e quantidade de bandas analisadas.

A partir do que foi exposto, tem-se que o objetivo geral do presente trabalho foi atingido, uma vez que a concepção, o desenvolvimento e a avaliação de um novo segmentador para dados PolSAR foi realizado, o que resultou no algoritmo PolSeg. Tem-se, portanto, que a primeira hipótese foi confirmada, pois o algoritmo desenvolvido adota abordagem estatística e pode ser considerado híbrido por integrar em um único sistema diversas técnicas de segmentação e processamento de imagens.

Tem-se ainda, que o objetivo secundário e os objetivos específicos também foram atingidos, pois observou-se que:

- a modelagem estatística rigorosa adotada para o PolSeg na segmentação dos dados univariados em intensidade, tomando por base a distribuição *Gama* (L, β) , gerou resultados superiores de segmentação quando comparados aos resultados decorrentes da modelagem estatística adotada pelo SegSAR;
- tomando por base os valores das medidas de desempenho, a modelagem estatística adotada para a segmentação de dados PolSAR, adotada para o PolSeg, foi capaz de gerar melhores resultados, para os dados simulados, quando comparados com os resultados obtidos na segmentação de dados multivariados polarizados em intensidade;

- os resultados obtidos na segmentação dos dados multivariados polarizados em intensidade com o PolSeg, foram superiores aos resultados obtidos na segmentação obtida usando o SegSAR. Isto mostra que a modelagem estatística adotada para dados PolSAR, pelo PolSeg, baseada na distribuição *Wishart*, foi superior a adotada pelo SegSAR na segmentação dos dados em intensidade;
- o par de polarizações *hh-hv* para imagem PolSAR gerou os melhores resultados de segmentação no PolSeg;
- o uso imagens polarimétricas simuladas formadas pelo par de polarizações *hh-hv* foi capaz de gerar resultados similares aos obtidos com a segmentação de dados PolSAR, apesar de os resultados obtidos serem considerados estatisticamente inferiores aos obtidos com dados PolSAR, ao nível de significância de 1%; e,
- o desempenho do algoritmo PolSeg na segmentação de imagens simuladas e reais podem ser considerados similares, uma vez que os resultados obtidos foram capazes de individualizar as regiões existentes nas duas imagens;

Com base nos objetivos atingidos, tem-se por fim que a segunda hipótese também foi confirmada, pois foi possível obter melhores resultados na segmentação de imagens SAR usando as informações polarimétricas e modelagens estatísticas adequadas a este tipo de informação.

8.2. Sugestões para trabalhos futuros

Como sugestões para trabalhos futuros e ou aprofundamento dos temas relacionados ao trabalho apresentado pode-se relacionar os seguintes tópicos:

- Desenvolvimento e incorporação ao algoritmo de rotina para obtenção da estimacão a cada nível de compressão do número equivalente de looks para imagens PolSAR, o qual pode ser fundamentado no trabalho desenvolvido por Anfinsen et al. (2009);

- Estudo, desenvolvimento e incorporação ao algoritmo de novo teste para detectar a homogeneidade das regiões em imagens PolSAR;
- Realizar testes de avaliação do algoritmo com imagens PolSAR geradas por diversos sensores para verificar o verdadeiro potencial de uso nas mais variadas aplicações de Sensoriamento Remoto;
- Otimizar os módulos de processamento do algoritmo visando melhorar o seu desempenho com imagens de grandes dimensões, tendo em vista que nos testes realizados foram usadas imagens de dimensões pequenas e que o aumento da imagem tende a exigir mais tempo de processamento;
- Melhorar a interface de visualização e interatividade com o usuário, inserindo funcionalidades, tais como, opções para carregar as bandas em processamento de acordo com a composição RGB desejada e ferramenta de aplicação / redução de visualização de imagem;
- Incorporação no algoritmo de rotinas para realizar leitura e carregamento de dados georreferenciados, e geração de saída de dados no formato vetorial dos contornos das regiões obtidas na segmentação;
- Desenvolvimento e incorporação no algoritmo de outros testes de hipóteses para a realização de segmentação de imagens SAR;
- Desenvolver e incorporar ao algoritmo um módulo de processamento visando à realização da classificação das regiões geradas pela segmentação.
- Realizar testes de avaliação do algoritmo com imagens PolSAR simuladas com regiões não homogêneas;
- Realizar testes de avaliação do algoritmo com imagens PolSAR *multilook* em intensidade;

- Verificar a possibilidade de integrar o algoritmo na biblioteca TerraLib desenvolvido pelo IPE;
- Estudo, desenvolvimento e incorporação ao algoritmo de teste estatístico baseado na distribuição K para realizar a segmentação de em imagens PoISAR.

REFERÊNCIAS BIBLIOGRÁFICAS

ACHARYA, T.; RAY, A. K. **Image processing, principles and applications**. New Jersey: John Wiley and Sons, Inc. 2005. 452 p.

AKBARI, V.; DOULGERIS, A.P.; MOSER, G.; ELTOFT, T.; ANFINSEN, S.N.; SERPICO, S.B. A Textural-contextual model for unsupervised segmentation of multipolarization synthetic Aperture Radar Images. **IEEE Transactions on Geoscience and Remote Sensing**, v.51, n. 4, p. 2442-2453, 2013.

AYED, I. B.; MITICHE, A.; BELHADJ, Z. Multiregion level-set partitioning of synthetic Aperture Radar Images. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 27, n. 5, p. 793-800, 2005.

BEAULIEU, J. M.; TOUZI, R. Segmentation of textured scenes using polarimetric SARs. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), 2003, Toulouse, France. **Proceedings...** Toulouse: IEEE 2003.p. 446-448.

BEAULIEU, J.; TOUZI, R. Segmentation of textured polarimetric SAR scenes by likelihood approximation. **IEEE Transactions on Geoscience and Remote Sensing**, v. 42, n. 10, p. 2063-2072, 2004.

BENBOUDJEMA, D.; TUPIN, F.; PIECZYNSKI, W.; SIGELLE, M.; NICOLAS, J. M. Unsupervised segmentation of SAR images using Triplet Markov fields and Fisher noise distributions. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), 2007, Barcelona, Spain. **Proceedings...** Barcelona: IEEE 2007. p. 3891-3894.

BOMBRUN, L.; BEAULIEU, J.M.; VASILE, G.; OVARLEZ, J.P.; PASCAL, F.; GAY, M. Hierarchical segmentation of polarimetric SAR images using heterogeneous clutter models. **IEEE Transactions on Geoscience and Remote Sensing**, v. 49, n. 2, p. 726 - 737, 2009.

BOMBRUN, L.; VASILE, G.; GAY, M.; TOTIR, F. Hierarchical segmentation of polarimetric SAR images using heterogeneous clutter models. **IEEE Transactions on Geoscience and Remote Sensing**, v. 49, n. 2, p. 726-737, 2011.

BOVIK, A. C. On detecting edges in speckle imagery. **IEEE Trans Acoustic Speech Signal Processing**, v. 36, n. 10, p. 1618-1627, 1988.

CAO, F.; HONG, W.; WU, Y.; POTTIER, E. An unsupervised segmentation with an adaptive number of clusters using the SPAN/H/a/A space and the complex Wishart clustering for fully polarimetric SAR data analysis. **IEEE Transactions on Geoscience and Remote Sensing**, v. 45, n. 11, p. 3454-3467, 2007.

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.

CAVES, R.; QUEGAN, S.; WHITE, R. G. Quantitative comparison of the performance of SAR segmentation algorithms. **IEEE Transactions on Image Processing**, v. 7, n. 11, p. 1534-546, 1998.

CHAN, T. F.; VESE, L. A. Active contours without edges. **IEEE Transactions on Image Processing**, v. 10, n. 2, p. 266-277, 2001.

CHENG, H.; SUN, Y. A hierarchical approach to colour image segmentation using homogeneity. **IEEE Transactions on Image Processing**, v. 9, n. 12, pp. 2071-082, 2000.

CIHLAR, J.; XIAO, Q.; CHEN, J.; BEAUBIEN, J.; FUNG, K.; LAVITOVIC, R. Classification by progressive generalization: a new automated methodology for remote sensing multichannel data. **International Journal of Remote Sensing**, v. 19, n. 14, p. 2685-2704, 1999.

CLOUDE, R. S.; POTTIER, E. Concept of polarization entropy in optical scattering. **Optical Engineering**, v. 34, n. 6, p. 1599-1610, 1995.

COMANICIU, D.; MEER, P. Mean shift: A robust approach toward feature space analysis. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 24, n. 5, pp. 603-619, 2002.

CONRADSEN, K.; NIELSEN, A. A.; SCHOU, J.; SKRIVER, H. Change detection in polarimetric SAR data and the complex Wishart distribution. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), 2001, Cape Town, South Africa. **Proceedings...** Cape Town: IEEE 2001. p. 2628-2630.

CONRADSEN, K.; NIELSEN, A. A.; SCHOU, J.; SKRIVER, H. A test statistic in the complex Wishart distribution and its application to change detection in polarimetric SAR data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 1, p. 4-19, 2003.

COOK, R.; MC CONNELL, I.; STEWART, D.; OLIVER, C. MUM (Merge Using Moments) segmentation for SAR images. In: EurOpto SAR DATA PROCESSING FOR REMOTE SENSING, 1994, Rome, Italy. **Proceedings...** Rome: SPIE 1994. p. 92-103.

CORREIA, A. H. **Método automático para calibração polarimétrica de imagens SAR**. 2009. 307 p. (INPE-16349-TDI/1557). Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009. Disponível em: <<http://urlib.net/8JMKD3MGP8W/35DKDSP>>. Acesso em: 22 jan. 2014.

DABBOR, M.; KARATHANASSI, V.; BRAUN, A. Multilevel hierarchical segmentation method for polarimetric SAR data based on scattering behavior and histograms. **Canadian journal of Remote Sensing**, v. 36, n. 2, p. 142-153, 2010.

DAVIES, E. R. **Machine vision: theory, algorithms, practicalities**. 3. ed. Royal Holloway, University of London. Morgan Kaufmann Publishers. 2004. 934 p.

DE GRANDI, G.; LEE, J.; SIQUEIRA, P.; BARALDI, A.; SIMARD, M. Segmentation and labeling of polarimetric SAR data: can wavelets help? In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS'01), 2001, Sydney, Australia. **Proceedings...** Piscataway, N.J.: IEEE International, 2001.v. 1, p. 410–413.

DELON, J.; DESOLNEUX, A.; LISANI, J.; PETRO, A. A nonparametric approach for histogram segmentation. **IEEE Transactions on Image Processing**, v. 16, n. 1, pp. 253-261, 2007.

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.2, p.2121-2149, 1992.

DUDA, R.; HART, P.; STORK, D. **Pattern classification**. 2. ed. New York: Wiley Interscience, 2000. 654 p.

DUTRA, L. V.; MURA, J. C.; FREITAS, C. C.; JOÃO, R. S.; E., M. T. Processamento de imagens de Radar de Abertura Sintética – princípios e aplicações. In: WORKSHOP EM TRATAMENTO DE IMAGENS, 4., 2003, Belo Horizonte, Minas Gerais. **Anais...** Belo Horizonte: DCC / UFMG, 2003. p. 4-13.

ERSAHIN, K.; CUMMING, I.G.; WARD, R.K. Segmentation and classification of polarimetric SAR data using spectral graph partitioning. **IEEE Transactions on Geoscience and Remote Sensing**, v. 48, n. 1, p.164-174, 2010.

FERNANDES, D. **Formação de imagens de abertura sintética e modelos da “speckle”-textura**. 1993. 192 p. Tese (Doutorado em Engenharia Eletrônica) – Instituto Tecnológico de Aeronáutica (ITA), São José dos Campos, 1993.

FERRO-FAMIL, L.; POTTIER, E.; LEE, J. S. Unsupervised classification of multifrequency and fully polarimetric SAR images based on the H/A/Alpha–Wishart Classifier. **IEEE Transactions on Geoscience and Remote Sensing**, v. 39, n. 11, p. 2332-2342, 2001.

FJØRTOFT, R.; CABADA, J.; LOPÈS, A.; MARTON, P.; CUBERO-CASTAN, E. Complementary edge detection and region growing for SAR image segmentation. In: CONFERENCE OF THE NORWEGIAN SOCIETY FOR IMAGE PROCESSING AND PATTERN RECOGNITION (NOBIM'97), 1997, Tromsø, Norway. **Proceedings...** Tromsø: [s.n], 1997.

- MARÇAL A.R.S.; RODRIGUES A.S. A method for multi-spectral image segmentation evaluation based on synthetic images. **Computers & Geosciences**, v.35, n.8, p.1574-1581, 2009.
- MARÇAL A.R.S.; RODRIGUES A.S.; CUNHA M. Evaluation of satellite image segmentation using synthetic images. In: IEEE IGARSS, 2010, Honolulu. **Proceedings...** Honolulu: IEEE, 2010. p. 2210-2213.
- MARPU, P. R.; NEUBERT, M.; HEROLD, H.; NIEMEYER, I. Enhanced evaluation of image segmentation results. **Journal of Spatial Science**, v. 55, n. 1, p. 55-68, 2010.
- MEINEL, G.; NEUBERT, M. A Comparison of segmentation programs for high resolution remote sensing data. In: ISPRS, 2004, Istanbul. **Proceedings...** Istanbul: 2004. v. XXXV-B4, p. 1097-1102.
- FJØRTOFT, R.; LOPES, A.; BRUNIQUEL, J.; MARTON, P. Optimal edge detection and edge localization in complex SAR images with correlated speckle. **IEEE Transactions on Geoscience and Remote Sensing**, v. 37, n. 5, p. 2272-2281, 1999.
- FREITAS, C. C.; FRERY, A. C.; CORREIA, A. H. The polarimetric G distribution for SAR analysis. **Environmetrics**, v. 16, n. pp. 13-31, 2005.
- FRERY, A.; CORREIA, A.; FREITAS, C. Classifying multifrequency fully polarimetric imagery with multiple sources of statistical evidence and contextual information. **IEEE Transactions on Geoscience and Remote Sensing**, v. 45, n. 10, p. 3098-3109, 2007.
- FRERY A. C.; MULLER, H. J.; YANASSE, C. C. F.; SANT'ANNA, S. J. S. A model for extremely heterogeneous clutter. **IEEE Transactions on Geoscience and Remote Sensing**, v. 35, n. 3, p. 648–659, May 1997.
- FRERY, A.C.; NASCIMENTO, A.D.C.; CINTRA, R.J. Information theory and image understanding: an application to polarimetric SAR imagery. **Chilean Journal of Statistics**, v. 2, n. 2, pp. 81-100, 2011.
- FU, K. S.; MUI, J. K. A survey on image segmentation. **Pattern Recognition**, v. 13, n. 1, p. 3-16, 1981.
- GONZALEZ, R. C.; WOODS, R. E. **Digital image processing**. New York: Addison-Wesley Publishing Company, Inc, 1987. 793 p.
- GOODMAN, N. R. Statistical analysis based on a certain multivariate complex Gaussian distribution. **Annals of Mathematical Statistics**, v. 34, n. 1, pp. 152-177, 1963.
- HÄNSCH, R.; JÄGER, M.; HELLWICH, O. Clustering by deterministic annealing and Wishart based distance measures for fully-polarimetric SAR-data. In: EUROPEAN CONFERENCE ON SYNTHETIC APERTURE RADAR (EUSAR

2008), 7, 2008, Graf-Zeppelin-Haus, Friedrichshafen, Germany. **Proceedings...** Friedrichshafen, 2008. p. 419-422.

HELLMAN, M. **SAR polarimetry tutorial (Beta version 0.1a)**. Rennes, France: Epsilon.Nought, 2001. Disponível em: <<http://epsilon.nought.de/>>. Acesso em: 02 Set 2009.

HOEKMAN, D.H.;VISSERS, M.A.M.; TRAN, T.N. Unsupervised full-polarimetric SAR data segmentation as a tool for classification of agricultural areas. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 4, n. 2, pp. 402-411, 2011.

JAIN, A. K. **Fundamentals of digital image processing**. New Jersey: Prentice-Hall, Inc. 1989. 569 p.

LEE, J. S.; GRUES, M. R.; KWOK, R. Classification of multi-look polarimetric SAR imagery based on complex Wishart distribution. **International Journal of Remote Sensing**, v. 15, n. 11, p. 2299-2311, 1994.

LEE, J. S.; JURKEVICH, I. Segmentation of SAR images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 27, n. 6, p. 674-680, 1989.

LEE J.S.; POTTIER E. **Polarimetric radar imaging: from basic to applications**. CRC Press, Taylor and Francis Group, 2009. 440p.

LEE, J. S.; HOPPEL, K. W.; MANGO, S. A.; MILLER, A. R. Intensity and phase statistics of multilook polarimetric and interferometric SAR imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v. 32, n. 5, p. 1017-1028, 1994a.

LEE, J.S.; GRUNES, M.; AINSWORTH, T.; DU, L.; SCHULER, D. L.; CLOUDE, S. R. Unsupervised classification using polarimetric decomposition and the complex Wishart classifier. **IEEE Transactions on Geoscience and Remote Sensing**, v. 37, n. 5, pp. 2249-2258, 1999.

LI, J.; CHEN, W. Clustering synthetic aperture radar (SAR) imagery using an automatic approach. **Canadian Journal of Remote Sensing**, v. 33, n. 4, p. 303-311, 2007.

LOMBARDO, P.; OLIVER, C. Optimal classification of polarimetric SAR images using segmentation. In: IEEE radar conference, 22-25 April 2002, Long Beach, Calif. **Proceedings...** Piscataway, N.J: IEEE International,2002. p. 8-13.

LUCCA, E. V. D. **Avaliação e comparação de algoritmos de segmentação de imagens de radar de abertura sintética**. 1998. 207 p. (INPE-7507-TDI/721). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1998. Disponível em: <<http://urlib.net/sid.inpe.br/deise/2000/04.27.16.28>>. Acesso em: 22 jan. 2014.

MEASURES, R. M. **Laser remote sensing: fundamentals and applications**. Malabar, Florida: Krieger Publishing Company, 1992. 524 p.

MOIK, J. G. **Digital processing of remotely sensed images**. Washington DC: Government Printing Office. 1980.

MURA, J.C. **Geocodificação automática de imagens de radar de abertura sintética interferométrico: sistema Geo-InSAR**. 2000. 160 p. (INPE-8209-TDI/764). Tese (Doutorado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2000. Disponível em: <<http://urlib.net/sid.inpe.br/deise/2001/08.03.12.24>>. Acesso em: 22 jan. 2014.

NASCIMENTO, A.D.C.; CINTRA, R.J.; FRERY, A.C. Hypothesis testing in speckled data with stochastic distances. **IEEE Transactions on Geoscience and Remote Sensing**, v. 48, n. 1, p. 373-385, 2010.

NASCIMENTO, A.D.C.; HORTA, M.M.; FRERY, A.C. Boundary detection with stochastic distance in polarimetric imagery. In: INTERNATIONAL WORKSHOP ON SCIENCE AND APPLICATIONS OF SAR POLARIMETRY AND POLARIMETRIC INTERFEROMETRY (POLinSAR'2011'), 5., 2011, Frascati, Italy. **Proceedings...** Frascati: ESA SP-695, Mar 2011.

Nascimento, A.D.C. **Teoria estatística da informação para dados de radar de abertura sintética univariados e polarimétricos**. 2012. 283 p. Tese (Doutorado em Estatística) – Universidade Federal de Pernambuco (UFPE), Recife, 2012.

NIKHIL, R. P.; SANKAR, K. P. A review on image segmentation techniques. **Pattern Recognition**. v. 26, n. 9, p.1277-1294, 1993.

OLIVER, C.; QUEGAN, S. **Understanding synthetic aperture radar images**. Raleigh, North Carolina: SciTech Publishing, Inc., 2004. 479 p.

ORBANZ, P. E.; BUHMANN, J. M. SAR images as mixtures of Gaussian mixtures. In: INTERNATIONAL CONFERENCE ON IMAGE PROCESSING (ICIP 2005), 2005, Genoa, Italy. **Proceedings...** Genoa: IEEE International Conference on Image Processing, 11-14 september. p. II-209-12.

PELLIZZERI, T.; LOMBARDO, P.; OLIVER, C.; SCIOTTI, M.; MELONI, M.; McConnell, I. A comparison of statistical segmentation technique for polarimetric SAR: region growing versus simulated annealing. In: POLinSAR 2003: WORKSHOP ON APPLICATIONS OF SAR POLARIMETRY AND POLARIMETRIC INTERFEROMETRY, 2003, Frascati, Italy. **Proceedings...** Noordwijk, The Netherlands: European Space Agency (ESA), ESTEC, 2003.

ROSE, K. Deterministic annealing for clustering, compression, classification, regression and related optimization problems. **Proceedings of the IEEE**, v. 86, n. 11, p. 2210-2239, 1998.

ROSENFELD, A. **Multiresolution image processing and analysis**. New York: Springer-Verlag, 1984. 385 p.

SCHOU, J.; SKRIVER, H.; NIELSEN, A. H.; CONRADSEN, K. CFAR edge detector for polarimetric SAR images. **IEEE Transactions on Geoscience and Remote Sensing**. v. 41, n. 1, pp. 20-32, 2003.

SHAPIRO, L. G.; STOCKMAN, G. C. **Computer vision**. New Jersey: Prentice-Hall, 2001. 625 p.

SHEN, J.; CASTAN, S. An optimal linear operator for step edge detection. **CVGIP: Graphical Models and Image Processing**, v. 54, n. 2, p. 112-133, 1992.

SHI, J.; MALIK, J. Normalized Cuts and Image Segmentation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 22, n. 8, pp. 888-905, 2000.

SHI, Q.; LI, Y.; ZHANG, Y. A New automatic segmentation for synthetic aperture radar image. In: INTERNATIONAL SYMPOSIUM ON INTELLIGENT MULTIMEDIA VIDEO AND SPEECH PROCESSING, 2004, Hong kong, China. **Proceeding...** Hong Kong, 20-22 october. p. 739-742.

SHUAI, Y.; SUN H.; XU, G. A fast segmentation scheme based on level set for SAR images. In: ASIAN AND PACIFIC CONFERENCE ON SYNTHETIC APERTURE RADAR (APSAR 2007), 1., 2007, Huangshan, China. **Proceedings...** Huangshan, 2007. p. 503-506.

SILVA, W. B. **Classificação de regiões de imagens utilizando testes de hipóteses baseados em distâncias estocásticas**: aplicações a dados polarimétricos. 2013. 143 p. (INPE-17186-TDI/2032). Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2013. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3DJMB48>>. Acesso em: 22 jan. 2014.

SILVA, W. B.; FREITAS, C. C.; SANT' ANNA S. J. S.; FRERY A. C. Classification of segments in PolSAR imagery by minimum stochastic distances between Wishart distributions. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 6, n. 3, pp. 1263-1274, 2013.

SKRIVER, H.; NIELSEN, A. A.; CONRADSEN, K. Evaluation of the Wishart test statistic for polarimetric data. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), Toulouse, France, 21-25 July 2003. **Proceedings...** Piscataway: IEEE International, 2003.p. 699-701.

SKRIVER, H.; SCHOU, J.; NIELSEN, A. A.; CONRADSEN, K. Polarimetric segmentation using the complex Wishart test statistic. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (

IGARSS), 2002, Toronto, Ontario, Canada, 24-28 June 2002. **Proceedings...** Piscataway: IEEE International, 2002, v.2, p. 1011-1013.

SMITH, D. M. Speckle reduction and segmentation of synthetic aperture radar images. **International Journal of Remote Sensing**, vol. 17, no. 11, pp. 2043-2057, 1996.

SOUSA JUNIOR, M. A. **Segmentação multiníveis e multi-modelos para imagens de radar e óptica**. 2005. 136 p. (INPE-14466-TDI/1147). Tese (Doutorado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2005. Disponível em: <<http://urlib.net/sid.inpe.br/jeferson/2005/06.01.18.47>>. Acesso em: 22 jan. 2014.

SRIVASTAVA, M. S. On the complex Wishart distribution. **Annals of Mathematical Statistics**, v. 36, n. 1, p. 313-315, 1963.

TOUZI, R. A review of speckle filtering in the context of estimation theory. **IEEE Transaction on Geoscience and Remote Sensing**, v. 40, n. 11, p. 2392-2404, 2002.

TOUZI, R.; LOPES, A.; BOUSQUET, P. A statistical and geometrical edge detector for SAR image. **IEEE Transactions on Geoscience and Remote Sensing**, vol. 26, p. 764-773, 1988.

TUR, M.; CHIN, K. C.; GOODMAN, J. W. When is speckle noise multiplicative? **Applied Optics**, v. 21, n. 7, p. 1157-1159, 1982.

ULABY, F. T.; ELACHI, C. **Radar polarimetry for geoscience applications**. Norwood: Artech House, 1990. 364 p.

VAN ZYL, J.J.; ULABY, F.T. Scattering matrix representation for simple targets. In: ULABY, F.T.; ELACHI, C. (eds.). **Radar polarimetry for geoscience applications**. Norwood, Mass.: Artech House, 1990. Chapt. 2, p. 17–50.

VAN ZYL, J. J.; ZEBKER, H. A.; ELACHI, C. Imaging radar polarimetric signatures: theory and observation. **Radio Science**, v.22, n.4, p.529–543, 1987.

WANG, J. S.; SWENDSEN, R. H. Cluster Monte Carlo algorithms. **Physica A: Statistical and Theoretical Physics**, v. 167, n. 3, p. 565-579, 1990.

WANG, Y.; HAN, C.; TUPIN, F. PolSAR Data segmentation by combining tensor space cluster analysis and Markovian framework. **IEEE Geoscience and Remote Sensing Letters**, v. 7, n. 1, p. 210-214, 2010.

WEISENSEEL, R. A.; KARL, W. C.; CASTAÑON, D. A.; BROWER, R. C. MRF-based algorithms for segmentation of SAR images. In: INTERNATIONAL CONFERENCE ON IMAGE PROCESSING (ICIP'98), 1998, Chicago, Illinois. **Proceedings...** Chicago, 1998. p. 770-774.

WHITE, R. G. **Low-level segmentation of noise imagery**. DRA, Royal Signal and Radar Establishment: Works (Memorandum 3900), 1986.

WOODHOUSE, I. H. **Introduction to microwave remote sensing**. Florida: Taylor and Francis Group. 2006. 400 p.

XU, H.; TIAN, Z.; DING, M. Graph spectral segmentation of SAR image based on information similarity measure. In: INTERNATIONAL CONFERENCE ON FUZZY SYSTEMS AND KNOWLEDGE DISCOVERY, (FSKD 2007), 2007, Haikou, Hainan, China. **Proceedings...** Haikou, 2007. p. 708-711.

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. 298p.

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-5630-NTC/318).

YANG, J.; YANG, R.; LI, YN, S. S.; QIN, Q. A novel edge-detection based segmentation algorithm for polarimetric SAR images. In: THE INTERNATIONAL ARCHIVES OF THE PHOTOGRAMMETRY, REMOTE SENSING AND SPATIAL INFORMATION SCIENCES (ISPRS 2008), 2008, Beijing, China. **Proceedings...** Beijing: ISPRS, 2008. p. 141-144.

YONG, X.; FENG, D.; RONGCHUN, Z. Optimal selection of image segmentation algorithms based on performance prediction. In: PAN-SYDNEY AREA WORKSHOP ON VISUAL INFORMATION PROCESSING (VIP '05), 2004, Sydney. **Proceedings...** Sydney: Australian Computer Society, Inc. 2004. p. 105-109.

ZAART, A. E.; ZIOU, D.; WANG, S.; JIANG, Q.; BÉNIÉ, G. B. SAR Images SEGMENTATION USING MIXTURE OF GAMMA DISTRIBUTION. In: VISION INTERFACE CONFERENCE (VI'99), 12., 1999, Trois-Rivières, Quebec, Canada. **Proceedings...** Trois-Rivières, 1999. p. 125-130.

APÊNDICE A – TABELAS DE TESTE-Z

As áreas em verde nas tabelas que se seguem representam os pares de parâmetros, onde não existem evidências estatísticas ao nível de significância de 10,0% para rejeitar a igualdade dos valores das medidas.

Tabela A.1 - Valores da estatística Z para as medidas de avaliação obtidas na segmentação pelo PolSeg da imagem simulada na polarização *hh* variando níveis de compressão de três a sete: (a) medida de intensidade \bar{M}_{val} , (b) medida de posição \bar{M}_{pos} , (c) medida de dimensão \bar{M}_{dim} , (d) medida de forma \bar{M}_{for} , e (e) geral \bar{M}_{geral} .

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-2,966	-1,270	-2,334	-1,773	1,665	0,669	1,076	-1,025	-0,532	0,450
85,0%	-2,500	-1,516	-2,059	-1,676	1,118	0,401	0,733	-0,673	-0,298	0,335
90,0%	-0,747	0,133	-1,607	-1,091	0,833	-0,847	-0,343	-1,638	-1,156	0,499
95,0%	-1,416	-1,328	-2,061	-1,758	-0,090	-0,634	-0,433	-0,450	-0,293	0,148
99,0%	0,470	-0,665	-1,224	-1,747	-1,079	-1,690	-2,241	-0,433	-0,862	-0,456
99,5%	-0,236	-0,650	-3,358	-1,044	-0,366	-2,822	-0,735	-2,661	-0,403	2,188
99,9%	1,370	1,498	-2,273	-0,829	0,153	-3,141	-1,942	-3,211	-2,047	1,335

(a)

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-7,796	-5,157	-5,564	-4,292	3,410	2,549	3,854	-0,702	0,736	1,353
85,0%	-12,104	-10,225	-9,349	-8,582	2,236	2,408	3,380	0,354	1,309	0,886
90,0%	-17,460	-15,040	-17,580	-17,510	2,439	0,547	0,650	-2,018	-1,921	0,108
95,0%	-7,335	-8,005	-10,435	-10,295	-0,067	-2,142	-2,060	-2,416	-2,312	0,078
99,0%	-6,981	-12,701	-13,692	-14,784	-6,025	-6,991	-8,206	-0,776	-2,057	-1,387
99,5%	-11,797	-17,929	-19,926	-18,298	-5,942	-8,068	-6,926	-2,374	-1,612	0,442
99,9%	-12,671	-18,795	-22,747	-23,309	-5,627	-9,202	-9,276	-3,576	-3,426	0,333

(b)

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-4,649	0,536	-0,845	0,400	5,275	3,402	4,744	-1,349	-0,096	1,171
85,0%	-8,274	-5,158	-5,726	-4,792	3,262	2,259	3,122	-0,839	0,068	0,855
90,0%	-12,194	-8,630	-10,873	-10,102	3,309	0,789	1,421	-2,380	-1,721	0,614
95,0%	-6,844	-6,828	-7,788	-7,541	0,110	-0,639	-0,586	-0,768	-0,709	0,031
99,0%	-6,680	-10,237	-10,348	-11,664	-4,235	-4,215	-5,689	0,151	-1,235	-1,434
99,5%	-10,758	-13,670	-14,352	-13,840	-3,540	-4,521	-4,290	-1,060	-1,030	-0,035
99,9%	-10,901	-14,975	-18,069	-17,788	-3,916	-6,936	-6,054	-3,043	-1,910	1,343

(c)

Tabela A.1 - Conclusão

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-5,983	-0,815	-2,751	-1,320	5,029	2,642	4,182	-1,960	-0,541	1,360
85,0%	-8,926	-4,758	-5,771	-4,650	4,194	2,690	3,881	-1,264	-0,104	1,110
90,0%	-12,144	-7,364	-9,963	-9,633	3,942	1,156	1,803	-2,540	-2,043	0,557
95,0%	-8,987	-8,553	-10,148	-9,646	0,882	-0,185	-0,344	-1,200	-1,284	-0,196
99,0%	-8,098	-12,004	-12,166	-14,415	-4,682	-4,818	-6,757	-0,102	-1,587	-1,487
99,5%	-11,970	-14,966	-16,754	-15,405	-3,697	-5,637	-4,676	-1,855	-1,135	0,623
99,9%	-10,474	-14,653	-18,462	-18,096	-3,921	-7,371	-6,391	-3,411	-2,234	1,356

(d)

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-6,045	-1,033	-2,570	-1,220	5,050	2,938	4,385	-1,638	-0,265	1,287
85,0%	-9,324	-5,853	-6,408	-5,389	3,647	2,456	3,498	-0,946	0,104	0,987
90,0%	-12,741	-8,634	-11,314	-10,753	3,472	0,771	1,396	-2,558	-1,985	0,586
95,0%	-7,762	-7,662	-9,333	-8,820	0,379	-0,745	-0,727	-1,218	-1,161	-0,038
99,0%	-6,926	-10,755	-11,167	-12,943	-4,652	-4,980	-6,721	-0,187	-1,552	-1,395
99,5%	-10,435	-13,768	-15,651	-14,249	-3,665	-5,730	-4,606	-2,054	-1,139	0,792
99,9%	-9,966	-13,750	-17,972	-17,810	-3,680	-7,422	-6,559	-3,621	-2,530	1,353

(e)

Tabela A.2 - Valores da estatística Z para as medidas de avaliação obtidas na segmentação pelo SegSAR das imagens simuladas na polarização *hh* variando níveis de compressão de três a sete: (a) medida de intensidade \bar{M}_{val} , (b) medida de posição \bar{M}_{pos} , (c) medida de dimensão \bar{M}_{dim} , (d) medida de forma \bar{M}_{for} , e (e) geral \bar{M}_{geral} .

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	2,816	1,627	2,204	2,590	-1,180	-0,356	-0,328	0,724	0,892	0,067
85,0%	2,937	1,318	2,419	1,395	-1,795	-0,642	-1,638	1,196	0,120	-1,046
90,0%	2,337	1,407	1,062	0,673	-1,070	-1,277	-1,730	-0,278	-0,734	-0,420
95,0%	0,954	1,268	1,056	-0,051	0,283	0,111	-1,018	-0,166	-1,337	-1,120
99,0%	0,293	0,900	-0,266	-0,253	0,577	-0,541	-0,534	-1,136	-1,141	0,018
99,5%	-0,019	0,381	0,201	-1,258	0,391	0,215	-1,206	-0,163	-1,682	-1,419
99,9%	-0,717	1,523	-0,548	-1,064	2,091	0,185	-0,247	-1,985	-2,563	-0,460

(a)

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	1,229	0,556	1,522	0,303	-0,787	0,397	-0,976	1,138	-0,251	-1,296
85,0%	3,147	2,118	1,891	2,224	-0,965	-1,220	-1,118	-0,241	-0,066	0,194
90,0%	1,537	2,026	1,180	-0,120	0,554	-0,161	-1,836	-0,633	-2,366	-1,383
95,0%	1,188	1,138	1,904	0,514	-0,095	0,705	-0,702	0,828	-0,632	-1,430
99,0%	1,591	2,213	0,979	1,429	0,732	-0,615	-0,033	-1,302	-0,697	0,527
99,5%	1,994	2,604	2,688	2,193	0,692	0,739	0,183	0,030	-0,523	-0,567
99,9%	1,176	2,138	1,001	-0,262	0,928	-0,110	-1,587	-0,976	-2,730	-1,357

(b)

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	8,850	2,063	7,064	3,064	-7,406	-1,842	-6,314	5,488	1,103	-4,406
85,0%	9,644	1,602	6,778	3,374	-7,937	-2,228	-6,363	5,217	1,718	-3,692
90,0%	9,472	1,137	5,853	1,838	-8,353	-2,506	-7,355	4,862	0,739	-4,088
95,0%	7,721	0,822	6,334	1,578	-6,767	-0,865	-6,333	5,472	0,706	-5,005
99,0%	8,031	1,482	6,491	1,841	-6,638	-1,816	-5,993	5,035	0,414	-4,423
99,5%	6,987	1,227	6,287	1,770	-5,863	-0,573	-5,506	5,172	0,520	-4,801
99,9%	7,769	0,503	5,736	1,102	-7,251	-2,119	-7,176	5,216	0,564	-5,005

(c)

Tabela A.2 - Conclusão

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	7,864	2,259	5,893	3,105	-6,134	-2,011	-5,436	4,018	0,871	-3,278
85,0%	9,210	1,701	6,000	3,551	-7,821	-2,910	-6,049	4,542	1,902	-2,802
90,0%	8,455	1,900	4,638	1,482	-7,030	-3,052	-7,236	3,128	-0,396	-3,408
95,0%	7,113	1,084	5,359	1,425	-6,538	-1,171	-6,394	4,680	0,341	-4,492
99,0%	7,326	1,670	5,294	2,525	-6,382	-2,162	-5,027	4,110	1,038	-2,887
99,5%	6,793	1,688	6,364	2,164	-5,603	-0,497	-5,077	5,131	0,527	-4,603
99,9%	6,377	1,465	4,805	1,159	-5,076	-1,667	-5,812	3,444	-0,420	-4,094

(d)

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	8,481	2,410	6,731	3,437	-6,774	-1,835	-5,762	4,864	1,126	-3,837
85,0%	9,816	2,035	6,610	3,786	-7,927	-2,598	-6,359	4,790	1,741	-3,265
90,0%	9,129	1,933	5,154	1,703	-7,597	-2,764	-7,384	3,666	-0,146	-3,659
95,0%	7,343	1,281	5,847	1,482	-6,310	-0,841	-6,268	4,850	0,181	-4,775
99,0%	7,585	1,912	5,658	2,166	-6,144	-2,033	-5,474	4,071	0,366	-3,505
99,5%	6,812	1,697	6,324	1,876	-5,308	-0,401	-5,326	4,823	0,138	-4,825
99,9%	6,681	1,406	4,917	0,859	-5,434	-1,711	-6,421	3,641	-0,662	-4,508

(e)

Tabela A.3 - Valores da estatística Z para as medidas de avaliação obtidas na segmentação pelo PolSeg da imagem simulada na polarização $h\nu$ variando níveis de compressão de três a sete: (a) medida de intensidade \bar{M}_{val} , (b) medida de posição \bar{M}_{pos} , (c) medida de dimensão \bar{M}_{dim} , (d) medida de forma \bar{M}_{for} , e (e) geral \bar{M}_{geral} .

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-4,439	-3,127	-4,892	-5,125	0,810	-0,658	-0,759	-1,345	-1,447	-0,066
85,0%	-6,667	-7,248	-7,397	-9,496	-1,139	-1,048	-2,823	0,132	-1,376	-1,596
90,0%	-10,402	-11,944	-11,290	-11,787	-0,935	-0,662	-0,921	0,258	0,004	-0,251
95,0%	-8,192	-12,618	-12,052	-13,723	-3,455	-3,046	-3,880	0,401	-0,232	-0,660
99,0%	-5,379	-7,034	-6,301	-8,499	-2,079	-1,344	-3,274	0,666	-0,909	-1,622
99,5%	-2,348	-3,640	-4,101	-4,446	-1,529	-1,631	-2,108	0,106	-0,403	-0,572
99,9%	0,829	-1,526	-1,654	-2,391	-2,144	-2,260	-2,956	-0,126	-0,744	-0,612

(a)

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	3,803	5,334	5,335	5,373	1,219	1,326	1,070	0,140	-0,203	-0,343
85,0%	2,316	3,506	4,105	2,569	1,149	1,748	0,280	0,608	-0,853	-1,446
90,0%	0,149	1,526	1,961	0,560	1,232	1,624	0,360	0,406	-0,919	-1,329
95,0%	-1,239	-0,683	-0,672	-1,531	0,586	0,460	-0,328	-0,063	-0,904	-0,749
99,0%	-7,539	-6,550	-6,882	-7,815	0,068	0,055	-1,027	-0,015	-0,946	-0,982
99,5%	-8,423	-8,868	-8,500	-9,589	-1,640	-0,708	-2,170	0,913	-0,262	-1,295
99,9%	-8,664	-11,295	-10,435	-10,991	-4,486	-3,168	-4,045	1,032	0,252	-0,756

(b)

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	4,419	7,858	7,542	6,592	2,770	2,955	1,962	0,414	-0,696	-1,038
85,0%	0,786	3,780	4,386	3,128	2,926	3,531	2,263	0,635	-0,731	-1,372
90,0%	-3,015	1,237	1,107	-0,730	3,938	3,922	1,987	-0,170	-1,788	-1,687
95,0%	-7,144	-5,126	-5,442	-6,132	1,840	1,310	0,628	-0,461	-1,130	-0,650
99,0%	-11,826	-12,226	-12,229	-12,603	-0,646	-0,744	-1,583	-0,101	-0,952	-0,848
99,5%	-12,687	-14,362	-14,235	-14,364	-2,963	-2,452	-2,995	0,592	-0,039	-0,630
99,9%	-14,440	-17,871	-17,477	-17,510	-5,113	-4,879	-4,885	0,000	0,021	0,020

(c)

Tabela A.3 - Conclusão

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	1,711	4,967	4,139	2,699	2,789	2,243	0,878	-0,352	-1,882	-1,400
85,0%	-1,347	0,823	1,572	-0,120	2,049	2,703	1,161	0,753	-0,895	-1,608
90,0%	-5,426	-2,164	-1,848	-3,742	3,010	3,400	1,270	0,334	-1,588	-1,931
95,0%	-7,835	-7,676	-7,916	-9,140	0,218	-0,017	-0,931	-0,237	-1,164	-0,919
99,0%	-13,533	-14,385	-14,734	-15,561	-1,134	-1,507	-2,540	-0,368	-1,398	-1,034
99,5%	-15,255	-15,298	-16,292	-16,328	-1,959	-2,218	-2,713	-0,089	-0,596	-0,543
99,9%	-19,308	-20,282	-19,775	-20,198	-2,418	-2,929	-3,033	-0,654	-0,688	-0,017

(d)

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	2,385	5,461	4,833	3,810	2,668	2,314	1,261	-0,183	-1,391	-1,117
85,0%	-1,081	1,040	1,741	-0,022	2,020	2,677	1,026	0,688	-1,032	-1,715
90,0%	-5,256	-2,241	-2,097	-3,789	2,781	3,040	1,181	0,192	-1,512	-1,732
95,0%	-7,827	-7,897	-7,877	-9,095	0,061	-0,133	-1,012	-0,196	-1,091	-0,865
99,0%	-11,970	-12,549	-12,547	-13,842	-1,130	-1,159	-2,421	-0,031	-1,229	-1,194
99,5%	-12,697	-13,522	-14,169	-14,327	-2,343	-2,223	-2,885	0,309	-0,389	-0,744
99,9%	-14,838	-17,501	-16,748	-17,340	-3,837	-3,729	-4,123	-0,185	-0,450	-0,242

(e)

Tabela A.4 - Valores da estatística Z para as medidas de avaliação obtidas na segmentação pelo SegSAR das imagens simuladas na polarização hv variando níveis de compressão de três a sete: (a) medida de intensidade \bar{M}_{val} , (b) medida de posição \bar{M}_{pos} , (c) medida de dimensão \bar{M}_{dim} , (d) medida de forma \bar{M}_{for} , e (e) geral \bar{M}_{geral} .

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	4,765	-2,126	3,256	-0,698	-6,969	-1,822	-5,708	5,562	1,514	-4,181
85,0%	5,416	-1,841	1,072	-1,055	-7,546	-4,533	-6,698	3,045	0,810	-2,215
90,0%	6,426	-0,354	2,954	0,662	-6,764	-3,641	-6,125	3,310	1,033	-2,442
95,0%	5,712	-1,218	2,348	0,063	-6,973	-3,621	-5,884	3,638	1,330	-2,385
99,0%	6,402	-2,002	2,343	0,340	-8,582	-3,914	-6,105	4,359	2,367	-2,026
99,5%	5,585	-1,019	1,150	-0,559	-6,445	-4,178	-6,160	2,103	0,477	-1,689
99,9%	3,559	-0,974	0,308	-1,258	-4,636	-3,512	-5,026	1,359	-0,265	-1,677

(a)

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	4,181	0,363	5,565	1,721	-3,793	1,292	-2,290	5,160	1,364	-3,573
85,0%	2,498	0,802	4,048	0,772	-1,717	1,287	-1,782	3,198	-0,043	-3,296
90,0%	4,778	1,376	5,567	2,594	-3,277	0,836	-1,956	4,061	1,219	-2,736
95,0%	3,655	-0,107	3,681	1,644	-3,850	0,044	-1,928	3,875	1,785	-1,962
99,0%	3,588	0,031	3,869	2,203	-3,164	0,379	-1,034	3,435	1,972	-1,355
99,5%	3,340	1,703	3,166	1,164	-1,803	-0,112	-2,230	1,649	-0,509	-2,074
99,9%	2,876	0,992	1,386	0,678	-1,993	-1,659	-2,307	0,391	-0,326	-0,724

(b)

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	10,458	-6,620	5,811	-0,833	-17,112	-4,370	-10,659	12,294	5,429	-6,303
85,0%	8,037	-5,996	4,277	-1,937	-14,522	-4,444	-10,267	11,171	4,180	-6,579
90,0%	9,527	-5,801	5,236	-1,051	-16,212	-4,425	-10,153	11,605	4,399	-6,067
95,0%	9,013	-6,583	4,611	-1,418	-16,403	-4,572	-10,618	11,706	5,179	-6,145
99,0%	8,221	-6,639	3,092	-1,367	-14,441	-5,198	-9,252	9,623	5,125	-4,350
99,5%	6,811	-6,385	0,458	-2,945	-13,889	-6,286	-10,039	6,828	3,417	-3,395
99,9%	4,350	-6,734	-2,763	-4,087	-11,536	-7,483	-8,512	4,188	2,411	-1,551

(c)

Tabela A.4 - Conclusão

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	9,843	-5,068	7,009	-0,969	-15,310	-3,559	-10,828	12,670	4,074	-8,045
85,0%	8,248	-5,020	4,412	-2,177	-14,166	-4,703	-11,207	10,505	3,077	-7,300
90,0%	9,630	-4,370	6,381	-0,683	-15,282	-3,839	-10,403	11,962	3,649	-7,166
95,0%	8,874	-4,918	4,928	-1,052	-14,727	-4,315	-10,521	10,511	4,047	-6,333
99,0%	8,268	-5,357	3,372	-1,313	-13,558	-4,610	-9,554	8,565	4,040	-4,639
99,5%	6,380	-4,746	0,495	-2,392	-11,658	-5,847	-9,212	5,252	2,456	-2,903
99,9%	3,635	-5,272	-3,063	-3,284	-9,514	-7,244	-7,176	2,381	1,871	-0,398

(d)

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	10,101	-5,291	6,843	-0,723	-15,429	-3,840	-10,411	12,399	4,389	-7,306
85,0%	8,291	-5,036	4,402	-1,859	-14,001	-4,736	-10,531	10,413	3,270	-6,693
90,0%	9,872	-4,334	6,088	-0,406	-15,220	-4,206	-9,992	11,269	3,763	-6,325
95,0%	9,167	-5,162	4,849	-0,884	-15,231	-4,560	-10,369	10,575	4,358	-5,911
99,0%	8,712	-5,498	3,562	-0,867	-13,805	-4,936	-9,203	8,814	4,486	-4,276
99,5%	7,057	-4,791	0,926	-2,283	-12,316	-6,026	-9,638	5,708	2,547	-3,213
99,9%	4,437	-5,108	-2,246	-3,281	-10,087	-7,207	-7,967	3,087	1,745	-1,216

(e)

Tabela A. 5 - Valores da estatística Z para as medidas de avaliação obtidas na segmentação pelo PolSeg da imagem simulada na polarização vv variando níveis de compressão de 2 a 7: (a) medida de intensidade \bar{M}_{val} , (b) medida de posição \bar{M}_{pos} , (c) medida de dimensão \bar{M}_{dim} , (d) medida de forma \bar{M}_{for} e (e) geral \bar{M}_{geral} .

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-1,119	0,298	-0,880	0,379	1,336	0,259	1,385	-1,115	0,085	1,171
85,0%	-0,991	0,139	0,750	-0,820	1,059	1,735	0,249	0,561	-0,901	-1,618
90,0%	-2,157	0,138	-2,214	-0,617	2,312	-0,107	1,381	-2,366	-0,750	1,451
95,0%	-5,238	-4,296	-5,241	-4,529	1,119	-0,138	0,370	-1,229	-0,656	0,490
99,0%	-2,481	-3,694	-3,109	-3,036	-1,206	-0,752	-0,529	0,382	0,690	0,261
99,5%	-6,338	-4,802	-3,864	-3,441	1,742	2,724	2,922	1,005	1,273	0,307
99,9%	-5,121	-3,972	-3,721	-4,784	0,838	1,220	0,604	0,342	-0,306	-0,692

(a)

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-5,595	-7,285	-6,984	-7,191	-1,842	-1,389	-1,685	0,512	0,183	-0,330
85,0%	-6,789	-7,602	-7,455	-8,537	-0,971	-1,113	-1,945	-0,197	-0,947	-0,689
90,0%	-7,505	-9,725	-8,892	-8,812	-2,490	-1,624	-1,480	0,832	1,002	0,159
95,0%	-7,389	-12,471	-12,214	-12,293	-5,237	-5,098	-5,060	-0,036	0,168	0,196
99,0%	-10,104	-12,643	-12,946	-12,558	-3,166	-3,455	-2,830	-0,197	0,535	0,772
99,5%	-14,308	-15,514	-15,537	-13,993	-0,245	-0,494	1,003	-0,309	1,444	1,682
99,9%	-8,184	-11,109	-11,701	-11,176	-3,716	-4,511	-3,656	-0,816	0,225	1,085

(b)

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-4,490	-3,697	-4,770	-5,174	1,162	0,225	-0,249	-1,099	-1,609	-0,559
85,0%	-5,967	-4,580	-5,727	-6,041	1,743	0,096	-0,078	-1,581	-1,826	-0,172
90,0%	-5,397	-6,596	-6,641	-6,820	-1,228	-1,259	-1,423	-0,027	-0,184	-0,158
95,0%	-7,794	-11,354	-11,681	-11,606	-3,505	-4,082	-3,805	-0,816	-0,353	0,482
99,0%	-13,617	-14,336	-15,745	-14,960	-0,104	-1,309	-0,497	-1,330	-0,429	0,942
99,5%	-16,505	-15,837	-15,861	-14,325	3,014	2,785	3,840	-0,235	1,244	1,436
99,9%	-9,023	-11,012	-11,554	-11,375	-1,374	-2,255	-1,894	-1,080	-0,631	0,459

(c)

Tabela A.5 - Conclusão

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-8,276	-7,368	-8,811	-8,634	1,044	0,003	0,034	-1,112	-1,061	0,033
85,0%	-8,412	-6,758	-7,591	-8,090	1,545	0,232	-0,011	-1,195	-1,487	-0,233
90,0%	-7,065	-7,467	-8,204	-8,038	-0,320	-1,045	-0,882	-0,736	-0,570	0,165
95,0%	-9,868	-13,431	-13,467	-13,650	-3,564	-3,900	-3,944	-0,526	-0,483	0,056
99,0%	-16,858	-19,924	-20,434	-20,364	-2,592	-2,538	-2,585	0,178	0,103	-0,077
99,5%	-22,528	-22,524	-23,017	-21,891	1,148	1,555	2,229	0,379	1,131	0,804
99,9%	-13,197	-16,880	-17,129	-17,295	-3,450	-3,719	-3,588	-0,285	-0,034	0,262

(d)

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-6,673	-6,080	-7,394	-7,254	0,962	-0,066	-0,060	-1,151	-1,119	0,005
85,0%	-7,509	-6,005	-6,797	-7,702	1,454	0,288	-0,309	-1,070	-1,733	-0,570
90,0%	-6,647	-7,336	-7,977	-7,614	-0,545	-1,224	-0,861	-0,704	-0,329	0,372
95,0%	-9,132	-12,926	-13,010	-13,126	-3,423	-3,912	-3,757	-0,766	-0,443	0,341
99,0%	-13,659	-15,775	-16,367	-16,003	-1,813	-2,247	-1,777	-0,416	0,104	0,541
99,5%	-17,672	-17,726	-17,512	-15,981	1,867	2,019	3,005	0,197	1,457	1,265
99,9%	-9,900	-12,283	-12,725	-12,740	-2,232	-2,790	-2,543	-0,621	-0,263	0,384

(e)

Tabela A.6 - Valores da estatística Z para as medidas de avaliação obtidas na segmentação pelo SegSAR das imagens simuladas na polarização vv variando níveis de compressão de 2 a 7: (a) medida de intensidade \bar{M}_{val} , (b) medida de posição \bar{M}_{pos} , (c) medida de dimensão \bar{M}_{dim} , (d) medida de forma \bar{M}_{for} , e (e) geral \bar{M}_{geral} .

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	2,816	1,627	2,204	2,590	-1,180	-0,356	-0,328	0,724	0,892	0,067
85,0%	2,937	1,318	2,419	1,395	-1,795	-0,642	-1,638	1,196	0,120	-1,046
90,0%	2,337	1,407	1,062	0,673	-1,070	-1,277	-1,730	-0,278	-0,734	-0,420
95,0%	0,954	1,268	1,056	-0,051	0,283	0,111	-1,018	-0,166	-1,337	-1,120
99,0%	0,293	0,900	-0,266	-0,253	0,577	-0,541	-0,534	-1,136	-1,141	0,018
99,5%	-0,019	0,381	0,201	-1,258	0,391	0,215	-1,206	-0,163	-1,682	-1,419
99,9%	-0,717	1,523	-0,548	-1,064	2,091	0,185	-0,247	-1,985	-2,563	-0,460

(a)

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	1,229	0,556	1,522	0,303	-0,787	0,397	-0,976	1,138	-0,251	-1,296
85,0%	3,147	2,118	1,891	2,224	-0,965	-1,220	-1,118	-0,241	-0,066	0,194
90,0%	1,537	2,026	1,180	-0,120	0,554	-0,161	-1,836	-0,633	-2,366	-1,383
95,0%	1,188	1,138	1,904	0,514	-0,095	0,705	-0,702	0,828	-0,632	-1,430
99,0%	1,591	2,213	0,979	1,429	0,732	-0,615	-0,033	-1,302	-0,697	0,527
99,5%	1,994	2,604	2,688	2,193	0,692	0,739	0,183	0,030	-0,523	-0,567
99,9%	1,176	2,138	1,001	-0,262	0,928	-0,110	-1,587	-0,976	-2,730	-1,357

(b)

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	8,850	2,063	7,064	3,064	-7,406	-1,842	-6,314	5,488	1,103	-4,406
85,0%	9,644	1,602	6,778	3,374	-7,937	-2,228	-6,363	5,217	1,718	-3,692
90,0%	9,472	1,137	5,853	1,838	-8,353	-2,506	-7,355	4,862	0,739	-4,088
95,0%	7,721	0,822	6,334	1,578	-6,767	-0,865	-6,333	5,472	0,706	-5,005
99,0%	8,031	1,482	6,491	1,841	-6,638	-1,816	-5,993	5,035	0,414	-4,423
99,5%	6,987	1,227	6,287	1,770	-5,863	-0,573	-5,506	5,172	0,520	-4,801
99,9%	7,769	0,503	5,736	1,102	-7,251	-2,119	-7,176	5,216	0,564	-5,005

(c)

Tabela A.6 - Conclusão

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	7,864	2,259	5,893	3,105	-6,134	-2,011	-5,436	4,018	0,871	-3,278
85,0%	9,210	1,701	6,000	3,551	-7,821	-2,910	-6,049	4,542	1,902	-2,802
90,0%	8,455	1,900	4,638	1,482	-7,030	-3,052	-7,236	3,128	-0,396	-3,408
95,0%	7,113	1,084	5,359	1,425	-6,538	-1,171	-6,394	4,680	0,341	-4,492
99,0%	7,326	1,670	5,294	2,525	-6,382	-2,162	-5,027	4,110	1,038	-2,887
99,5%	6,793	1,688	6,364	2,164	-5,603	-0,497	-5,077	5,131	0,527	-4,603
99,9%	6,377	1,465	4,805	1,159	-5,076	-1,667	-5,812	3,444	-0,420	-4,094

(d)

Nível de conf.	Combinação de níveis de compressão									
	3-4	3-5	3-6	3-7	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	8,481	2,410	6,731	3,437	-6,774	-1,835	-5,762	4,864	1,126	-3,837
85,0%	9,816	2,035	6,610	3,786	-7,927	-2,598	-6,359	4,790	1,741	-3,265
90,0%	9,129	1,933	5,154	1,703	-7,597	-2,764	-7,384	3,666	-0,146	-3,659
95,0%	7,343	1,281	5,847	1,482	-6,310	-0,841	-6,268	4,850	0,181	-4,775
99,0%	7,585	1,912	5,658	2,166	-6,144	-2,033	-5,474	4,071	0,366	-3,505
99,5%	6,812	1,697	6,324	1,876	-5,308	-0,401	-5,326	4,823	0,138	-4,825
99,9%	6,681	1,406	4,917	0,859	-5,434	-1,711	-6,421	3,641	-0,662	-4,508

(e)

Tabela A.7 - Valores da estatística Z para as medidas de avaliação obtidas na segmentação pelo PoSeg da imagem simulada com três bandas nas polarizações *hh-hv-vv* variando níveis de compressão de 4 a 7: (a) medida de intensidade \bar{M}_{val} , (b) medida de posição \bar{M}_{pos} , (c) medida de dimensão \bar{M}_{dim} , (d) medida de forma \bar{M}_{for} , e (e) geral \bar{M}_{geral} .

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-0,276	-0,350	-0,443	-0,066	-0,166	-0,106
85,0%	-0,235	-0,331	-0,434	-0,086	-0,192	-0,114
90,0%	-0,287	-0,369	-0,458	-0,081	-0,181	-0,105
95,0%	-0,444	-0,566	-0,622	-0,109	-0,181	-0,079
99,0%	-0,847	-0,854	-0,925	-0,023	-0,084	-0,059
99,5%	-1,085	-1,078	-1,074	0,012	0,000	-0,012
99,9%	-1,155	-1,058	-1,116	0,095	0,041	-0,054

(a)

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-0,505	-0,579	-0,599	-0,067	-0,111	-0,049
85,0%	-0,393	-0,534	-0,611	-0,127	-0,210	-0,088
90,0%	-0,381	-0,561	-0,589	-0,165	-0,195	-0,033
95,0%	-0,511	-0,693	-0,730	-0,159	-0,199	-0,044
99,0%	-0,745	-0,720	-0,675	0,015	0,058	0,042
99,5%	-0,950	-0,944	-0,875	0,009	0,067	0,058
99,9%	-0,701	-0,639	-0,601	0,048	0,076	0,028

(b)

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-1,482	-1,728	-1,830	-0,227	-0,373	-0,158
85,0%	-1,320	-1,570	-1,713	-0,221	-0,402	-0,195
90,0%	-1,437	-1,767	-1,862	-0,323	-0,446	-0,134
95,0%	-1,843	-2,177	-2,269	-0,307	-0,436	-0,141
99,0%	-2,057	-2,101	-1,949	-0,036	0,065	0,100
99,5%	-2,755	-2,671	-2,574	0,039	0,120	0,079
99,9%	-2,480	-2,285	-2,333	0,177	0,130	-0,047

(c)

Tabela A.7 - Conclusão

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-2,595	-2,902	-2,956	-0,311	-0,398	-0,094
85,0%	-2,397	-2,730	-2,831	-0,303	-0,443	-0,152
90,0%	-2,621	-2,978	-3,089	-0,352	-0,476	-0,128
95,0%	-3,082	-3,478	-3,551	-0,366	-0,456	-0,095
99,0%	-3,221	-3,205	-3,027	-0,015	0,129	0,141
99,5%	-4,060	-3,993	-3,859	-0,003	0,121	0,122
99,9%	-3,732	-3,541	-3,599	0,137	0,099	-0,038

(d)

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-1,489	-1,699	-1,766	-0,197	-0,297	-0,107
85,0%	-1,343	-1,574	-1,676	-0,205	-0,339	-0,145
90,0%	-1,461	-1,732	-1,814	-0,259	-0,360	-0,109
95,0%	-1,792	-2,082	-2,145	-0,263	-0,352	-0,097
99,0%	-2,013	-2,021	-1,912	-0,018	0,061	0,078
99,5%	-2,588	-2,530	-2,441	0,015	0,090	0,074
99,9%	-2,358	-2,209	-2,237	0,125	0,093	-0,031

(e)

Tabela A.8 - Valores da estatística Z para as medidas de avaliação obtidas na segmentação pelo SegSAR da imagem simulada com três bandas nas polarizações hh-hv-vv variando níveis de compressão de 4 a 7: (a) medida de intensidade \bar{M}_{val} , (b) medida de posição \bar{M}_{pos} , (c) medida de dimensão \bar{M}_{dim} , (d) medida de forma \bar{M}_{for} , e (e) geral \bar{M}_{geral} .

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-3,846	-5,024	-6,357	-1,025	-2,577	-1,748
85,0%	-3,186	-4,666	-6,133	-1,282	-2,889	-1,874
90,0%	-3,805	-4,962	-6,160	-1,296	-2,902	-1,782
95,0%	-6,001	-7,823	-8,544	-1,724	-2,798	-1,301
99,0%	-10,529	-10,597	-11,514	-0,374	-1,410	-0,961
99,5%	-13,070	-12,983	-12,919	0,196	-0,002	-0,192
99,9%	-13,681	-12,470	-13,208	1,337	0,588	-0,759

(a)

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-8,158	-9,476	-9,584	-1,254	-1,981	-0,895
85,0%	-6,236	-8,765	-10,001	-2,203	-3,616	-1,613
90,0%	-5,744	-8,763	-9,215	-2,785	-3,300	-0,606
95,0%	-7,711	-10,919	-11,446	-2,552	-3,183	-0,743
99,0%	-10,769	-10,383	-9,720	0,294	1,115	0,792
99,5%	-12,619	-12,555	-11,521	0,143	1,031	0,901
99,9%	-8,856	-7,920	-7,320	0,610	0,940	0,338

(b)

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-9,590	-11,311	-11,913	-1,773	-2,859	-1,264
85,0%	-8,537	-10,320	-11,211	-1,697	-3,046	-1,563
90,0%	-9,129	-11,334	-11,927	-2,592	-3,555	-1,139
95,0%	-11,890	-14,212	-14,773	-2,431	-3,412	-1,163
99,0%	-12,699	-12,969	-11,988	-0,313	0,536	0,831
99,5%	-16,282	-15,683	-15,042	0,278	0,842	0,546
99,9%	-14,410	-13,160	-13,459	1,098	0,804	-0,290

(c)

Tabela A.8 - Conclusão

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-14,411	-16,121	-16,425	-2,422	-3,077	-0,760
85,0%	-13,289	-15,163	-15,727	-2,306	-3,351	-1,229
90,0%	-14,252	-16,161	-16,742	-2,774	-3,784	-1,098
95,0%	-17,374	-19,667	-20,078	-2,772	-3,456	-0,767
99,0%	-17,151	-17,085	-16,146	-0,117	0,996	1,076
99,5%	-21,474	-21,045	-20,283	-0,021	0,809	0,793
99,9%	-19,560	-18,334	-18,721	0,781	0,570	-0,214

(d)

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-11,996	-13,785	-14,298	-2,026	-3,004	-1,137
85,0%	-10,735	-12,717	-13,517	-2,058	-3,366	-1,538
90,0%	-11,422	-13,609	-14,253	-2,691	-3,741	-1,215
95,0%	-14,371	-16,846	-17,340	-2,671	-3,545	-1,032
99,0%	-15,277	-15,346	-14,508	-0,208	0,649	0,831
99,5%	-19,201	-18,681	-17,952	0,136	0,822	0,660
99,9%	-17,252	-16,000	-16,194	0,981	0,730	-0,241

(e)

Tabela A.9 - Valores da estatística Z para as medidas de avaliação obtidas na segmentação pelo PolSeg da imagem simulada com duas bandas nas polarizações *hh-hv* variando níveis de compressão de 2 a 7: (a) medida de intensidade \bar{M}_{val} , (b) medida de posição \bar{M}_{pos} , (c) medida de dimensão \bar{M}_{dim} , (d) medida de forma \bar{M}_{for} , e (e) geral \bar{M}_{geral} .

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-0,999	-1,116	-1,397	-0,104	-0,432	-0,338
85,0%	-0,253	-0,311	-0,754	-0,059	-0,477	-0,410
90,0%	-0,539	-0,637	-1,272	-0,101	-0,728	-0,622
95,0%	-2,286	-3,349	-3,974	-1,126	-1,736	-0,579
99,0%	-6,569	-7,544	-8,905	-0,795	-1,975	-1,206
99,5%	-5,477	-5,813	-6,798	0,019	-1,104	-1,218
99,9%	-6,776	-6,936	-7,594	0,035	-0,692	-0,756

(a)

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-5,883	-7,571	-7,691	-1,922	-2,030	-0,097
85,0%	-6,473	-8,105	-8,304	-1,653	-2,054	-0,463
90,0%	-6,453	-8,082	-8,003	-1,605	-1,680	-0,124
95,0%	-9,139	-8,233	-9,291	-0,184	-1,151	-0,839
99,0%	-10,909	-11,490	-11,961	-0,988	-1,671	-0,666
99,5%	-9,005	-10,299	-10,493	-1,186	-1,488	-0,325
99,9%	-5,685	-5,500	-6,851	0,392	-0,979	-1,433

(b)

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-8,482	-10,083	-10,230	-2,131	-2,460	-0,368
85,0%	-8,937	-10,508	-10,821	-1,816	-2,427	-0,670
90,0%	-8,722	-10,369	-10,400	-1,783	-2,043	-0,323
95,0%	-10,755	-11,630	-12,224	-1,782	-2,498	-0,647
99,0%	-12,553	-12,766	-13,523	-0,803	-2,136	-1,274
99,5%	-12,303	-13,244	-13,598	-0,711	-1,449	-0,799
99,9%	-8,903	-9,731	-10,473	0,292	-0,941	-1,475

(c)

Tabela A.9 - Conclusão

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-13,939	-15,521	-15,206	-2,387	-2,384	-0,116
85,0%	-15,104	-16,699	-16,890	-1,958	-2,615	-0,751
90,0%	-15,384	-16,926	-16,999	-1,913	-2,310	-0,467
95,0%	-17,828	-17,921	-18,792	-1,215	-2,364	-1,015
99,0%	-17,975	-17,984	-18,575	-0,325	-1,490	-1,131
99,5%	-18,594	-19,599	-19,993	-0,684	-1,595	-0,996
99,9%	-13,989	-16,030	-16,486	-0,411	-1,619	-1,490

(d)

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-8,482	-10,083	-10,230	-2,131	-2,460	-0,368
85,0%	-8,937	-10,508	-10,821	-1,816	-2,427	-0,670
90,0%	-8,722	-10,369	-10,400	-1,783	-2,043	-0,323
95,0%	-10,755	-11,630	-12,224	-1,782	-2,498	-0,647
99,0%	-12,553	-12,766	-13,523	-0,803	-2,136	-1,274
99,5%	-12,303	-13,244	-13,598	-0,711	-1,449	-0,799
99,9%	-8,903	-9,731	-10,473	0,292	-0,941	-1,475

(e)

Tabela A.10 - Valores da estatística Z para as medidas de avaliação obtidas na segmentação pelo PolSeg da imagem simulada com duas bandas nas polarizações *hh-vv* variando níveis de compressão de 2 a 7: (a) medida de intensidade \bar{M}_{val} , (b) medida de posição \bar{M}_{pos} , (c) medida de dimensão \bar{M}_{dim} , (d) medida de forma \bar{M}_{for} , e (e) geral \bar{M}_{geral} .

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-9,398	-10,014	-8,926	-0,749	0,367	1,091
85,0%	-9,357	-10,149	-9,620	-0,923	-0,409	0,490
90,0%	-11,027	-12,075	-11,033	-0,781	0,058	0,849
95,0%	-10,656	-10,882	-11,163	0,113	-0,014	-0,135
99,0%	-9,592	-9,787	-10,046	0,115	-0,116	-0,243
99,5%	-10,049	-9,987	-10,125	0,172	-0,202	-0,373
99,9%	-9,709	-8,722	-8,633	1,276	1,422	0,141

(a)

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-11,069	-12,913	-12,114	-1,901	-0,553	1,501
85,0%	-9,141	-10,482	-12,341	-1,462	-2,625	-0,958
90,0%	-10,243	-11,902	-11,852	-1,329	-0,811	0,625
95,0%	-12,604	-13,542	-13,781	-1,052	-0,708	0,426
99,0%	-12,161	-11,437	-12,137	0,232	-0,042	-0,270
99,5%	-11,358	-11,261	-11,051	0,151	-0,158	-0,303
99,9%	-7,358	-6,782	-6,302	0,300	0,964	0,636

(b)

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-15,048	-16,451	-16,092	-2,168	-0,721	1,655
85,0%	-13,862	-15,151	-15,573	-1,832	-2,038	-0,097
90,0%	-16,028	-17,073	-16,913	-1,454	-0,758	0,758
95,0%	-14,044	-14,265	-14,684	-0,306	-0,563	-0,247
99,0%	-10,297	-9,576	-10,116	0,484	-0,156	-0,616
99,5%	-10,709	-10,264	-10,420	0,139	-0,441	-0,553
99,9%	-8,627	-7,795	-7,066	0,795	1,414	0,627

(c)

Tabela A.10 - Conclusão

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-20,067	-21,417	-21,380	-2,108	-1,564	0,641
85,0%	-18,023	-19,674	-20,067	-2,381	-2,806	-0,375
90,0%	-20,902	-22,060	-22,144	-1,469	-1,188	0,332
95,0%	-19,101	-19,502	-19,830	-0,627	-0,723	-0,076
99,0%	-15,348	-14,989	-15,608	0,233	-0,467	-0,691
99,5%	-16,513	-16,280	-16,207	0,057	-0,542	-0,587
99,9%	-13,868	-13,245	-12,488	0,361	1,062	0,689

(d)

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-17,810	-19,228	-18,897	-2,239	-1,106	1,276
85,0%	-16,071	-17,584	-18,038	-2,152	-2,506	-0,257
90,0%	-18,536	-19,754	-19,691	-1,498	-0,952	0,614
95,0%	-16,876	-17,188	-17,583	-0,491	-0,631	-0,121
99,0%	-13,285	-12,729	-13,337	0,335	-0,303	-0,624
99,5%	-14,066	-13,694	-13,716	0,112	-0,469	-0,561
99,9%	-11,650	-10,872	-10,188	0,629	1,281	0,645

(e)

Tabela A.11 - Valores da estatística Z para as medidas de avaliação obtidas na segmentação pelo PolSeg da imagem simulada com duas bandas nas polarizações $hv-vv$ variando níveis de compressão de quatro a sete: (a) medida de intensidade \bar{M}_{val} , (b) medida de posição \bar{M}_{pos} , (c) medida de dimensão \bar{M}_{dim} , (d) medida de forma \bar{M}_{for} , e (e) geral \bar{M}_{geral} .

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-2,131	-2,175	-3,355	-0,116	-1,347	-1,187
85,0%	-3,035	-3,981	-4,474	-1,086	-1,658	-0,576
90,0%	-4,122	-4,680	-5,683	-0,450	-1,554	-1,153
95,0%	-5,643	-6,251	-6,248	-0,477	-0,618	-0,163
99,0%	-7,045	-9,525	-8,625	-2,729	-1,561	1,271
99,5%	-6,619	-8,238	-7,674	-1,940	-1,209	0,751
99,9%	-6,056	-8,237	-7,187	-2,869	-1,836	0,777

(a)

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-4,468	-3,715	-4,393	1,171	0,497	-0,753
85,0%	-4,926	-4,654	-4,870	0,218	-0,016	-0,230
90,0%	-6,402	-5,291	-5,233	1,251	1,113	-0,097
95,0%	-6,030	-6,576	-6,642	0,056	-0,021	-0,087
99,0%	-11,144	-16,423	-14,256	-4,320	-2,559	1,781
99,5%	-6,997	-8,340	-6,441	-1,389	0,294	1,621
99,9%	-1,319	-3,398	-3,367	-1,929	-1,857	0,125

(b)

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-10,537	-11,068	-12,564	-0,406	-1,742	-1,353
85,0%	-10,993	-12,322	-12,512	-1,893	-2,223	-0,345
90,0%	-12,362	-13,165	-12,927	-0,870	-1,185	-0,370
95,0%	-12,019	-13,930	-12,515	-1,521	-0,601	0,870
99,0%	-10,140	-12,362	-10,264	-2,654	-0,448	2,100
99,5%	-8,578	-10,772	-8,616	-2,372	-0,067	2,295
99,9%	-6,303	-9,688	-8,906	-3,434	-2,554	0,933

(c)

Tabela A.11 - Conclusão

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-20,067	-21,417	-21,380	-2,108	-1,564	0,641
85,0%	-18,023	-19,674	-20,067	-2,381	-2,806	-0,375
90,0%	-20,902	-22,060	-22,144	-1,469	-1,188	0,332
95,0%	-19,101	-19,502	-19,830	-0,627	-0,723	-0,076
99,0%	-15,348	-14,989	-15,608	0,233	-0,467	-0,691
99,5%	-16,513	-16,280	-16,207	0,057	-0,542	-0,587
99,9%	-13,868	-13,245	-12,488	0,361	1,062	0,689

(d)

Nível de conf.	Pares de valores de níveis de compressão					
	4-5	4-6	4-7	5-6	5-7	6-7
80,0%	-17,810	-19,228	-18,897	-2,239	-1,106	1,276
85,0%	-16,071	-17,584	-18,038	-2,152	-2,506	-0,257
90,0%	-18,536	-19,754	-19,691	-1,498	-0,952	0,614
95,0%	-16,876	-17,188	-17,583	-0,491	-0,631	-0,121
99,0%	-13,285	-12,729	-13,337	0,335	-0,303	-0,624
99,5%	-14,066	-13,694	-13,716	0,112	-0,469	-0,561
99,9%	-11,650	-10,872	-10,188	0,629	1,281	0,645

(e)

APÊNDICE B – VALORES OBTIDOS PARA AS MEDIDAS DE AJUSTE

B.1 Resultados obtidos para as medidas de ajuste usando o algoritmo PolSeg na segmentação com polarização *hh*

Mval							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,9347	0,9594	0,9626	0,9608	0,9619	0,9614
	σ	0,0089	0,0082	0,0072	0,0080	0,0072	0,0082
85,0%	μ	0,9324	0,9591	0,9621	0,9608	0,9616	0,9612
	σ	0,0104	0,0089	0,0080	0,0075	0,0084	0,0089
90,0%	μ	0,9287	0,9579	0,9591	0,9577	0,9603	0,9596
	σ	0,0097	0,0107	0,0106	0,0121	0,0101	0,0105
95,0%	μ	0,9216	0,9525	0,9550	0,9552	0,9560	0,9558
	σ	0,0132	0,0133	0,0119	0,0154	0,0110	0,0133
99,0%	μ	0,8878	0,9401	0,9390	0,9420	0,9433	0,9445
	σ	0,0154	0,0174	0,0167	0,0226	0,0194	0,0182
99,5%	μ	0,8733	0,9313	0,9321	0,9333	0,9410	0,9346
	σ	0,0172	0,0223	0,0257	0,0222	0,0188	0,0228
99,9%	μ	0,8433	0,9193	0,9146	0,9140	0,9268	0,9219
	σ	0,0192	0,0195	0,0283	0,0298	0,0267	0,0250

Mdim							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,7446	0,8359	0,8538	0,8338	0,8395	0,8342
	σ	0,0307	0,0282	0,0262	0,0275	0,0327	0,0320
85,0%	μ	0,7181	0,8190	0,8541	0,8409	0,8445	0,8406
	σ	0,0287	0,0314	0,0286	0,0287	0,0316	0,0325
90,0%	μ	0,6751	0,7979	0,8497	0,8363	0,8465	0,8438
	σ	0,0299	0,0328	0,0270	0,0301	0,0304	0,0315
95,0%	μ	0,6419	0,7955	0,8330	0,8325	0,8359	0,8358
	σ	0,0384	0,0429	0,0342	0,0332	0,0292	0,0318
99,0%	μ	0,4918	0,7470	0,7811	0,8003	0,7996	0,8058
	σ	0,0481	0,0405	0,0312	0,0328	0,0309	0,0301
99,5%	μ	0,4486	0,7129	0,7740	0,7896	0,7942	0,7943
	σ	0,0506	0,0472	0,0317	0,0303	0,0313	0,0352
99,9%	μ	0,4069	0,6683	0,7318	0,7532	0,7692	0,7627
	σ	0,0431	0,0423	0,0399	0,0377	0,0364	0,0319

B.1 - Continuação

Mpos							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,9226	0,9498	0,9605	0,9569	0,9577	0,9561
	σ	0,0139	0,0115	0,0074	0,0075	0,0082	0,0088
85,0%	μ	0,9090	0,9429	0,9599	0,9573	0,9569	0,9557
	σ	0,0137	0,0115	0,0080	0,0081	0,0095	0,0094
90,0%	μ	0,8921	0,9321	0,9571	0,9541	0,9565	0,9563
	σ	0,0152	0,0115	0,0085	0,0090	0,0077	0,0077
95,0%	μ	0,8817	0,9329	0,9499	0,9500	0,9536	0,9535
	σ	0,0177	0,0178	0,0149	0,0119	0,0087	0,0091
99,0%	μ	0,8111	0,9096	0,9298	0,9430	0,9443	0,9462
	σ	0,0329	0,0230	0,0177	0,0127	0,0106	0,0092
99,5%	μ	0,7756	0,8919	0,9257	0,9383	0,9421	0,9413
	σ	0,0395	0,0228	0,0173	0,0121	0,0106	0,0144
99,9%	μ	0,7059	0,8682	0,9070	0,9229	0,9320	0,9312
	σ	0,0487	0,0223	0,0211	0,0187	0,0170	0,0153

Mfor							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,5670	0,6878	0,7133	0,6914	0,7010	0,6940
	σ	0,0263	0,0310	0,0293	0,0322	0,0365	0,0356
85,0%	μ	0,5522	0,6807	0,7209	0,7027	0,7086	0,7032
	σ	0,0251	0,0337	0,0300	0,0316	0,0347	0,0347
90,0%	μ	0,5279	0,6686	0,7198	0,7029	0,7148	0,7123
	σ	0,0263	0,0325	0,0268	0,0333	0,0331	0,0316
95,0%	μ	0,4964	0,6589	0,7094	0,7049	0,7103	0,7112
	σ	0,0310	0,0415	0,0379	0,0342	0,0290	0,0349
99,0%	μ	0,3463	0,6085	0,6497	0,6735	0,6741	0,6816
	σ	0,0381	0,0383	0,0335	0,0384	0,0380	0,0333
99,5%	μ	0,3115	0,5743	0,6407	0,6594	0,6690	0,6656
	σ	0,0375	0,0433	0,0346	0,0368	0,0363	0,0405
99,9%	μ	0,2788	0,5251	0,5874	0,6127	0,6348	0,6265
	σ	0,0282	0,0383	0,0455	0,0460	0,0455	0,0409

B.1 - Conclusão

Mgeral							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,7922	0,8582	0,8726	0,8607	0,8650	0,8614
	σ	0,0170	0,0174	0,0161	0,0170	0,0200	0,0197
85,0%	μ	0,7779	0,8504	0,8742	0,8654	0,8679	0,8652
	σ	0,0160	0,0191	0,0170	0,0172	0,0195	0,0196
90,0%	μ	0,7560	0,8392	0,8714	0,8628	0,8695	0,8680
	σ	0,0170	0,0196	0,0160	0,0191	0,0183	0,0183
95,0%	μ	0,7354	0,8349	0,8618	0,8607	0,8640	0,8640
	σ	0,0212	0,0261	0,0228	0,0211	0,0169	0,0203
99,0%	μ	0,6343	0,8013	0,8249	0,8397	0,8403	0,8445
	σ	0,0297	0,0267	0,0212	0,0237	0,0225	0,0201
99,5%	μ	0,6023	0,7776	0,8181	0,8301	0,8366	0,8339
	σ	0,0309	0,0308	0,0237	0,0226	0,0218	0,0249
99,9%	μ	0,5587	0,7452	0,7852	0,8007	0,8157	0,8106
	σ	0,0302	0,0270	0,0297	0,0300	0,0284	0,0249

Número de regiões							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	151,89	102,68	83,76	85,22	82,19	84,45
85,0%	μ	111,48	82,91	72,1	74,34	72,82	74,04
90,0%	μ	74,74	63,03	60,7	63,73	62,67	62,67
95,0%	μ	56,55	52,4	50,01	52,34	51,12	50,75
99,0%	μ	70,34	37,87	39,73	39,57	40,14	40,4
99,5%	μ	53,87	33,72	35,21	37,15	36,22	36,3
99,9%	μ	33,98	29,62	31,09	32,99	33,93	33,93

Tempo de processamento							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	16,43	15,85	14,73	16,49	18,23	18,03
85,0%	μ	14,55	15,54	13,80	15,57	16,69	17,28
90,0%	μ	13,81	15,72	13,11	14,65	15,55	16,91
95,0%	μ	14,00	13,05	12,31	13,73	14,32	14,84
99,0%	μ	19,83	12,15	11,71	12,02	12,48	12,87
99,5%	μ	22,11	13,08	11,42	11,92	12,23	12,65
99,9%	μ	25,27	14,23	11,98	12,08	11,79	12,02

B.2 Resultados obtidos para as medidas de ajuste usando o algoritmo PolSeg na segmentação do vetor de espalhamento complexo com polarização *hv*.

Mval							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,9079	0,9281	0,9341	0,9329	0,9349	0,9350
	σ	0,0106	0,0107	0,0083	0,0113	0,0089	0,0081
85,0%	μ	0,9074	0,9197	0,9298	0,9315	0,9313	0,9335
	σ	0,0111	0,0116	0,0097	0,0114	0,0106	0,0087
90,0%	μ	0,9058	0,9112	0,9274	0,9289	0,9285	0,9289
	σ	0,0137	0,0102	0,0119	0,0108	0,0115	0,0111
95,0%	μ	0,9060	0,8968	0,9157	0,9233	0,9225	0,9238
	σ	0,0147	0,0156	0,0170	0,0140	0,0145	0,0119
99,0%	μ	0,8752	0,8836	0,9001	0,9061	0,9041	0,9086
	σ	0,0144	0,0239	0,0194	0,0213	0,0221	0,0172
99,5%	μ	0,8639	0,8869	0,8936	0,8988	0,8984	0,9002
	σ	0,0158	0,0188	0,0211	0,0265	0,0207	0,0231
99,9%	μ	0,8561	0,8796	0,8771	0,8846	0,8851	0,8874
	σ	0,0204	0,0197	0,0233	0,0263	0,0266	0,0257

Mdim							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,8400	0,8942	0,8800	0,8704	0,8689	0,8728
	σ	0,0240	0,0193	0,0256	0,0233	0,0273	0,0260
85,0%	μ	0,8084	0,8897	0,8872	0,8768	0,8744	0,8794
	σ	0,0297	0,0216	0,0236	0,0264	0,0274	0,0246
90,0%	μ	0,7351	0,8813	0,8909	0,8772	0,8778	0,8838
	σ	0,0418	0,0213	0,0234	0,0256	0,0237	0,0267
95,0%	μ	0,6486	0,8602	0,8847	0,8783	0,8800	0,8824
	σ	0,0572	0,0247	0,0238	0,0253	0,0268	0,0266
99,0%	μ	0,4785	0,8051	0,8594	0,8622	0,8626	0,8666
	σ	0,0454	0,0347	0,0299	0,0311	0,0316	0,0342
99,5%	μ	0,4933	0,7687	0,8403	0,8536	0,8509	0,8538
	σ	0,0742	0,0482	0,0292	0,0342	0,0317	0,0344
99,9%	μ	0,4741	0,7119	0,8024	0,8242	0,8242	0,8242
	σ	0,0752	0,0550	0,0300	0,0305	0,0333	0,0330

B.2 - Continuação

Mpos							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,9568	0,9695	0,9639	0,9620	0,9618	0,9623
	σ	0,0089	0,0090	0,0114	0,0106	0,0111	0,0097
85,0%	μ	0,9461	0,9662	0,9628	0,9610	0,9601	0,9624
	σ	0,0123	0,0098	0,0109	0,0110	0,0112	0,0112
90,0%	μ	0,9114	0,9613	0,9610	0,9590	0,9584	0,9605
	σ	0,0200	0,0093	0,0117	0,0111	0,0112	0,0107
95,0%	μ	0,8856	0,9541	0,9561	0,9552	0,9553	0,9566
	σ	0,0269	0,0112	0,0108	0,0105	0,0130	0,0114
99,0%	μ	0,8019	0,9360	0,9506	0,9505	0,9505	0,9525
	σ	0,0264	0,0158	0,0113	0,0156	0,0141	0,0140
99,5%	μ	0,7932	0,9203	0,9418	0,9450	0,9431	0,9456
	σ	0,0492	0,0230	0,0113	0,0159	0,0139	0,0130
99,9%	μ	0,7537	0,9009	0,9292	0,9373	0,9354	0,9368
	σ	0,0679	0,0298	0,0133	0,0121	0,0141	0,0133

Mfor							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,6788	0,7554	0,7488	0,7375	0,7390	0,7450
	σ	0,0293	0,0245	0,0303	0,0264	0,0313	0,0298
85,0%	μ	0,6519	0,7557	0,7607	0,7525	0,7493	0,7561
	σ	0,0312	0,0252	0,0277	0,0288	0,0320	0,0281
90,0%	μ	0,5791	0,7518	0,7716	0,7596	0,7583	0,7662
	σ	0,0404	0,0230	0,0282	0,0279	0,0268	0,0310
95,0%	μ	0,4932	0,7350	0,7666	0,7657	0,7667	0,7706
	σ	0,0461	0,0258	0,0311	0,0306	0,0307	0,0292
99,0%	μ	0,3425	0,6658	0,7381	0,7441	0,7461	0,7518
	σ	0,0329	0,0387	0,0368	0,0382	0,0383	0,0394
99,5%	μ	0,3420	0,6346	0,7237	0,7350	0,7355	0,7387
	σ	0,0557	0,0471	0,0346	0,0456	0,0402	0,0429
99,9%	μ	0,3038	0,5548	0,6784	0,6920	0,6962	0,6963
	σ	0,0543	0,0526	0,0365	0,0425	0,0484	0,0463

B.2 - Conclusão

Mgeral							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,8459	0,8868	0,8817	0,8757	0,8762	0,8788
	σ	0,0153	0,0135	0,0165	0,0150	0,0173	0,0160
85,0%	μ	0,8284	0,8828	0,8851	0,8805	0,8788	0,8829
	σ	0,0170	0,0147	0,0155	0,0170	0,0180	0,0157
90,0%	μ	0,7829	0,8764	0,8877	0,8812	0,8808	0,8849
	σ	0,0241	0,0138	0,0166	0,0165	0,0157	0,0177
95,0%	μ	0,7334	0,8615	0,8808	0,8806	0,8811	0,8833
	σ	0,0309	0,0164	0,0183	0,0178	0,0187	0,0175
99,0%	μ	0,6245	0,8226	0,8621	0,8657	0,8658	0,8699
	σ	0,0245	0,0246	0,0219	0,0240	0,0241	0,0236
99,5%	μ	0,6231	0,8026	0,8499	0,8581	0,8570	0,8596
	σ	0,0439	0,0303	0,0216	0,0277	0,0235	0,0257
99,9%	μ	0,5969	0,7618	0,8218	0,8345	0,8352	0,8362
	σ	0,0502	0,0336	0,0225	0,0245	0,0282	0,0267

Número de regiões							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	154,16	92,40	85,06	88,15	86,86	85,72
85,0%	μ	137,11	74,16	73,01	76,37	74,93	75,55
90,0%	μ	114,08	60,18	62,23	65,07	64,64	63,48
95,0%	μ	90,95	47,16	51,42	53,15	51,85	52,57
99,0%	μ	34,43	43,82	40,11	41,92	41,71	41,41
99,5%	μ	37,92	38,88	34,66	39,25	36,85	36,97
99,9%	μ	55,33	38,42	31,91	36,94	35,00	36,05

Tempo de processamento							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	14,32	13,82	15,02	16,45	17,77	18,14
85,0%	μ	13,71	12,75	14,12	15,47	16,51	17,07
90,0%	μ	14,47	11,91	13,41	15,51	15,97	16,44
95,0%	μ	16,05	10,98	12,37	13,78	14,57	15,00
99,0%	μ	19,03	10,38	10,94	12,29	12,95	13,41
99,5%	μ	17,29	11,56	10,62	11,98	12,54	12,91
99,9%	μ	19,07	11,35	10,25	11,36	12,00	12,37

B.3 Resultados obtidos para as medidas de ajuste usando o algoritmo PolSeg na segmentação do vetor de espalhamento complexo com polarização vv.

Mval							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,8446	0,8592	0,8614	0,8586	0,8608	0,8584
	σ	0,0211	0,0124	0,0156	0,0138	0,0145	0,0146
85,0%	μ	0,8316	0,8544	0,8565	0,8541	0,8527	0,8561
	σ	0,0242	0,0156	0,0150	0,0179	0,0162	0,0128
90,0%	μ	0,8141	0,8441	0,8500	0,8437	0,8503	0,8460
	σ	0,0247	0,0206	0,0180	0,0205	0,0188	0,0227
95,0%	μ	0,7831	0,8246	0,8416	0,8382	0,8420	0,8403
	σ	0,0240	0,0238	0,0221	0,0209	0,0233	0,0254
99,0%	μ	0,7664	0,8137	0,8226	0,8266	0,8253	0,8244
	σ	0,0239	0,0266	0,0242	0,0228	0,0262	0,0231
99,5%	μ	0,7666	0,8018	0,8280	0,8212	0,8174	0,8162
	σ	0,0242	0,0304	0,0280	0,0268	0,0268	0,0289
99,9%	μ	0,7529	0,7898	0,8108	0,8070	0,8054	0,8083
	σ	0,0205	0,0274	0,0306	0,0336	0,0319	0,0274

Mdim							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,5102	0,7246	0,7482	0,7430	0,7473	0,7493
	σ	0,0774	0,0403	0,0339	0,0294	0,0253	0,0256
85,0%	μ	0,4118	0,7038	0,7367	0,7286	0,7363	0,7371
	σ	0,0717	0,0438	0,0337	0,0321	0,0361	0,0336
90,0%	μ	0,3597	0,6782	0,7125	0,7191	0,7192	0,7200
	σ	0,0610	0,0502	0,0392	0,0365	0,0361	0,0353
95,0%	μ	0,3324	0,6042	0,6730	0,6956	0,7001	0,6974
	σ	0,0599	0,0711	0,0523	0,0376	0,0410	0,0374
99,0%	μ	0,3359	0,4933	0,6430	0,6439	0,6528	0,6468
	σ	0,0583	0,0915	0,0609	0,0515	0,0435	0,0464
99,5%	μ	0,3286	0,4630	0,6466	0,6230	0,6245	0,6143
	σ	0,0628	0,0908	0,0642	0,0444	0,0461	0,0540
99,9%	μ	0,2795	0,4493	0,5635	0,5767	0,5858	0,5819
	σ	0,0569	0,1005	0,0770	0,0573	0,0621	0,0590

B.3 - Continuação

Mpos							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,8624	0,9238	0,9346	0,9375	0,9368	0,9373
	σ	0,0227	0,0155	0,0116	0,0108	0,0103	0,0106
85,0%	μ	0,8278	0,9160	0,9305	0,9323	0,9326	0,9339
	σ	0,0325	0,0172	0,0127	0,0128	0,0143	0,0121
90,0%	μ	0,7867	0,9033	0,9226	0,9278	0,9261	0,9257
	σ	0,0398	0,0208	0,0152	0,0143	0,0150	0,0148
95,0%	μ	0,7052	0,8715	0,9003	0,9157	0,9158	0,9153
	σ	0,0526	0,0309	0,0237	0,0173	0,0189	0,0177
99,0%	μ	0,6219	0,8090	0,8781	0,8916	0,8923	0,8897
	σ	0,0606	0,0598	0,0334	0,0265	0,0240	0,0237
99,5%	μ	0,6092	0,7778	0,8793	0,8804	0,8815	0,8744
	σ	0,0588	0,0610	0,0363	0,0256	0,0273	0,0324
99,9%	μ	0,5715	0,7596	0,8319	0,8541	0,8585	0,8529
	σ	0,0515	0,0758	0,0455	0,0386	0,0373	0,0350

Mfor							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,3203	0,5189	0,5578	0,5530	0,5578	0,5577
	σ	0,0607	0,0333	0,0333	0,0322	0,0291	0,0302
85,0%	μ	0,2492	0,5114	0,5547	0,5473	0,5535	0,5548
	σ	0,0553	0,0397	0,0327	0,0352	0,0387	0,0360
90,0%	μ	0,2170	0,4924	0,5357	0,5374	0,5413	0,5404
	σ	0,0364	0,0470	0,0393	0,0378	0,0367	0,0369
95,0%	μ	0,2052	0,4192	0,4977	0,5195	0,5225	0,5221
	σ	0,0347	0,0639	0,0473	0,0385	0,0423	0,0400
99,0%	μ	0,2070	0,3082	0,4454	0,4632	0,4621	0,4625
	σ	0,0352	0,0632	0,0513	0,0453	0,0409	0,0418
99,5%	μ	0,2025	0,2857	0,4490	0,4418	0,4397	0,4354
	σ	0,0381	0,0557	0,0464	0,0413	0,0372	0,0397
99,9%	μ	0,1676	0,2747	0,3789	0,4013	0,4030	0,4015
	σ	0,0292	0,0617	0,0491	0,0425	0,0424	0,0395

B.3 - Conclusão

Mgeral							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,6344	0,7566	0,7755	0,7730	0,7757	0,7757
	σ	0,0358	0,0209	0,0192	0,0172	0,0152	0,0160
85,0%	μ	0,5801	0,7464	0,7696	0,7656	0,7688	0,7705
	σ	0,0345	0,0244	0,0190	0,0205	0,0221	0,0195
90,0%	μ	0,5444	0,7295	0,7552	0,7570	0,7592	0,7581
	σ	0,0320	0,0301	0,0243	0,0224	0,0220	0,0224
95,0%	μ	0,5065	0,6799	0,7282	0,7422	0,7451	0,7438
	σ	0,0373	0,0414	0,0328	0,0247	0,0282	0,0256
99,0%	μ	0,4828	0,6061	0,6973	0,7063	0,7081	0,7059
	σ	0,0396	0,0549	0,0381	0,0320	0,0296	0,0296
99,5%	μ	0,4767	0,5821	0,7007	0,6916	0,6908	0,6851
	σ	0,0408	0,0546	0,0391	0,0290	0,0296	0,0343
99,9%	μ	0,4429	0,5683	0,6463	0,6598	0,6632	0,6611
	σ	0,0354	0,0636	0,0464	0,0387	0,0389	0,0356

Número de regiões							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	18,47	13,23	13,66	14,57	15,75	16,33
85,0%	μ	20,79	12,30	12,79	13,69	14,81	15,409
90,0%	μ	21,78	11,79	12,195	12,97	14,01	14,58
95,0%	μ	24,01	12,22	11,692	12,25	13,21	13,70
99,0%	μ	27,13	14,94	11,24	11,59	12,26	12,56
99,5%	μ	28,38	15,38	11,46	11,62	12,13	12,51
99,9%	μ	32,48	16,37	11,70	11,67	12,20	12,48

Tempo de processamento							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	216,10	93,82	72,90	71,55	71,37	71,77
85,0%	μ	173,05	74,79	60,68	61,33	61,29	62,29
90,0%	μ	117,79	61,75	50,11	51,47	52,02	51,60
95,0%	μ	58,72	51,79	42,53	42,41	41,51	42,01
99,0%	μ	20,06	38,82	37,11	34,67	35,50	33,67
99,5%	μ	19,87	28,97	37,57	30,42	32,05	30,39
99,9%	μ	20,88	21,70	33,01	26,77	28,64	28,11

B.4 Resultados obtidos para as medidas de ajuste usando o algoritmo SegSAR na segmentação da imagem em intensidade na polarização *hh*.

		Mval					
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,9062	0,9265	0,9216	0,9237	0,9223	0,9222
	σ	0,0142	0,0115	0,0129	0,0124	0,0150	0,0120
85,0%	μ	0,9050	0,9259	0,9203	0,9236	0,9215	0,9234
	σ	0,0143	0,0130	0,0143	0,0119	0,0129	0,0127
90,0%	μ	0,9055	0,9254	0,9209	0,9229	0,9234	0,9242
	σ	0,0145	0,0127	0,0144	0,0121	0,0135	0,0124
95,0%	μ	0,9064	0,9261	0,9243	0,9237	0,9240	0,9261
	σ	0,0151	0,0126	0,0139	0,0134	0,0142	0,0121
99,0%	μ	0,9055	0,9262	0,9257	0,9247	0,9267	0,9267
	σ	0,0150	0,0121	0,0129	0,0121	0,0130	0,0125
99,5%	μ	0,9063	0,9263	0,9263	0,9257	0,9260	0,9283
	σ	0,0150	0,0120	0,0125	0,0115	0,0128	0,0110
99,9%	μ	0,9062	0,9266	0,9279	0,9239	0,9276	0,9284
	σ	0,0150	0,0123	0,0146	0,0130	0,0135	0,0121

		Mdim					
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,4594	0,5379	0,4922	0,5280	0,5017	0,5230
	σ	0,0363	0,0363	0,0367	0,0314	0,0362	0,0322
85,0%	μ	0,4613	0,5378	0,4927	0,5303	0,5040	0,5224
	σ	0,0361	0,0326	0,0335	0,0335	0,0378	0,0323
90,0%	μ	0,4628	0,5367	0,4926	0,5315	0,5060	0,5280
	σ	0,0374	0,0323	0,0334	0,0323	0,0414	0,0345
95,0%	μ	0,4627	0,5350	0,4979	0,5310	0,5024	0,5277
	σ	0,0375	0,0333	0,0345	0,0346	0,0391	0,0319
99,0%	μ	0,4604	0,5360	0,4964	0,5287	0,5049	0,5266
	σ	0,0407	0,0354	0,0343	0,0345	0,0321	0,0369
99,5%	μ	0,4597	0,5358	0,5015	0,5298	0,5044	0,5274
	σ	0,0411	0,0351	0,0343	0,0340	0,0357	0,0321
99,9%	μ	0,4603	0,5362	0,4982	0,5338	0,5084	0,5312
	σ	0,0414	0,0346	0,0346	0,0348	0,0339	0,0302

B.4 - Continuação

Mpos							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,9550	0,9555	0,9543	0,9550	0,9540	0,9552
	σ	0,0084	0,0071	0,0059	0,0055	0,0068	0,0064
85,0%	μ	0,9564	0,9570	0,9541	0,9550	0,9552	0,9550
	σ	0,0075	0,0067	0,0063	0,0067	0,0066	0,0057
90,0%	μ	0,9563	0,9563	0,9549	0,9544	0,9550	0,9564
	σ	0,0079	0,0069	0,0061	0,0063	0,0080	0,0057
95,0%	μ	0,9557	0,9562	0,9551	0,9552	0,9544	0,9558
	σ	0,0093	0,0069	0,0067	0,0062	0,0064	0,0065
99,0%	μ	0,9556	0,9567	0,9553	0,9546	0,9558	0,9553
	σ	0,0093	0,0071	0,0059	0,0064	0,0064	0,0072
99,5%	μ	0,9556	0,9568	0,9549	0,9543	0,9543	0,9548
	σ	0,0094	0,0070	0,0064	0,0067	0,0064	0,0062
99,9%	μ	0,9555	0,9568	0,9557	0,9549	0,9558	0,9570
	σ	0,0094	0,0069	0,0063	0,0053	0,0071	0,0056

Mfor							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,2894	0,3460	0,3118	0,3367	0,3204	0,3334
	σ	0,0295	0,0312	0,0303	0,0270	0,0302	0,0258
85,0%	μ	0,2924	0,3480	0,3100	0,3410	0,3222	0,3337
	σ	0,0299	0,0299	0,0283	0,0277	0,0308	0,0269
90,0%	μ	0,2910	0,3454	0,3110	0,3379	0,3245	0,3394
	σ	0,0315	0,0295	0,0280	0,0261	0,0342	0,0276
95,0%	μ	0,2917	0,3445	0,3157	0,3403	0,3207	0,3390
	σ	0,0311	0,0299	0,0273	0,0258	0,0328	0,0242
99,0%	μ	0,2898	0,3453	0,3156	0,3387	0,3237	0,3349
	σ	0,0333	0,0308	0,0263	0,0248	0,0267	0,0277
99,5%	μ	0,2898	0,3455	0,3174	0,3388	0,3194	0,3369
	σ	0,0334	0,0303	0,0281	0,0258	0,0276	0,0260
99,9%	μ	0,2898	0,3463	0,3186	0,3403	0,3259	0,3418
	σ	0,0333	0,0298	0,0315	0,0286	0,0302	0,0245

B.4 - Conclusão

Mgeral							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,6525	0,6914	0,6700	0,6858	0,6746	0,6835
	σ	0,0179	0,0178	0,0180	0,0150	0,0176	0,0149
85,0%	μ	0,6538	0,6922	0,6693	0,6875	0,6757	0,6836
	σ	0,0184	0,0165	0,0164	0,0160	0,0186	0,0154
90,0%	μ	0,6539	0,6909	0,6698	0,6867	0,6772	0,6870
	σ	0,0191	0,0163	0,0164	0,0149	0,0211	0,0165
95,0%	μ	0,6541	0,6904	0,6733	0,6875	0,6754	0,6872
	σ	0,0192	0,0166	0,0165	0,0155	0,0196	0,0148
99,0%	μ	0,6528	0,6911	0,6733	0,6867	0,6778	0,6858
	σ	0,0207	0,0174	0,0158	0,0151	0,0158	0,0167
99,5%	μ	0,6529	0,6911	0,6751	0,6872	0,6760	0,6868
	σ	0,0208	0,0171	0,0162	0,0160	0,0167	0,0150
99,9%	μ	0,6529	0,6915	0,6751	0,6882	0,6794	0,6896
	σ	0,0210	0,0168	0,0178	0,0162	0,0178	0,0138

Número de regiões							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	756,10	598,50	627,70	601,90	616,40	595,90
85,0%	μ	758,10	599,50	616,00	598,60	609,30	591,80
90,0%	μ	758,50	598,80	602,70	596,00	599,40	585,30
95,0%	μ	758,00	599,00	585,30	592,20	586,40	574,80
99,0%	μ	758,90	599,20	566,20	583,30	569,80	565,30
99,5%	μ	758,80	599,30	563,30	581,50	563,30	560,50
99,9%	μ	758,30	599,60	555,80	574,00	560,40	556,00

Tempo de processamento							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	185,17	45,57	84,41	53,83	71,58	59,39
85,0%	μ	181,44	44,55	94,86	56,89	84,22	61,21
90,0%	μ	180,73	44,51	90,84	55,57	79,62	59,95
95,0%	μ	182,36	44,81	87,61	55,15	77,50	58,94
99,0%	μ	181,53	44,98	82,38	54,39	73,02	56,31
99,5%	μ	183,19	44,94	80,51	53,52	72,10	55,30
99,9%	μ	185,17	45,57	84,41	53,83	71,58	59,39

B.5 Resultados obtidos para as medidas de ajuste usando o algoritmo SegSAR na segmentação da imagem em intensidade na polarização *hv*.

		Mval					
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,8737	0,8951	0,8851	0,8999	0,8886	0,8966
	σ	0,0146	0,0156	0,0141	0,0158	0,0127	0,0145
85,0%	μ	0,8720	0,8943	0,8831	0,8979	0,8921	0,8964
	σ	0,0123	0,0146	0,0146	0,0132	0,0136	0,0135
90,0%	μ	0,8730	0,8966	0,8837	0,8974	0,8907	0,8953
	σ	0,0124	0,0147	0,0137	0,0148	0,0135	0,0131
95,0%	μ	0,8739	0,8952	0,8833	0,8978	0,8905	0,8951
	σ	0,0122	0,0151	0,0145	0,0150	0,0136	0,0139
99,0%	μ	0,8724	0,8946	0,8820	0,8983	0,8899	0,8939
	σ	0,0139	0,0137	0,0140	0,0129	0,0145	0,0136
99,5%	μ	0,8728	0,8947	0,8843	0,8968	0,8924	0,8959
	σ	0,0130	0,0140	0,0122	0,0150	0,0149	0,0141
99,9%	μ	0,8723	0,8965	0,8888	0,8986	0,8958	0,8992
	σ	0,0122	0,0158	0,0146	0,0153	0,0137	0,0146

		Mdim					
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,3999	0,4908	0,4424	0,5235	0,4627	0,4951
	σ	0,0291	0,0342	0,0312	0,0356	0,0343	0,0383
85,0%	μ	0,3955	0,4908	0,4460	0,5222	0,4689	0,5012
	σ	0,0286	0,0393	0,0394	0,0346	0,0329	0,0365
90,0%	μ	0,4037	0,4977	0,4471	0,5278	0,4698	0,5038
	σ	0,0317	0,0389	0,0361	0,0342	0,0364	0,0425
95,0%	μ	0,4022	0,4943	0,4468	0,5303	0,4696	0,5022
	σ	0,0286	0,0399	0,0344	0,0375	0,0359	0,0392
99,0%	μ	0,4022	0,4943	0,4542	0,5320	0,4787	0,5017
	σ	0,0286	0,0368	0,0321	0,0433	0,0346	0,0401
99,5%	μ	0,4016	0,4946	0,4602	0,5291	0,4921	0,5107
	σ	0,0296	0,0388	0,0324	0,0376	0,0391	0,0385
99,9%	μ	0,4018	0,4979	0,4770	0,5332	0,5118	0,5200
	σ	0,0299	0,0366	0,0311	0,0375	0,0346	0,0398

B.5 - Continuação

Mpos							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,9458	0,9511	0,9468	0,9508	0,9455	0,9493
	σ	0,0066	0,0075	0,0073	0,0075	0,0069	0,0080
85,0%	μ	0,9440	0,9499	0,9470	0,9490	0,9455	0,9490
	σ	0,0079	0,0081	0,0085	0,0081	0,0070	0,0079
90,0%	μ	0,9455	0,9516	0,9463	0,9501	0,9453	0,9486
	σ	0,0079	0,0078	0,0080	0,0083	0,0081	0,0087
95,0%	μ	0,9457	0,9505	0,9463	0,9507	0,9462	0,9485
	σ	0,0076	0,0087	0,0079	0,0083	0,0080	0,0087
99,0%	μ	0,9453	0,9507	0,9468	0,9506	0,9464	0,9480
	σ	0,0075	0,0076	0,0076	0,0093	0,0081	0,0092
99,5%	μ	0,9454	0,9511	0,9471	0,9492	0,9473	0,9497
	σ	0,0074	0,0081	0,0084	0,0075	0,0087	0,0080
99,9%	μ	0,9453	0,9507	0,9473	0,9495	0,9491	0,9499
	σ	0,0073	0,0088	0,0081	0,0080	0,0075	0,0080

Mfor							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,2510	0,3177	0,2768	0,3410	0,2895	0,3221
	σ	0,0208	0,0322	0,0262	0,0327	0,0241	0,0327
85,0%	μ	0,2464	0,3159	0,2785	0,3386	0,2971	0,3257
	σ	0,0197	0,0340	0,0299	0,0301	0,0257	0,0296
90,0%	μ	0,2525	0,3238	0,2799	0,3430	0,2957	0,3270
	σ	0,0219	0,0340	0,0303	0,0281	0,0279	0,0337
95,0%	μ	0,2520	0,3203	0,2807	0,3442	0,2978	0,3253
	σ	0,0203	0,0353	0,0273	0,0333	0,0288	0,0325
99,0%	μ	0,2517	0,3201	0,2857	0,3456	0,3048	0,3261
	σ	0,0211	0,0320	0,0265	0,0353	0,0319	0,0329
99,5%	μ	0,2515	0,3201	0,2929	0,3421	0,3178	0,3310
	σ	0,0214	0,0330	0,0271	0,0324	0,0330	0,0313
99,9%	μ	0,2515	0,3220	0,3070	0,3469	0,3359	0,3378
	σ	0,0215	0,0330	0,0246	0,0339	0,0314	0,0351

B.5 - Conclusão

Mgeral							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,6176	0,6637	0,6378	0,6788	0,6465	0,6658
	σ	0,0145	0,0196	0,0166	0,0207	0,0157	0,0211
85,0%	μ	0,6145	0,6627	0,6386	0,6769	0,6509	0,6681
	σ	0,0138	0,0211	0,0199	0,0188	0,0165	0,0196
90,0%	μ	0,6187	0,6674	0,6392	0,6796	0,6504	0,6687
	σ	0,0151	0,0212	0,0191	0,0183	0,0183	0,0224
95,0%	μ	0,6184	0,6651	0,6393	0,6807	0,6510	0,6678
	σ	0,0135	0,0220	0,0176	0,0208	0,0189	0,0212
99,0%	μ	0,6179	0,6649	0,6422	0,6816	0,6550	0,6674
	σ	0,0137	0,0199	0,0169	0,0230	0,0196	0,0216
99,5%	μ	0,6178	0,6651	0,6461	0,6793	0,6624	0,6718
	σ	0,0140	0,0209	0,0170	0,0209	0,0210	0,0206
99,9%	μ	0,6177	0,6668	0,6550	0,6821	0,6732	0,6767
	σ	0,0140	0,0210	0,0162	0,0214	0,0193	0,0219

Número de regiões							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	899,62	665,93	674,61	496,72	638,45	542,96
85,0%	μ	882,26	652,21	654,53	477,68	617,31	526,68
90,0%	μ	871,38	648,16	644,75	469,34	605,98	514,62
95,0%	μ	872,43	645,47	643,32	465,26	604,82	512,47
99,0%	μ	871,94	644,31	637,02	460,98	590,86	506,13
99,5%	μ	871,52	644,91	633,48	458,00	582,17	505,82
99,9%	μ	871,72	644,82	612,63	453,53	555,50	497,75

Tempo de processamento							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	122,97	30,64	52,86	29,89	46,10	33,42
85,0%	μ	120,69	30,49	52,43	29,73	45,54	33,27
90,0%	μ	120,28	30,44	51,96	29,57	45,32	33,18
95,0%	μ	121,86	31,15	52,38	29,84	45,68	33,38
99,0%	μ	122,04	31,03	51,17	29,43	44,35	32,99
99,5%	μ	122,38	30,96	50,36	29,22	43,65	32,43
99,9%	μ	121,52	30,72	47,64	28,44	40,81	31,39

B.6 Resultados obtidos para as medidas de ajuste usando o algoritmo SegSAR na segmentação da imagem em intensidade na polarização vv.

		Mval					
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,8914	0,9222	0,9114	0,9237	0,9154	0,9201
	σ	0,0127	0,0105	0,0123	0,0118	0,0116	0,0119
85,0%	μ	0,8918	0,9216	0,9124	0,9216	0,9142	0,9189
	σ	0,0134	0,0105	0,0132	0,0121	0,0117	0,0114
90,0%	μ	0,8911	0,9218	0,9112	0,9218	0,9146	0,9191
	σ	0,0140	0,0104	0,0121	0,0107	0,0122	0,0101
95,0%	μ	0,8918	0,9223	0,9106	0,9215	0,9158	0,9184
	σ	0,0126	0,0105	0,0118	0,0114	0,0115	0,0115
99,0%	μ	0,8917	0,9220	0,9095	0,9207	0,9152	0,9173
	σ	0,0133	0,0107	0,0118	0,0120	0,0122	0,0123
99,5%	μ	0,8920	0,9220	0,9091	0,9190	0,9147	0,9179
	σ	0,0132	0,0106	0,0134	0,0126	0,0112	0,0119
99,9%	μ	0,8921	0,9216	0,9094	0,9218	0,9142	0,9184
	σ	0,0130	0,0105	0,0122	0,0114	0,0127	0,0126

		Mdim					
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,4584	0,5078	0,4938	0,5216	0,5091	0,5090
	σ	0,0299	0,0423	0,0328	0,0403	0,0325	0,0421
85,0%	μ	0,4557	0,5107	0,4900	0,5231	0,5075	0,5092
	σ	0,0293	0,0412	0,0317	0,0463	0,0367	0,0390
90,0%	μ	0,4560	0,5098	0,4963	0,5226	0,5058	0,5057
	σ	0,0302	0,0425	0,0326	0,0452	0,0372	0,0433
95,0%	μ	0,4570	0,5088	0,4896	0,5213	0,5068	0,5043
	σ	0,0298	0,0442	0,0303	0,0448	0,0359	0,0439
99,0%	μ	0,4563	0,5071	0,4945	0,5157	0,5070	0,5074
	σ	0,0300	0,0440	0,0336	0,0456	0,0319	0,0412
99,5%	μ	0,4559	0,5071	0,4930	0,5176	0,5132	0,5064
	σ	0,0304	0,0440	0,0352	0,0462	0,0312	0,0413
99,9%	μ	0,4549	0,5070	0,4884	0,5316	0,5057	0,5099
	σ	0,0304	0,0435	0,0301	0,0422	0,0339	0,0369

B.6 - Continuação

Mpos							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,9621	0,9544	0,9610	0,9565	0,9590	0,9575
	σ	0,0049	0,0088	0,0055	0,0074	0,0052	0,0071
85,0%	μ	0,9621	0,9549	0,9611	0,9566	0,9587	0,9579
	σ	0,0051	0,0083	0,0051	0,0077	0,0060	0,0071
90,0%	μ	0,9621	0,9548	0,9608	0,9561	0,9584	0,9566
	σ	0,0053	0,0084	0,0048	0,0086	0,0061	0,0089
95,0%	μ	0,9617	0,9543	0,9603	0,9563	0,9584	0,9567
	σ	0,0050	0,0086	0,0064	0,0076	0,0066	0,0082
99,0%	μ	0,9620	0,9540	0,9609	0,9562	0,9578	0,9576
	σ	0,0052	0,0087	0,0058	0,0081	0,0064	0,0071
99,5%	μ	0,9621	0,9540	0,9604	0,9579	0,9591	0,9578
	σ	0,0054	0,0087	0,0057	0,0071	0,0061	0,0067
99,9%	μ	0,9621	0,9541	0,9615	0,9587	0,9584	0,9577
	σ	0,0053	0,0087	0,0050	0,0068	0,0055	0,0069

Mfor							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,2153	0,2535	0,2381	0,2593	0,2467	0,2525
	σ	0,0163	0,0226	0,0160	0,0236	0,0195	0,0226
85,0%	μ	0,2157	0,2540	0,2375	0,2598	0,2477	0,2537
	σ	0,0171	0,0233	0,0176	0,0260	0,0202	0,0218
90,0%	μ	0,2156	0,2527	0,2378	0,2579	0,2462	0,2519
	σ	0,0166	0,0242	0,0184	0,0271	0,0188	0,0234
95,0%	μ	0,2159	0,2520	0,2361	0,2574	0,2469	0,2512
	σ	0,0164	0,0248	0,0175	0,0260	0,0194	0,0222
99,0%	μ	0,2156	0,2507	0,2377	0,2563	0,2462	0,2519
	σ	0,0164	0,0244	0,0179	0,0254	0,0193	0,0232
99,5%	μ	0,2154	0,2507	0,2375	0,2586	0,2489	0,2527
	σ	0,0165	0,0244	0,0192	0,0250	0,0196	0,0228
99,9%	μ	0,2155	0,2511	0,2385	0,2653	0,2444	0,2543
	σ	0,0166	0,0240	0,0189	0,0231	0,0189	0,0206

B.6 - Conclusão

Mgeral							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,6318	0,6595	0,6510	0,6653	0,6575	0,6598
	σ	0,0111	0,0162	0,0111	0,0167	0,0124	0,0167
85,0%	μ	0,6313	0,6603	0,6502	0,6653	0,6571	0,6599
	σ	0,0110	0,0162	0,0117	0,0192	0,0142	0,0153
90,0%	μ	0,6312	0,6598	0,6515	0,6646	0,6563	0,6583
	σ	0,0107	0,0166	0,0121	0,0186	0,0136	0,0170
95,0%	μ	0,6316	0,6594	0,6492	0,6641	0,6570	0,6577
	σ	0,0110	0,0172	0,0114	0,0181	0,0125	0,0173
99,0%	μ	0,6314	0,6585	0,6507	0,6622	0,6565	0,6585
	σ	0,0107	0,0170	0,0109	0,0187	0,0122	0,0165
99,5%	μ	0,6314	0,6584	0,6500	0,6633	0,6590	0,6587
	σ	0,0109	0,0170	0,0124	0,0182	0,0120	0,0164
99,9%	μ	0,6312	0,6585	0,6494	0,6694	0,6557	0,6601
	σ	0,0109	0,0167	0,0112	0,0164	0,0123	0,0143

Número de regiões							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	1169,86	797,11	915,23	821,58	879,63	818,86
85,0%	μ	1169,74	797,31	909,83	818,22	876,47	814,74
90,0%	μ	1169,14	796,31	903,46	814,41	870,49	812,38
95,0%	μ	1168,62	796,69	896,68	811,51	862,32	804,78
99,0%	μ	1169,22	796,45	890,52	805,86	858,41	801,87
99,5%	μ	1169,12	796,48	889,39	802,67	858,19	799,27
99,9%	μ	1169,29	796,37	890,46	791,23	855,33	791,14

Tempo de processamento							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	182,33	37,40	88,69	49,17	73,39	53,59
85,0%	μ	182,60	37,31	87,08	48,88	72,14	52,78
90,0%	μ	181,82	37,31	85,57	48,33	71,15	52,25
95,0%	μ	173,13	35,72	79,52	45,74	66,51	49,18
99,0%	μ	172,79	35,67	77,89	45,31	65,24	48,34
99,5%	μ	172,97	35,72	77,64	44,85	64,88	48,02
99,9%	μ	177,95	36,70	79,90	45,23	66,69	49,03

B.7 Resultados obtidos para as medidas de ajuste usando o algoritmo PolSeg na segmentação do vetor de espalhamento complexo com as polarizações *hh-hv-vv*.

Mval							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,8806	0,8847	0,9844	0,9872	0,9878	0,9887
	σ	0,0598	0,0700	0,0056	0,0045	0,0037	0,0037
85,0%	μ	0,8885	0,8805	0,9841	0,9866	0,9874	0,9884
	σ	0,0604	0,0677	0,0059	0,0050	0,0038	0,0036
90,0%	μ	0,8990	0,8806	0,9832	0,9862	0,9869	0,9878
	σ	0,0588	0,0709	0,0066	0,0043	0,0035	0,0034
95,0%	μ	0,9172	0,8868	0,9806	0,9852	0,9862	0,9868
	σ	0,0501	0,0721	0,0062	0,0045	0,0035	0,0038
99,0%	μ	0,9201	0,8782	0,9759	0,9849	0,9851	0,9857
	σ	0,0479	0,0720	0,0078	0,0037	0,0040	0,0034
99,5%	μ	0,9208	0,8821	0,9731	0,9850	0,9849	0,9850
	σ	0,0487	0,0707	0,0083	0,0038	0,0038	0,0041
99,9%	μ	0,9059	0,8742	0,9691	0,9825	0,9815	0,9820
	σ	0,0554	0,0683	0,0084	0,0049	0,0053	0,0050

Mdim							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,5781	0,6078	0,9144	0,9460	0,9501	0,9529
	σ	0,1106	0,1653	0,0279	0,0176	0,0148	0,0164
85,0%	μ	0,6057	0,6073	0,9178	0,9462	0,9502	0,9536
	σ	0,1125	0,1505	0,0276	0,0185	0,0149	0,0161
90,0%	μ	0,6304	0,6112	0,9145	0,9454	0,9511	0,9533
	σ	0,1172	0,1641	0,0293	0,0170	0,0136	0,0142
95,0%	μ	0,6837	0,6435	0,9029	0,9422	0,9476	0,9500
	σ	0,0961	0,1676	0,0281	0,0174	0,0142	0,0151
99,0%	μ	0,7238	0,6484	0,8848	0,9285	0,9291	0,9274
	σ	0,0966	0,1659	0,0317	0,0135	0,0128	0,0161
99,5%	μ	0,7342	0,6658	0,8758	0,9390	0,9382	0,9366
	σ	0,0995	0,1678	0,0341	0,0185	0,0205	0,0217
99,9%	μ	0,7149	0,6584	0,8614	0,9213	0,9172	0,9183
	σ	0,1026	0,1532	0,0329	0,0253	0,0267	0,0265

B.7 - Continuação

Mpos							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,9428	0,9390	0,9843	0,9887	0,9892	0,9896
	σ	0,0280	0,0403	0,0044	0,0030	0,0027	0,0033
85,0%	μ	0,9470	0,9410	0,9848	0,9883	0,9893	0,9900
	σ	0,0268	0,0346	0,0042	0,0037	0,0029	0,0030
90,0%	μ	0,9497	0,9377	0,9847	0,9882	0,9896	0,9898
	σ	0,0302	0,0392	0,0048	0,0039	0,0029	0,0029
95,0%	μ	0,9586	0,9442	0,9830	0,9878	0,9892	0,9896
	σ	0,0180	0,0362	0,0045	0,0042	0,0034	0,0035
99,0%	μ	0,9612	0,9415	0,9812	0,9880	0,9879	0,9876
	σ	0,0184	0,0374	0,0058	0,0024	0,0027	0,0030
99,5%	μ	0,9616	0,9448	0,9791	0,9889	0,9888	0,9883
	σ	0,0200	0,0373	0,0067	0,0040	0,0039	0,0044
99,9%	μ	0,9581	0,9447	0,9775	0,9853	0,9848	0,9845
	σ	0,0203	0,0327	0,0065	0,0060	0,0066	0,0070

Mfor							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,3917	0,4416	0,8244	0,8863	0,8919	0,8935
	σ	0,0911	0,1615	0,0391	0,0178	0,0150	0,0156
85,0%	μ	0,4139	0,4354	0,8301	0,8880	0,8936	0,8962
	σ	0,0961	0,1489	0,0391	0,0192	0,0149	0,0154
90,0%	μ	0,4413	0,4483	0,8262	0,8896	0,8959	0,8980
	σ	0,0979	0,1665	0,0408	0,0178	0,0140	0,0132
95,0%	μ	0,4948	0,4780	0,8135	0,8869	0,8937	0,8954
	σ	0,0909	0,1767	0,0377	0,0190	0,0154	0,0154
99,0%	μ	0,5384	0,4771	0,7927	0,8698	0,8700	0,8674
	σ	0,0955	0,1737	0,0424	0,0149	0,0158	0,0185
99,5%	μ	0,5504	0,4935	0,7809	0,8834	0,8834	0,8808
	σ	0,1023	0,1760	0,0430	0,0207	0,0229	0,0240
99,9%	μ	0,5224	0,4803	0,7613	0,8606	0,8572	0,8581
	σ	0,1062	0,1548	0,0414	0,0293	0,0319	0,0310

B.7 - Conclusão

Mgeral							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,6983	0,7183	0,9269	0,9520	0,9547	0,9562
	σ	0,0703	0,1068	0,0183	0,0102	0,0086	0,0092
85,0%	μ	0,7138	0,7161	0,9292	0,9522	0,9551	0,9570
	σ	0,0720	0,0976	0,0185	0,0110	0,0086	0,0091
90,0%	μ	0,7301	0,7195	0,9271	0,9524	0,9559	0,9572
	σ	0,0743	0,1073	0,0196	0,0103	0,0080	0,0080
95,0%	μ	0,7636	0,7381	0,9200	0,9505	0,9542	0,9554
	σ	0,0619	0,1108	0,0184	0,0106	0,0086	0,0089
99,0%	μ	0,7859	0,7363	0,9086	0,9428	0,9430	0,9420
	σ	0,0627	0,1098	0,0209	0,0079	0,0080	0,0095
99,5%	μ	0,7918	0,7465	0,9022	0,9491	0,9488	0,9477
	σ	0,0659	0,1107	0,0218	0,0110	0,0122	0,0129
99,9%	μ	0,7753	0,7394	0,8923	0,9374	0,9352	0,9357
	σ	0,0689	0,0998	0,0210	0,0156	0,0166	0,0167

Número de regiões							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	148,60	87,85	52,48	39,66	39,12	39,87
85,0%	μ	140,05	81,87	47,61	36,36	36,60	36,51
90,0%	μ	130,02	70,92	44,86	33,77	33,73	33,65
95,0%	μ	117,23	66,56	40,99	31,64	31,45	31,46
99,0%	μ	92,91	53,83	42,68	48,28	49,88	49,58
99,5%	μ	84,58	51,80	38,14	31,52	31,88	32,10
99,9%	μ	72,97	46,92	34,49	31,33	30,93	31,33

Tempo de processamento							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	1195,96	1338,04	331,68	363,89	384,23	369,38
85,0%	μ	997,24	1262,68	330,49	360,10	371,34	360,60
90,0%	μ	934,60	1233,41	341,12	354,17	352,48	357,81
95,0%	μ	607,96	1048,66	351,30	354,93	381,67	354,75
99,0%	μ	605,32	1075,39	323,62	228,64	225,03	222,09
99,5%	μ	637,09	1018,73	344,17	339,12	341,13	336,54
99,9%	μ	683,27	1048,27	401,85	395,07	391,93	396,97

B.8 Resultados obtidos para as medidas de ajuste usando o algoritmo SegSAR na segmentação das imagens em intensidade nas polarizações *hh-hv-vv*.

Mval							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,9423	0,9312	0,9459	0,9345	0,9435	0,9339
	σ	0,0098	0,0130	0,0095	0,0127	0,0109	0,0127
85,0%	μ	0,9418	0,9302	0,9447	0,9324	0,9417	0,9332
	σ	0,0088	0,0133	0,0106	0,0127	0,0121	0,0133
90,0%	μ	0,9396	0,9307	0,9449	0,9318	0,9436	0,9327
	σ	0,0104	0,0118	0,0112	0,0130	0,0105	0,0143
95,0%	μ	0,9415	0,9315	0,9459	0,9337	0,9431	0,9344
	σ	0,0096	0,0120	0,0102	0,0123	0,0104	0,0123
99,0%	μ	0,9413	0,9311	0,9463	0,9327	0,9437	0,9321
	σ	0,0100	0,0125	0,0106	0,0128	0,0115	0,0114
99,5%	μ	0,9423	0,9306	0,9463	0,9335	0,9424	0,9338
	σ	0,0092	0,0127	0,0099	0,0125	0,0109	0,0116
99,9%	μ	0,9415	0,9304	0,9468	0,9335	0,9426	0,9340
	σ	0,0090	0,0127	0,0094	0,0130	0,0104	0,0118

Mdim							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,3166	0,4499	0,3791	0,4527	0,4065	0,4525
	σ	0,0211	0,0363	0,0229	0,0343	0,0246	0,0364
85,0%	μ	0,3270	0,4486	0,3929	0,4494	0,4116	0,4539
	σ	0,0184	0,0339	0,0237	0,0371	0,0271	0,0343
90,0%	μ	0,3307	0,4515	0,3940	0,4580	0,4170	0,4512
	σ	0,0200	0,0358	0,0224	0,0373	0,0245	0,0375
95,0%	μ	0,3292	0,4509	0,3920	0,4595	0,4197	0,4538
	σ	0,0229	0,0336	0,0245	0,0334	0,0232	0,0344
99,0%	μ	0,3290	0,4500	0,3906	0,4562	0,4155	0,4549
	σ	0,0225	0,0367	0,0235	0,0357	0,0248	0,0391
99,5%	μ	0,3268	0,4485	0,3902	0,4594	0,4175	0,4516
	σ	0,0197	0,0373	0,0236	0,0353	0,0266	0,0358
99,9%	μ	0,3275	0,4477	0,3924	0,4521	0,4153	0,4490
	σ	0,0195	0,0375	0,0226	0,0349	0,0287	0,0387

B.8 - Continuação

Mpos							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,9673	0,9616	0,9642	0,9606	0,9628	0,9622
	σ	0,0042	0,0074	0,0043	0,0078	0,0046	0,0071
85,0%	μ	0,9673	0,9611	0,9637	0,9588	0,9622	0,9624
	σ	0,0046	0,0075	0,0045	0,0079	0,0051	0,0070
90,0%	μ	0,9668	0,9611	0,9642	0,9586	0,9627	0,9607
	σ	0,0042	0,0076	0,0043	0,0074	0,0047	0,0075
95,0%	μ	0,9671	0,9611	0,9637	0,9596	0,9628	0,9612
	σ	0,0038	0,0077	0,0046	0,0074	0,0044	0,0069
99,0%	μ	0,9672	0,9610	0,9633	0,9587	0,9621	0,9610
	σ	0,0041	0,0077	0,0043	0,0074	0,0051	0,0070
99,5%	μ	0,9664	0,9609	0,9638	0,9596	0,9624	0,9607
	σ	0,0042	0,0079	0,0040	0,0074	0,0045	0,0069
99,9%	μ	0,9670	0,9607	0,9640	0,9594	0,9620	0,9601
	σ	0,0041	0,0078	0,0043	0,0074	0,0046	0,0075

Mfor							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,2045	0,2998	0,2413	0,2987	0,2614	0,2945
	σ	0,0135	0,0299	0,0150	0,0283	0,0183	0,0284
85,0%	μ	0,2120	0,2999	0,2480	0,2959	0,2631	0,2980
	σ	0,0138	0,0313	0,0159	0,0315	0,0196	0,0301
90,0%	μ	0,2126	0,3021	0,2512	0,3005	0,2682	0,2943
	σ	0,0131	0,0308	0,0173	0,0307	0,0191	0,0302
95,0%	μ	0,2139	0,3015	0,2504	0,3036	0,2695	0,2966
	σ	0,0131	0,0290	0,0176	0,0301	0,0190	0,0289
99,0%	μ	0,2121	0,3011	0,2476	0,2986	0,2663	0,2957
	σ	0,0137	0,0309	0,0162	0,0305	0,0194	0,0295
99,5%	μ	0,2124	0,2999	0,2488	0,3025	0,2676	0,2950
	σ	0,0138	0,0314	0,0162	0,0300	0,0195	0,0298
99,9%	μ	0,2128	0,2991	0,2492	0,2975	0,2646	0,2918
	σ	0,0128	0,0312	0,0142	0,0290	0,0202	0,0302

B.8 - Conclusão

Mgeral							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,6077	0,6606	0,6326	0,6616	0,6436	0,6608
	σ	0,0075	0,0196	0,0091	0,0181	0,0102	0,0179
85,0%	μ	0,6120	0,6600	0,6373	0,6591	0,6447	0,6619
	σ	0,0074	0,0197	0,0094	0,0198	0,0117	0,0181
90,0%	μ	0,6124	0,6613	0,6386	0,6622	0,6479	0,6597
	σ	0,0070	0,0195	0,0097	0,0196	0,0105	0,0191
95,0%	μ	0,6129	0,6613	0,6380	0,6641	0,6488	0,6615
	σ	0,0085	0,0189	0,0101	0,0183	0,0106	0,0180
99,0%	μ	0,6124	0,6608	0,6370	0,6615	0,6469	0,6609
	σ	0,0078	0,0202	0,0092	0,0191	0,0112	0,0188
99,5%	μ	0,6120	0,6600	0,6373	0,6637	0,6475	0,6603
	σ	0,0076	0,0206	0,0091	0,0187	0,0116	0,0183
99,9%	μ	0,6122	0,6595	0,6381	0,6606	0,6461	0,6587
	σ	0,0075	0,0206	0,0085	0,0187	0,0120	0,0191

Número de regiões							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	1524,14	1106,64	1233,88	1116,04	1199,74	1123,01
85,0%	μ	1501,48	1084,23	1197,19	1091,69	1171,09	1094,74
90,0%	μ	1497,31	1080,61	1177,77	1083,77	1150,97	1086,12
95,0%	μ	1499,43	1081,49	1163,02	1081,07	1137,35	1078,40
99,0%	μ	1496,62	1081,13	1153,28	1076,05	1131,02	1071,55
99,5%	μ	1496,48	1080,39	1152,26	1076,09	1126,91	1069,53
99,9%	μ	1496,32	1080,84	1149,13	1071,51	1125,73	1066,18

Tempo de processamento							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	438,45	52,25	232,70	77,26	176,30	98,59
85,0%	μ	425,88	51,74	218,78	75,77	166,69	94,82
90,0%	μ	422,16	51,53	206,19	74,19	158,58	92,01
95,0%	μ	437,19	53,74	214,58	73,36	150,39	89,09
99,0%	μ	356,38	52,49	173,28	71,75	143,06	85,85
99,5%	μ	445,35	55,10	190,11	71,55	141,40	85,17
99,9%	μ	414,12	51,20	177,73	70,86	140,13	84,36

B.9 Resultados obtidos para as medidas de ajuste usando o algoritmo PolSeg na segmentação do vetor de espalhamento complexo com as polarizações *hh-hv*.

Mval							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,8553	0,9051	0,9733	0,9742	0,9743	0,9745
	σ	0,0660	0,0604	0,0065	0,0058	0,0055	0,0059
85,0%	μ	0,8667	0,9000	0,9730	0,9732	0,9733	0,9737
	σ	0,0666	0,0666	0,0059	0,0063	0,0065	0,0061
90,0%	μ	0,8820	0,8997	0,9718	0,9723	0,9724	0,9730
	σ	0,0655	0,0596	0,0066	0,0067	0,0068	0,0068
95,0%	μ	0,8975	0,9035	0,9684	0,9707	0,9718	0,9723
	σ	0,0570	0,0663	0,0076	0,0068	0,0068	0,0064
99,0%	μ	0,9103	0,8936	0,9633	0,9709	0,9716	0,9726
	σ	0,0559	0,0702	0,0090	0,0071	0,0063	0,0053
99,5%	μ	0,9117	0,8767	0,9619	0,9682	0,9682	0,9694
	σ	0,0533	0,0763	0,0087	0,0077	0,0066	0,0068
99,9%	μ	0,8933	0,8657	0,9562	0,9645	0,9645	0,9652
	σ	0,0675	0,0736	0,0096	0,0076	0,0070	0,0070

Mdim							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,5272	0,6528	0,9111	0,9374	0,9432	0,9443
	σ	0,1165	0,1372	0,0247	0,0187	0,0201	0,0210
85,0%	μ	0,5576	0,6541	0,9139	0,9407	0,9455	0,9474
	σ	0,1210	0,1516	0,0234	0,0187	0,0189	0,0202
90,0%	μ	0,5944	0,6746	0,9119	0,9412	0,9462	0,9471
	σ	0,1247	0,1464	0,0268	0,0203	0,0194	0,0207
95,0%	μ	0,6635	0,7091	0,9014	0,9401	0,9451	0,9470
	σ	0,1155	0,1520	0,0309	0,0183	0,0213	0,0208
99,0%	μ	0,7169	0,6879	0,8795	0,9265	0,9283	0,9315
	σ	0,1251	0,1688	0,0341	0,0155	0,0175	0,0180
99,5%	μ	0,7259	0,6673	0,8749	0,9263	0,9285	0,9310
	σ	0,1189	0,1681	0,0345	0,0235	0,0211	0,0225
99,9%	μ	0,7028	0,6555	0,8593	0,8995	0,8985	0,9029
	σ	0,1438	0,1636	0,0351	0,0285	0,0198	0,0225

B.9 - Continuação

Mpos							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,8453	0,9023	0,9718	0,9781	0,9800	0,9801
	σ	0,0866	0,0670	0,0082	0,0069	0,0071	0,0070
85,0%	μ	0,8595	0,8991	0,9711	0,9781	0,9798	0,9802
	σ	0,0810	0,0740	0,0083	0,0071	0,0068	0,0072
90,0%	μ	0,8760	0,9000	0,9698	0,9778	0,9795	0,9796
	σ	0,0773	0,0739	0,0094	0,0079	0,0073	0,0078
95,0%	μ	0,8990	0,9071	0,9673	0,9778	0,9780	0,9791
	σ	0,0695	0,0757	0,0093	0,0068	0,0091	0,0086
99,0%	μ	0,9136	0,8953	0,9607	0,9763	0,9772	0,9778
	σ	0,0673	0,0748	0,0128	0,0064	0,0065	0,0064
99,5%	μ	0,9167	0,8832	0,9591	0,9727	0,9743	0,9747
	σ	0,0621	0,0876	0,0116	0,0097	0,0091	0,0093
99,9%	μ	0,9022	0,8801	0,9518	0,9628	0,9621	0,9644
	σ	0,0830	0,0847	0,0145	0,0126	0,0117	0,0113

Mfor							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,3373	0,4783	0,8062	0,8613	0,8680	0,8683
	σ	0,1002	0,1405	0,0344	0,0195	0,0201	0,0221
85,0%	μ	0,3659	0,4816	0,8114	0,8688	0,8741	0,8762
	σ	0,1046	0,1568	0,0326	0,0195	0,0186	0,0201
90,0%	μ	0,4071	0,5044	0,8100	0,8728	0,8781	0,8794
	σ	0,1103	0,1506	0,0354	0,0202	0,0190	0,0202
95,0%	μ	0,4695	0,5380	0,7984	0,8757	0,8790	0,8820
	σ	0,1050	0,1668	0,0396	0,0176	0,0214	0,0203
99,0%	μ	0,5277	0,5220	0,7717	0,8578	0,8586	0,8616
	σ	0,1225	0,1862	0,0447	0,0173	0,0184	0,0186
99,5%	μ	0,5410	0,4940	0,7694	0,8614	0,8635	0,8666
	σ	0,1131	0,1800	0,0432	0,0240	0,0209	0,0222
99,9%	μ	0,5210	0,4749	0,7531	0,8276	0,8292	0,8345
	σ	0,1343	0,1626	0,0416	0,0332	0,0229	0,0266

B.9 - Conclusão

Mgeral							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,6413	0,7346	0,9156	0,9377	0,9414	0,9418
	σ	0,0887	0,0981	0,0171	0,0115	0,0120	0,0127
85,0%	μ	0,6624	0,7337	0,9174	0,9402	0,9432	0,9443
	σ	0,0900	0,1089	0,0159	0,0116	0,0116	0,0122
90,0%	μ	0,6899	0,7447	0,9159	0,9410	0,9440	0,9448
	σ	0,0920	0,1044	0,0179	0,0125	0,0118	0,0128
95,0%	μ	0,7324	0,7644	0,9089	0,9411	0,9435	0,9451
	σ	0,0839	0,1119	0,0202	0,0111	0,0132	0,0128
99,0%	μ	0,7671	0,7497	0,8938	0,9328	0,9339	0,9359
	σ	0,0900	0,1219	0,0233	0,0097	0,0106	0,0106
99,5%	μ	0,7738	0,7303	0,8913	0,9321	0,9336	0,9354
	σ	0,0840	0,1247	0,0225	0,0144	0,0129	0,0138
99,9%	μ	0,7548	0,7190	0,8801	0,9136	0,9136	0,9168
	σ	0,1047	0,1178	0,0229	0,0185	0,0133	0,0148

Número de regiões							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	606,82	368,99	152,13	174,82	179,10	177,25
85,0%	μ	620,31	364,92	152,69	177,65	167,93	168,18
90,0%	μ	465,61	368,72	148,50	172,43	164,32	168,98
95,0%	μ	355,37	309,73	148,94	162,39	165,81	170,19
99,0%	μ	303,81	377,92	146,01	119,19	107,89	109,03
99,5%	μ	249,91	436,07	160,26	164,61	160,37	155,65
99,9%	μ	300,44	416,37	190,34	188,96	191,85	189,44

Tempo de processamento							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	606,82	368,99	152,13	174,82	179,10	177,25
85,0%	μ	620,31	364,92	152,69	177,65	167,93	168,18
90,0%	μ	465,61	368,72	148,50	172,43	164,32	168,98
95,0%	μ	355,37	309,73	148,94	162,39	165,81	170,19
99,0%	μ	303,81	377,92	146,01	119,19	107,89	109,03
99,5%	μ	249,91	436,07	160,26	164,61	160,37	155,65
99,9%	μ	300,44	416,37	190,34	188,96	191,85	189,44

B.10 Resultados obtidos para as medidas de ajuste usando o algoritmo PolSeg na segmentação do vetor de espalhamento complexo com as polarizações *hh-vv*.

Mval							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,8770	0,9030	0,9747	0,9815	0,9819	0,9813
	σ	0,0564	0,0599	0,0062	0,0037	0,0036	0,0040
85,0%	μ	0,8797	0,9017	0,9736	0,9817	0,9822	0,9819
	σ	0,0597	0,0587	0,0077	0,0039	0,0035	0,0039
90,0%	μ	0,9016	0,9006	0,9730	0,9814	0,9819	0,9814
	σ	0,0504	0,0636	0,0063	0,0043	0,0038	0,0042
95,0%	μ	0,9136	0,9008	0,9709	0,9801	0,9800	0,9801
	σ	0,0446	0,0701	0,0068	0,0054	0,0050	0,0047
99,0%	μ	0,9120	0,8901	0,9633	0,9746	0,9744	0,9747
	σ	0,0479	0,0667	0,0095	0,0070	0,0064	0,0062
99,5%	μ	0,9124	0,8990	0,9600	0,9717	0,9716	0,9719
	σ	0,0482	0,0659	0,0100	0,0061	0,0059	0,0063
99,9%	μ	0,9021	0,8894	0,9547	0,9670	0,9657	0,9656
	σ	0,0510	0,0590	0,0106	0,0069	0,0069	0,0069

Mdim							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,5483	0,6576	0,8747	0,9237	0,9284	0,9251
	σ	0,1055	0,1320	0,0287	0,0154	0,0156	0,0126
85,0%	μ	0,5723	0,6631	0,8754	0,9259	0,9301	0,9303
	σ	0,1186	0,1348	0,0323	0,0168	0,0161	0,0141
90,0%	μ	0,6270	0,6732	0,8717	0,9267	0,9304	0,9286
	σ	0,1015	0,1554	0,0294	0,0176	0,0177	0,0162
95,0%	μ	0,6713	0,6798	0,8645	0,9237	0,9246	0,9253
	σ	0,0903	0,1628	0,0368	0,0206	0,0206	0,0190
99,0%	μ	0,7111	0,6868	0,8334	0,8805	0,8785	0,8811
	σ	0,0928	0,1554	0,0365	0,0276	0,0298	0,0299
99,5%	μ	0,7124	0,7072	0,8261	0,8749	0,8743	0,8767
	σ	0,0996	0,1466	0,0366	0,0271	0,0295	0,0319
99,9%	μ	0,7034	0,6971	0,8015	0,8414	0,8377	0,8348
	σ	0,1043	0,1289	0,0333	0,0320	0,0324	0,0334

B.10 - Continuação

Mpos							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,9405	0,9050	0,9802	0,9864	0,9872	0,9866
	σ	0,0285	0,0612	0,0046	0,0032	0,0029	0,0026
85,0%	μ	0,9423	0,9017	0,9807	0,9860	0,9868	0,9872
	σ	0,0303	0,0669	0,0047	0,0036	0,0035	0,0024
90,0%	μ	0,9527	0,8989	0,9799	0,9861	0,9868	0,9865
	σ	0,0234	0,0802	0,0047	0,0039	0,0035	0,0031
95,0%	μ	0,9598	0,9516	0,9782	0,9866	0,9871	0,9869
	σ	0,0165	0,0328	0,0055	0,0037	0,0036	0,0031
99,0%	μ	0,9616	0,8970	0,9748	0,9830	0,9829	0,9830
	σ	0,0170	0,0785	0,0055	0,0038	0,0044	0,0039
99,5%	μ	0,9600	0,9553	0,9739	0,9826	0,9825	0,9828
	σ	0,0180	0,0315	0,0059	0,0049	0,0048	0,0054
99,9%	μ	0,9567	0,9545	0,9706	0,9773	0,9770	0,9764
	σ	0,0211	0,0256	0,0060	0,0069	0,0073	0,0069

Mfor							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,3404	0,4706	0,7521	0,8349	0,8402	0,8387
	σ	0,0856	0,1335	0,0371	0,0180	0,0178	0,0162
85,0%	μ	0,3640	0,4789	0,7551	0,8393	0,8458	0,8468
	σ	0,0997	0,1384	0,0422	0,0200	0,0185	0,0174
90,0%	μ	0,4186	0,4965	0,7536	0,8444	0,8487	0,8477
	σ	0,0889	0,1596	0,0380	0,0210	0,0203	0,0191
95,0%	μ	0,4626	0,5079	0,7451	0,8426	0,8448	0,8450
	σ	0,0811	0,1715	0,0448	0,0245	0,0246	0,0231
99,0%	μ	0,5041	0,5091	0,7082	0,7924	0,7913	0,7946
	σ	0,0920	0,1645	0,0440	0,0329	0,0338	0,0337
99,5%	μ	0,5081	0,5247	0,6993	0,7894	0,7892	0,7920
	σ	0,0980	0,1597	0,0453	0,0305	0,0316	0,0349
99,9%	μ	0,4987	0,5122	0,6754	0,7495	0,7476	0,7440
	σ	0,0969	0,1369	0,0397	0,0357	0,0373	0,0379

B.10 - Conclusão

Mgeral							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,6766	0,7340	0,8954	0,9316	0,9344	0,9329
	σ	0,0661	0,0933	0,0182	0,0090	0,0089	0,0078
85,0%	μ	0,6896	0,7364	0,8962	0,9332	0,9362	0,9365
	σ	0,0750	0,0964	0,0207	0,0101	0,0095	0,0085
90,0%	μ	0,7250	0,7423	0,8945	0,9346	0,9369	0,9360
	σ	0,0640	0,1110	0,0187	0,0109	0,0105	0,0097
95,0%	μ	0,7518	0,7600	0,8897	0,9333	0,9341	0,9343
	σ	0,0561	0,1073	0,0225	0,0127	0,0127	0,0118
99,0%	μ	0,7722	0,7458	0,8699	0,9076	0,9068	0,9084
	σ	0,0605	0,1133	0,0228	0,0169	0,0179	0,0177
99,5%	μ	0,7732	0,7715	0,8648	0,9047	0,9044	0,9058
	σ	0,0641	0,0986	0,0232	0,0162	0,0172	0,0188
99,9%	μ	0,7652	0,7633	0,8505	0,8838	0,8820	0,8802
	σ	0,0662	0,0854	0,0209	0,0195	0,0201	0,0203

Número de regiões							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	177,76	115,40	67,64	50,31	50,23	49,73
85,0%	μ	162,33	101,32	58,69	43,54	43,71	43,66
90,0%	μ	156,65	88,20	50,60	37,50	37,98	37,50
95,0%	μ	134,74	71,94	42,82	32,64	32,66	32,76
99,0%	μ	97,48	57,19	39,85	46,57	48,44	46,67
99,5%	μ	87,15	54,34	36,20	30,88	30,06	29,93
99,9%	μ	71,42	46,12	31,86	30,72	29,91	30,12

Tempo de processamento							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	418,53	410,20	159,98	122,22	124,40	123,56
85,0%	μ	399,29	492,95	154,53	118,70	119,76	118,48
90,0%	μ	254,85	492,86	163,45	116,28	116,96	116,33
95,0%	μ	178,03	410,36	156,88	112,60	112,46	112,27
99,0%	μ	160,10	278,97	164,62	86,16	82,00	83,39
99,5%	μ	197,99	221,17	161,69	115,50	115,41	115,09
99,9%	μ	195,70	216,94	176,25	136,39	135,04	135,89

B.11 Resultados obtidos para as medidas de ajuste usando o algoritmo PolSeg na segmentação do vetor de espalhamento complexo com as polarizações *hv-vv*.

Mval							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,8770	0,9060	0,9736	0,9756	0,9757	0,9768
	σ	0,0564	0,0628	0,0073	0,0063	0,0068	0,0065
85,0%	μ	0,8797	0,9028	0,9722	0,9752	0,9762	0,9767
	σ	0,0597	0,0606	0,0076	0,0062	0,0063	0,0064
90,0%	μ	0,9016	0,9054	0,9702	0,9745	0,9750	0,9760
	σ	0,0504	0,0670	0,0079	0,0070	0,0065	0,0066
95,0%	μ	0,9136	0,9008	0,9666	0,9731	0,9735	0,9737
	σ	0,0446	0,0700	0,0090	0,0071	0,0065	0,0069
99,0%	μ	0,9120	0,8977	0,9608	0,9692	0,9718	0,9707
	σ	0,0479	0,0677	0,0096	0,0071	0,0065	0,0063
99,5%	μ	0,9124	0,8990	0,9565	0,9648	0,9669	0,9661
	σ	0,0482	0,0659	0,0102	0,0074	0,0074	0,0073
99,9%	μ	0,9021	0,8894	0,9485	0,9572	0,9602	0,9593
	σ	0,0510	0,0590	0,0121	0,0076	0,0075	0,0089

Mdim							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,5483	0,6592	0,8715	0,9079	0,9091	0,9128
	σ	0,1055	0,1323	0,0272	0,0213	0,0204	0,0185
85,0%	μ	0,5723	0,6654	0,8729	0,9096	0,9146	0,9156
	σ	0,1186	0,1352	0,0280	0,0183	0,0191	0,0195
90,0%	μ	0,6270	0,6740	0,8713	0,9121	0,9145	0,9155
	σ	0,1015	0,1568	0,0268	0,0193	0,0189	0,0212
95,0%	μ	0,6713	0,6798	0,8669	0,9082	0,9123	0,9099
	σ	0,0903	0,1628	0,0275	0,0206	0,0175	0,0206
99,0%	μ	0,7111	0,6882	0,8493	0,8871	0,8949	0,8885
	σ	0,0928	0,1557	0,0307	0,0211	0,0204	0,0227
99,5%	μ	0,7124	0,7072	0,8406	0,8745	0,8823	0,8748
	σ	0,0996	0,1466	0,0314	0,0239	0,0226	0,0241
99,9%	μ	0,7034	0,6971	0,8147	0,8416	0,8553	0,8517
	σ	0,1043	0,1289	0,0315	0,0289	0,0278	0,0272

B.11 - Continuação

Mpos							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,9405	0,9545	0,9783	0,9817	0,9809	0,9814
	σ	0,0285	0,0267	0,0055	0,0054	0,0044	0,0044
85,0%	μ	0,9423	0,9530	0,9775	0,9811	0,9809	0,9811
	σ	0,0303	0,0291	0,0054	0,0048	0,0049	0,0049
90,0%	μ	0,9527	0,9523	0,9765	0,9812	0,9804	0,9804
	σ	0,0234	0,0346	0,0056	0,0047	0,0046	0,0049
95,0%	μ	0,9598	0,9516	0,9759	0,9803	0,9803	0,9804
	σ	0,0165	0,0328	0,0052	0,0051	0,0041	0,0041
99,0%	μ	0,9616	0,9515	0,9742	0,9824	0,9851	0,9841
	σ	0,0170	0,0337	0,0055	0,0049	0,0037	0,0042
99,5%	μ	0,9600	0,9553	0,9727	0,9788	0,9799	0,9785
	σ	0,0180	0,0315	0,0065	0,0057	0,0056	0,0062
99,9%	μ	0,9567	0,9545	0,9695	0,9707	0,9726	0,9725
	σ	0,0211	0,0256	0,0063	0,0071	0,0068	0,0065

Mfor							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,3404	0,4713	0,7452	0,8140	0,8184	0,8217
	σ	0,0856	0,1334	0,0392	0,0220	0,0219	0,0197
85,0%	μ	0,3640	0,4793	0,7504	0,8208	0,8290	0,8287
	σ	0,0997	0,1384	0,0362	0,0203	0,0205	0,0212
90,0%	μ	0,4186	0,4971	0,7517	0,8248	0,8320	0,8316
	σ	0,0889	0,1593	0,0337	0,0218	0,0207	0,0231
95,0%	μ	0,4626	0,5079	0,7500	0,8229	0,8320	0,8275
	σ	0,0811	0,1715	0,0335	0,0246	0,0197	0,0243
99,0%	μ	0,5041	0,5093	0,7266	0,7928	0,8025	0,7941
	σ	0,0920	0,1644	0,0372	0,0265	0,0254	0,0266
99,5%	μ	0,5081	0,5247	0,7154	0,7827	0,7930	0,7850
	σ	0,0980	0,1597	0,0386	0,0301	0,0285	0,0307
99,9%	μ	0,4987	0,5122	0,6877	0,7450	0,7628	0,7587
	σ	0,0969	0,1369	0,0406	0,0348	0,0350	0,0338

B.11 - Conclusão

Mgeral							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	0,6766	0,7477	0,8921	0,9198	0,9210	0,9232
	σ	0,0661	0,0860	0,0185	0,0123	0,0122	0,0110
85,0%	μ	0,6896	0,7501	0,8933	0,9217	0,9252	0,9255
	σ	0,0750	0,0884	0,0179	0,0109	0,0115	0,0117
90,0%	μ	0,7250	0,7572	0,8924	0,9232	0,9254	0,9259
	σ	0,0640	0,1018	0,0172	0,0119	0,0115	0,0129
95,0%	μ	0,7518	0,7600	0,8899	0,9211	0,9245	0,9229
	σ	0,0561	0,1073	0,0173	0,0132	0,0109	0,0131
99,0%	μ	0,7722	0,7617	0,8777	0,9079	0,9136	0,9093
	σ	0,0605	0,1035	0,0188	0,0136	0,0130	0,0139
99,5%	μ	0,7732	0,7715	0,8713	0,9002	0,9055	0,9011
	σ	0,0641	0,0986	0,0195	0,0152	0,0144	0,0156
99,9%	μ	0,7652	0,7633	0,8551	0,8786	0,8877	0,8856
	σ	0,0662	0,0854	0,0209	0,0181	0,0180	0,0177

Número de regiões							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	177,76	115,40	67,99	53,21	51,68	51,73
85,0%	μ	162,33	101,32	59,29	46,12	44,46	44,76
90,0%	μ	156,65	88,19	50,18	40,25	38,79	39,25
95,0%	μ	134,74	71,95	42,54	34,28	33,58	33,88
99,0%	μ	97,48	57,19	40,10	44,54	52,00	51,47
99,5%	μ	87,15	54,34	36,81	34,67	37,25	36,42
99,9%	μ	71,42	46,12	33,12	28,72	28,96	28,87

Tempo de processamento							
Nível de confiança	Estatística	Nível de compressão					
		2	3	4	5	6	7
80,0%	μ	418,46	247,16	165,99	183,51	183,55	186,55
85,0%	μ	397,65	275,71	154,26	174,39	178,08	176,93
90,0%	μ	253,24	283,55	156,77	167,28	174,01	173,43
95,0%	μ	177,01	258,96	151,16	157,21	164,31	165,13
99,0%	μ	159,06	249,86	153,31	119,83	98,65	100,64
99,5%	μ	196,00	220,22	166,28	141,08	134,95	141,47
99,9%	μ	194,94	216,10	180,19	184,31	180,51	176,36

APÊNDICE C – SEGMENTADOR PARA DADOS POLSAR (POLSEG) – GUIA DE USO

C.1. INSTALAÇÃO

A instalação, a que se refere este documento, é o processo de criação do projeto que conterà os arquivos em linguagem IDL que compõe o segmentador PolSeg, a importação desses arquivos para o referido projeto e a construção do projeto criado. Após a criação do projeto o mesmo estará pronto para utilização sempre que o IDL for aberto.

C.2.1. CRIAÇÃO DO PROJETO

A sequência para a criação de projetos no IDL pode ser obtida no seu manual do usuário. Será visto aqui somente a sequência relativa ao uso específico do PolSeg a qual é constituída basicamente de dois passos:

1º Abrir o IDL; e

2º Criar um novo projeto IDL: Acionar: Arquivo → novo → Projeto IDL.

Ao realizar esta última operação o IDL disponibiliza a interface ilustrada na Figura B.1. Escolher para o nome do novo projeto o nome do arquivo principal do algoritmo intitulado “POLSEG_PRINCIPAL”.

O novo projeto será apresentado na janela de projetos do IDL, juntamente com o projeto default, já existente, conforme ilustrado na Figura B.2.

C.3.1. IMPORTAÇÃO DOS ARQUIVOS DO PROJETO

Nesta operação são importados os arquivos (programas do IDL) para o projeto do segmentador. Inicialmente, deve-se descomprimir o arquivo fornecido para uma pasta com o mesmo nome do arquivo contendo o código principal do segmentador (POLSEG_PRINCIPAL).

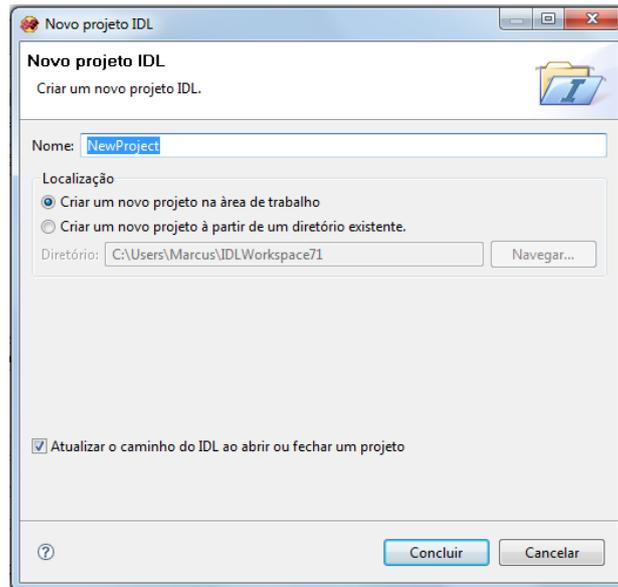


Figura B.1 – Criação do Projeto no ambiente IDL.

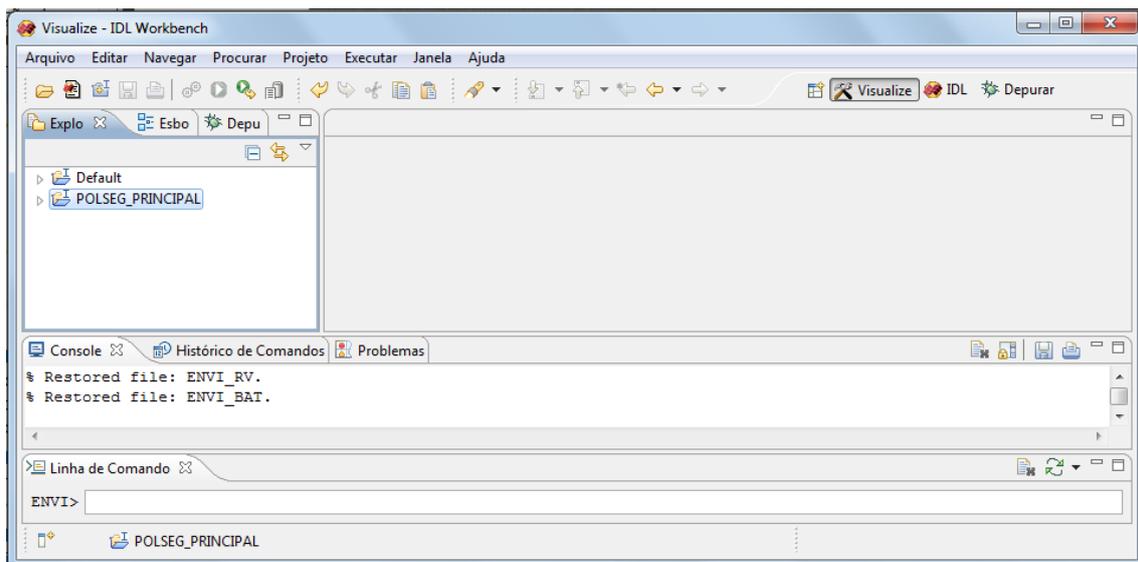


Figura B.2 – Lista de projetos no ambiente IDL.

Ainda no IDL, sobre o projeto listado na janela de projetos, deve-se clicar com o botão direito do mouse, para acessar as opções disponíveis para ação, das quais deve-se escolher a opção *importar*, que habilitará a interface da Figura B.3.

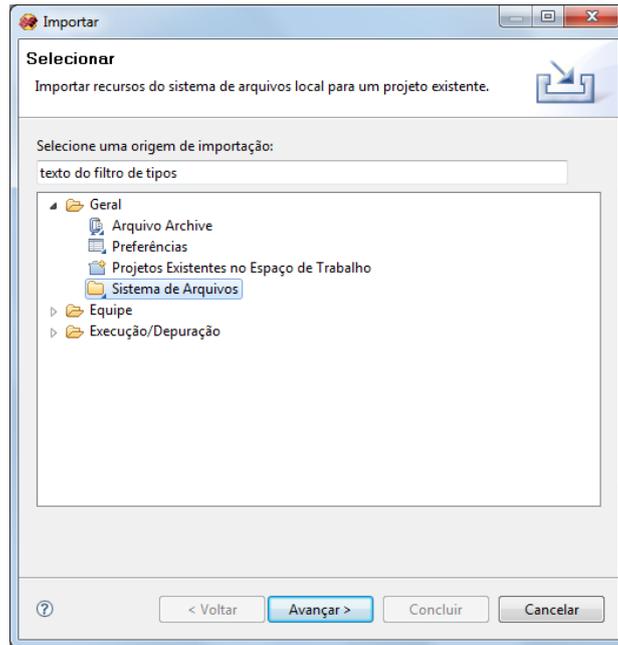


Figura B.3 – Interface de importação de projeto do IDL.

Na interface *Importar* deve ser escolhida a pasta *geral / sistema de arquivos* e acionar o botão *avançar*, que disponibilizará a interface ilustrada na Figura B.4. Nesta interface deve-se acionar o botão *Procurar* que permitirá procurar a pasta que contém os arquivos descompactados do segmentador polarimétrico armazenados no disco rígido do computador.

Após selecionada a pasta que contém dos arquivos, os mesmos serão carregados no espaço do lado direito da janela de importação. Deve-se então selecionar todos os arquivos listados acionando o botão *Selecionar Todos*. Após esta sequência de operações a finalização da importação é feita acionando o botão *Concluir*.

Após a conclusão, uma pasta com o nome do projeto e consequentemente com o nome do arquivo do programa principal do segmentador é criada em uma pasta do sistema de arquivos (pasta IDLworkspace), que é a pasta de trabalho do IDL, criada durante sua instalação.

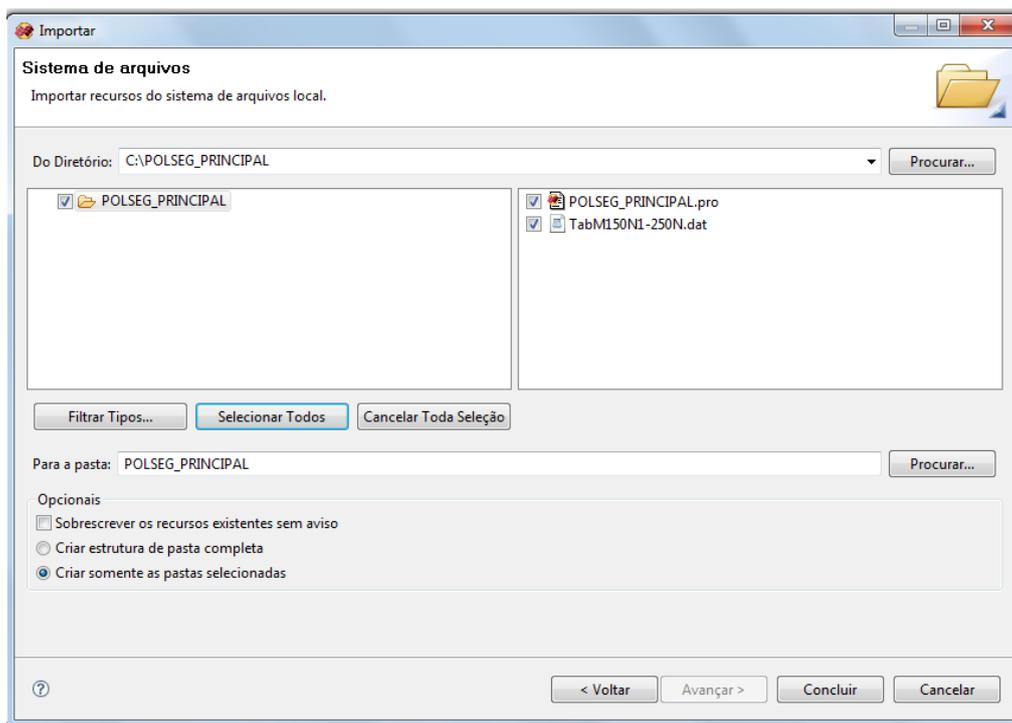


Figura B.4 – Interface de importação de projeto do IDL.

Na sequência deve-se então construir o projeto, processo no qual é gerado um arquivo .sav. Para tanto, na janela principal do IDL, deve-se clicar com o botão direito do mouse sobre o nome do projeto e escolher a opção construir projeto. Os arquivos serão então compilados e o projeto construído, ficando pronto para ser utilizado.

C.2. UTILIZAÇÃO DO SEGMENTADOR POLSEG

C.2.1. DESCRIÇÃO DO SEGMENTADOR

O PolSeg é um algoritmo híbrido que associa diversas técnicas de processamento de imagens para realizar a segmentação. Além disso, também é multinível e hierárquico, pois trabalha com imagens comprimidas em níveis segundo o critério hierárquico de pirâmides. Além disso é classificado como multicanais, pois permite processar diversos canais simultaneamente para obter a segmentação.

O PolSeg foi concebido para processar dados PolSAR e polarizados em intensidade, processados em 1-look ou múltiplas visadas. Para isso, os dados são representados na forma de matriz de covariância, independentemente da quantidade de canais que se deseja segmentar (dados multicanais ou dado monocanal). Para dados contidos em mais de um canal o segmentador usa o teste de igualdade de matrizes de covariância para realizar a segmentação. Já para dados em um único canal é usado o teste de igualdade de média de intensidades.

C.2.2. UTILIZAÇÃO

Para iniciar o segmentador, com o projeto carregado na lista de projetos do IDL, deve-se acionar:

Projeto → Executar Projeto nome do projeto; ou

Acionar o ícone destacado na Figura B.5, clicando com o apontador do mouse sobre ele.

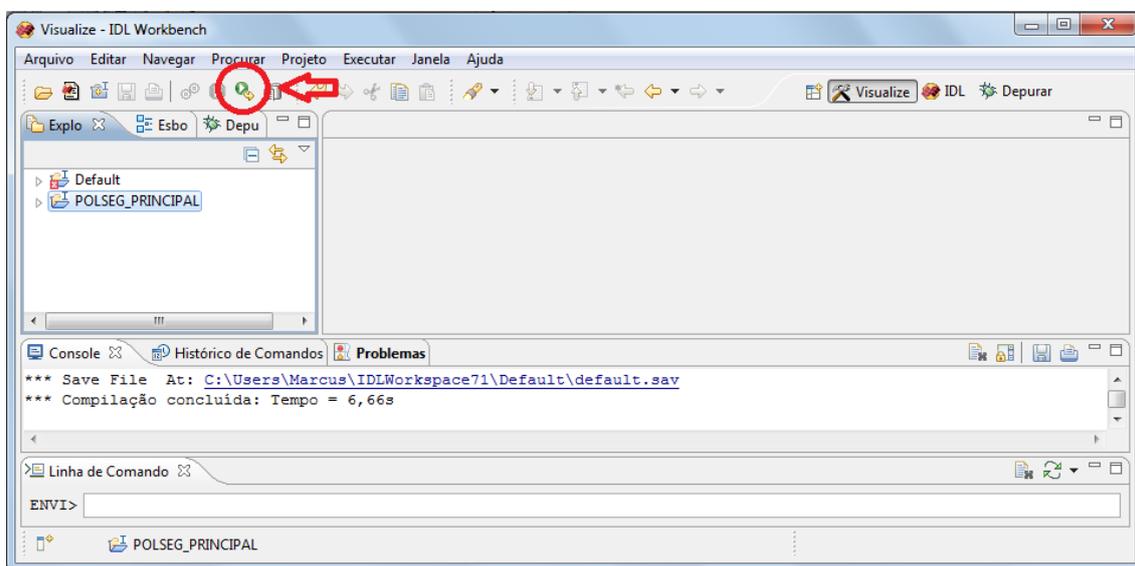


Figura B.5 – Ícone para a execução do projeto no ambiente IDL.

Ao realizar uma destas operações a interface gráfica do segmentador então será disponibilizada, a qual permite realizar a entrada de dados para

processamento, a seleção de parâmetros de segmentação e de opções de saída, e a execução do processamento. A seguir é feita uma descrição mais detalhada desta interface.

C.2.2.1. ENTRADA DE DADOS E PARÂMETROS

A entrada de dados e parâmetros do algoritmo é realizada via interface gráfica criada para esta finalidade, a qual também é responsável pelo acionamento do início do processamento (Figura B.6).

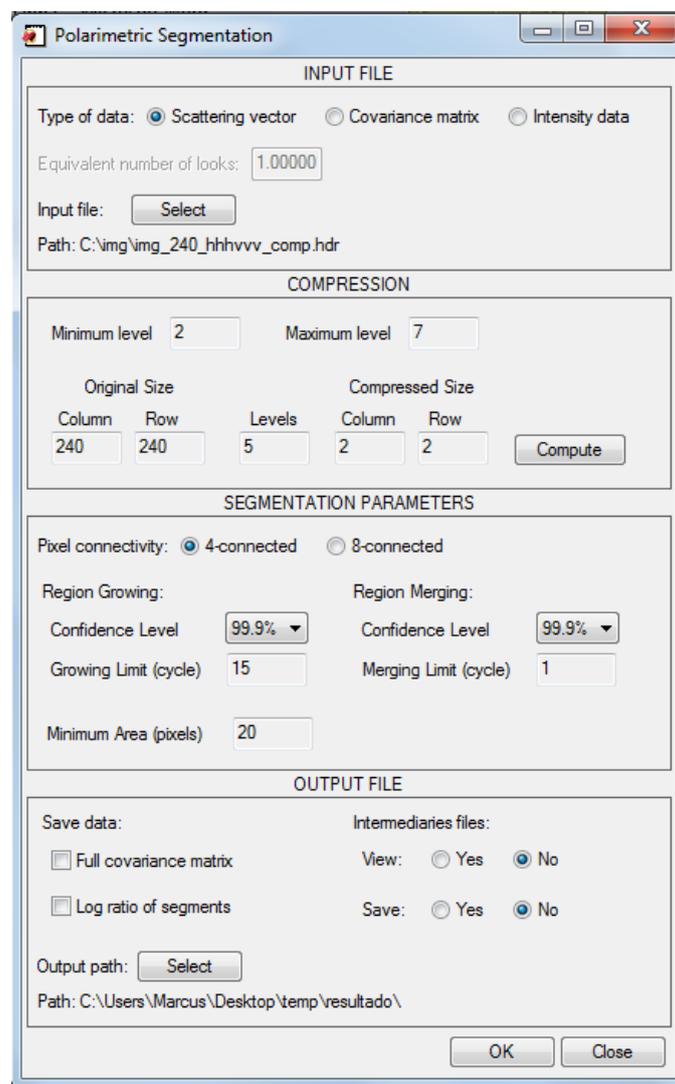


Figura B.6 - Interface de principal do PolSeg.

A interface de entrada é constituída por quatro blocos delimitados por molduras. Estes blocos são usados para que o usuário forneça informações a respeito da imagem, as opções de processamento e saída desejadas. A seguir é feito uma descrição detalhada de cada bloco contido na interface.

a. INPUT FILE

Neste bloco é realizada a entrada de informações referentes ao tipo de dado que se pretende segmentar e ao seu número de *looks*, bem como, é realizado o carregamento dos dados via seleção do arquivo digital usado para armazená-los.

Inicialmente o usuário deve informar o tipo de dado que deseja processar, no campo intitulado *Type of Data*. O PolSeg foi desenvolvido para trabalhar basicamente com um dos três tipos de dados de entrada: vetor de espalhamento (*Scattering vector*); matriz de covariância (*Covariance matrix*); e, dados multivariados em intensidade (*Intensity data*). Estes botões são exclusivos, ou seja, somente uma opção pode ser selecionada.

Quando selecionada a opção *Covariance matrix* ou *Intensity data* o campo *Equivalent number of looks* é habilitado. Isto é feito para que o usuário forneça o número equivalente de *looks* do dado SAR de entrada (nel_0) que será processado. Caso seja selecionado como tipo de dado a opção *Scattering vector* automaticamente é atribuído ao campo *Equivalent number of looks* um valor igual a um (dados 1-look). Cabe mencionar que o PolSeg não foi desenvolvido para gerar imagens em múltiplas visadas a partir de dados de 1-look.

Para realizar a entrada dos dados PolSAR, propriamente dito, o usuário deve acionar o botão denominado *Select* posicionado logo a direita do campo intitulado *Input File*. Quando este botão é acionado o PolSeg abre uma interface padrão do *Windows* (Figura B.7) intitulada *Input File (data type ENVI .hdr)* para a seleção de arquivo. Nesta interface o usuário deve indicar o caminho (*path*) até o diretório onde se encontra o arquivo que possui os dados, selecionando-o para processamento. O arquivo com os dados, para ser aceito

peço deve estar no formato padrão ENVI com seu respectivo arquivo *.hdr*, sendo este último o arquivo que deve ser selecionado. O arquivo tipo *.hdr* do ENVI contém todas as informações necessárias para que o PolSeg realize a abertura e o carregamento dos dados.

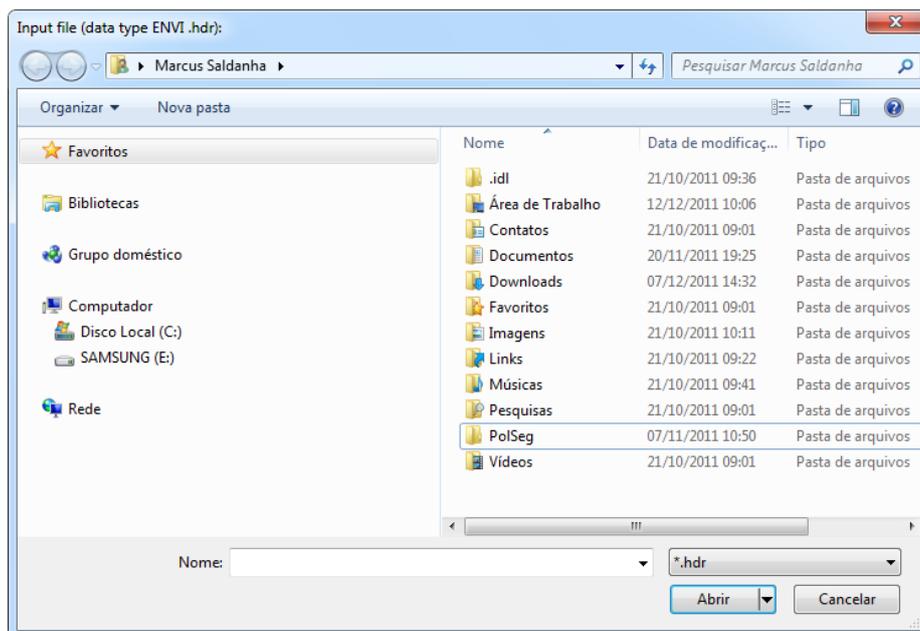


Figura B.7 - Interface padrão do *Windows* usado pelo PolSeg na seleção de arquivos.

O arquivo no formato ENVI com os dados deve estar estruturado de modo a conter em um único arquivo todos os canais que se pretende usar na segmentação. Se o tipo de dado for *Scatter vector* ou *Intensity data* a ordem dos canais dentro do arquivo deve estar de acordo com a sequência de polarizações previstas para formar a matriz de covariância. A Figura B.8 ilustra a organização dos canais do vetor de espalhamento para ser processado.

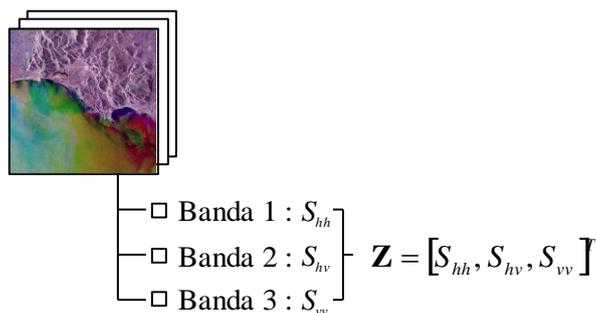


Figura B.8 - Estrutura do arquivo ENVI para carregamento do vetor de espalhamento (*Scattering vector*) e dados multivariados em intensidade (*Intensity data*).

Por sua vez, se o tipo de dado for *Covariance matrix*, deve-se ordenar os canais do arquivo tipo ENVI correspondentes aos elementos da matriz de covariância de forma linear da esquerda para direita e de cima para baixo, conforme vão aparecendo na matriz excluindo-se os elementos abaixo da diagonal principal. Esta operação deve ser executada previamente em outro ambiente, tal como o encontrado no ENVI. A Figura B.9 ilustra um exemplo de organização dos canais da imagem que possuem os dados da matriz de covariância.

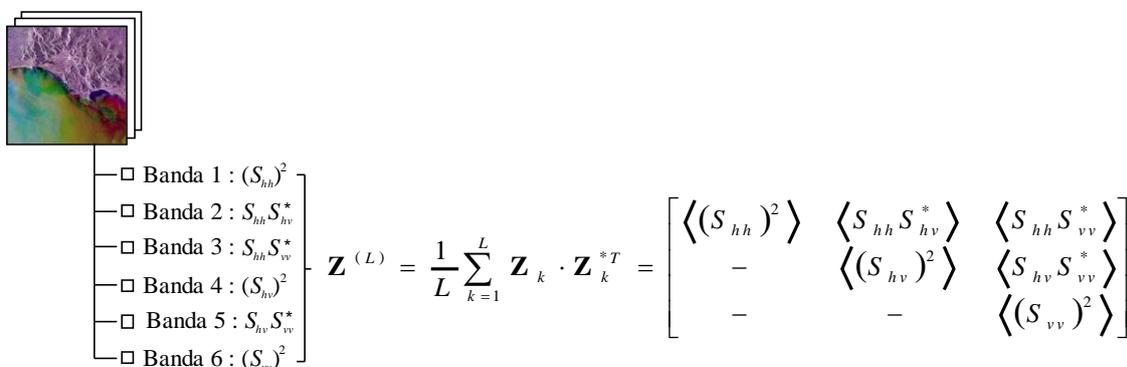


Figura B.9 - Estrutura do arquivo ENVI para carregamento da matriz de covariância (*Covariance matrix*).

Após selecionar o arquivo e acionar o botão Abrir da interface padrão do Windows o campo *Path* é preenchido com o caminho onde se encontra o arquivo que será processado.

b. COMPRESSION

Neste bloco são apresentados os níveis mínimo e máximo de compressão, as dimensões da imagem de entrada carregada sem compressões e comprimida, e fornecida à opção para que o usuário escolha o nível de compressão que deseja usar na segmentação.

Tomando por base o número de canais da imagem de entrada e o seu respectivo número equivalente de *looks*, o PolSeg obtém o nível mínimo de compressão. O valor obtido é apresentado na caixa de texto, posicionada a direita do campo denominado *minimum level* e não pode ser editado pelo usuário.

O nível máximo de compressão da imagem de entrada é calculado tomando por base as informações de número de colunas e de linhas. O valor calculado é apresentado na caixa de texto, posicionada a direita do campo denominado *maximum level* e não pode ser editado pelo usuário. O número máximo de compressão está limitado à oito níveis.

As dimensões da imagem original que está sendo processada são apresentadas no campo intitulado *Original Size* que disponibiliza a informação do número de colunas no campo *Column* e do número de linhas no campo *Row*, ambos situados nas caixas de texto logo abaixo de cada campo.

A quantidade de níveis de compressão pode ser ajustada conforme as necessidades do usuário, preenchendo o valor na caixa de texto posicionada logo abaixo do campo intitulado *Levels*. O valor default desta caixa é o nível máximo e as opções de preenchimento ficam limitadas ao intervalo compreendido entre o nível máximo e o nível mínimo (incluindo estes valores), para o processamento de imagens com mais de um canal, e ao intervalo compreendido entre um e nível máximo (incluindo estes valores), para imagens monocanais.

Após inserir o valor do nível de compressão que será usado no processamento, o usuário tem a opção de visualizar a dimensão em linha e coluna da imagem

comprimida, acionando o botão intitulado *Compute*. Ao fazer isso os valores calculados pelo PolSeg são apresentados no campo *Compressed Size*, nas caixas posicionadas logo abaixo dos campos intitulados *Column* e *Row*.

c. SEGMENTATION PARAMETERS

Neste bloco o usuário deve informar os parâmetros que deseja usar para realizar a segmentação da imagem SAR.

O primeiro parâmetro que deve ser informado é o *Pixel connectivity*, o qual define o número de vizinhos de um *pixel* que serão utilizados nos testes para o crescimento de regiões. As opções de conectividade que podem ser adotadas pelo PolSeg são quatro ou oito, sendo pré-selecionada a primeira opção.

Os parâmetros que definem o processo de crescimento de regiões (*Region Growing*) são o *Confidence Level* e o *Growing Limit (cycle)*. O primeiro diz respeito ao nível de confiança a ser adotado para a execução do teste estatístico responsável pelo crescimento, o qual pode assumir os valores de 99,9%, 99,5%, 99,0%, 95,0%, 90,0%, 85,0%, 80,0%. O segundo parâmetro define o número máximo de ciclos de crescimento do processo de crescimento de regiões. O campo referente ao parâmetro pode ser editado e está preparado para receber valores inteiros menores ou igual a dimensão máxima da imagem em linha ou coluna. Os valores pré-estabelecidos para os dois parâmetros são nível de confiança de 95,0% e limite de crescimento igual a 15.

Da mesma forma que no crescimento de regiões, o *Region Merging* usa dois parâmetros para realizar o processo de agrupamento de regiões, o *Confidence Level* e o *Merging Limit (cycle)*. O campo referente a este último parâmetro pode ser editado e está preparado para receber valores inteiros menores ou igual a dimensão máxima da imagem (linha ou coluna). Os valores pré-estabelecidos para os dois parâmetros são nível de confiança de 95,0% e limites de agrupamento igual a um.

O último parâmetro de segmentação é o *Minimum Area (pixels)*, que diz respeito à dimensão mínima permitida, em termos de quantidade de *pixels*,

para a definição do tamanho das regiões. O campo referente ao parâmetro tem valor pré-estabelecido de 20 *pixels* e pode ser editado pelo usuário.

d. OUTPUT FILES

Neste bloco o usuário deve informar quais os dados de saída adicionais deseja gerar e armazenar ao término do processamento (além dos dados relativos ao resultado final da segmentação), se pretende visualizar e ou armazenar os resultados intermediários e o local onde quer que os arquivos sejam armazenados.

O PolSeg permite que sejam selecionadas duas saídas de dados adicionais ao fim do processamento (*Save data*): a imagem da matriz de covariância complexa com todos os elementos (*Full covariance matrix*); e a imagem com os valores da razão de logaritmos média dos segmentos (*Log ratio of segments*). A primeira opção permite o armazenamento em disco rígido dos elementos da matriz de covariância gerada no processamento. Já a segunda opção permite obter uma imagem ao final do processamento possa ser usada para se avaliar a qualidade da segmentação obtida, uma vez que sob a suposição de homogeneidade dos segmentos, esta razão assume valores próximos à zero (SKRYVER et al. 2003).

Caso haja o interesse de acompanhar os resultados do processamento o usuário pode visualizar os arquivos de dados intermediários (*Intermediary files*) via interface gráfica. Para isso, a interface do PolSeg disponibiliza a opção *View*, que ao ser acionada (botão *Yes*) permite, a cada término da sequência de processamento da segunda etapa, acompanhar o andamento da segmentação. Também foi disponibilizada na interface a opção *Save*, que ao ser acionada (botão *Yes*) permite o armazenamento dos resultados intermediários gerados durante o processamento após cada término da sequência de processamento da segunda fase.

Para realizar a seleção do local em disco onde devem ser armazenados os resultados do processamento, o usuário deve acionar o botão denominado *Select* posicionado logo a direita do campo intitulado *Output path*. Quando este

botão é acionado o PolSeg abre uma interface padrão do *Windows* (Figura B.10) intitulada *Procurar Pasta*, com texto de cabeçalho *Output path*, para selecionar a pasta onde se pretende armazenar os dados. Nesta interface o usuário deve indicar o caminho (*path*) até o diretório onde se encontra a pasta. Após selecionar a pasta e acionar o botão *Ok* da interface padrão do *Windows* o campo *Path* é preenchido com o caminho onde se encontra a pasta a ser usada pelo PolSeg para a gravação dos dados de saída.

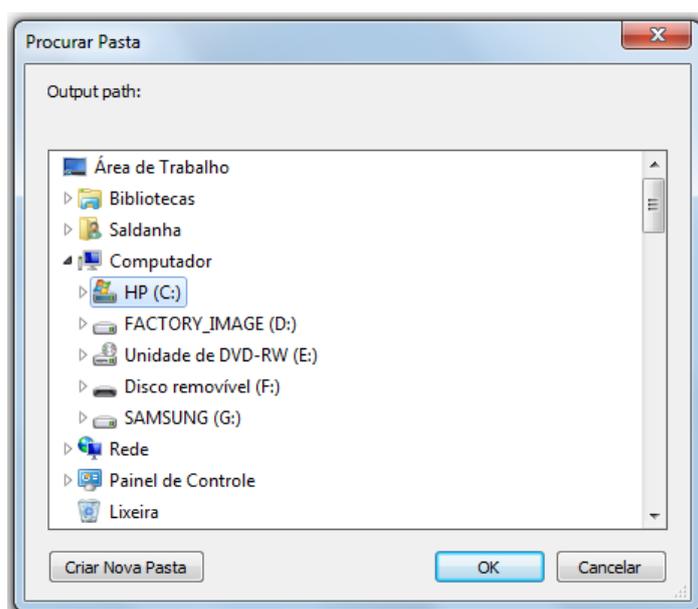


Figura B.10 - Interface de seleção de pasta para a gravação de resultados de processamento.

O início do processamento ocorre no momento que é acionado o botão *OK* localizado a direita no rodapé da interface gráfica do PolSeg. Caso se deseje fechar o segmentador sem executar a segmentação deve se acionar o botão *Close*.

C.2.2.2. INTERAÇÃO COM O USUÁRIO

A interação com o usuário tem por finalidade permitir que o usuário acompanhe o andamento do processamento para verificar se os resultados obtidos estão sendo os esperados para a sua aplicação. A interação é opcional, ou seja, somente ocorre caso o usuário tiver selecionado a opção de visualizar dados

intermediários na interface de entrada de dados e parâmetros. Quando a opção é selecionada, após cada sequência de processamento da segunda etapa, é disponibilizada uma interface gráfica com os resultados parciais obtidos. As informações apresentadas por esta interface podem ser usadas para que o usuário possa fazer uma análise antes de tomar uma decisão a respeito do processamento que está sendo executado. A interface gráfica do módulo de interação com o usuário é apresentada na Figura B.11.

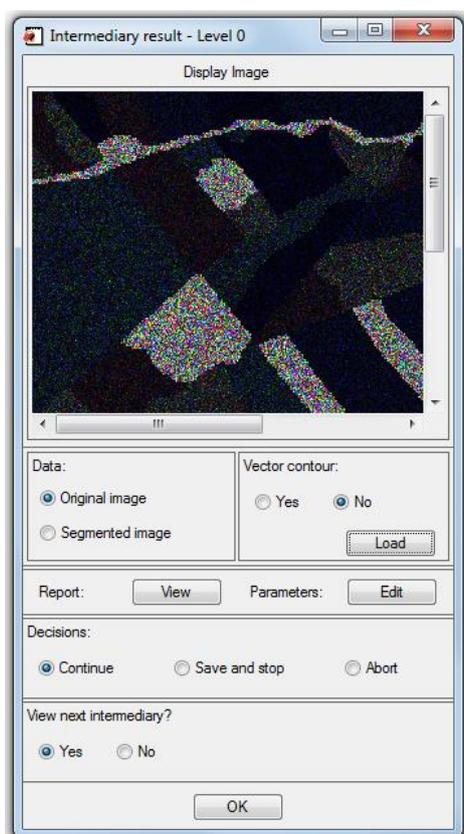


Figura B.11 - Interface principal de do módulo interação com o usuário.

A interface de interação com o usuário é constituída por cinco blocos dispostos em linhas e delimitados por molduras. Estes blocos são usados para que o usuário possa visualizar os resultados do processamento em forma de imagens, selecione as opções de visualização, verifique os resultados numéricos da segmentação e altere parâmetros, selecione a decisão que deseja tomar e decida se quer continuar vendo os resultados intermediários. A

seguir é feito uma descrição mais detalhada de cada bloco contido nessa interface.

a. *Display Image*

A função deste bloco é disponibilizar uma janela, com dimensões fixa em coluna e linha, para a visualização dos resultados da segmentação a partir das imagens. A dimensão da imagem visualizada nesta janela é a dimensão no nível de compressão igual a zero da imagem que esta sendo processada.

Quando a dimensão da imagem é maior que a dimensão da janela de visualização são habilitadas, na lateral direita e na base da janela, barras de rolagem que permitem navegar sobre toda a imagem.

b. *Bloco de Seleção de Dado para Visualização*

A função deste bloco é disponibilizar opções de visualização dos resultados de segmentação obtidos após a execução da sequência de processamento da segunda etapa.

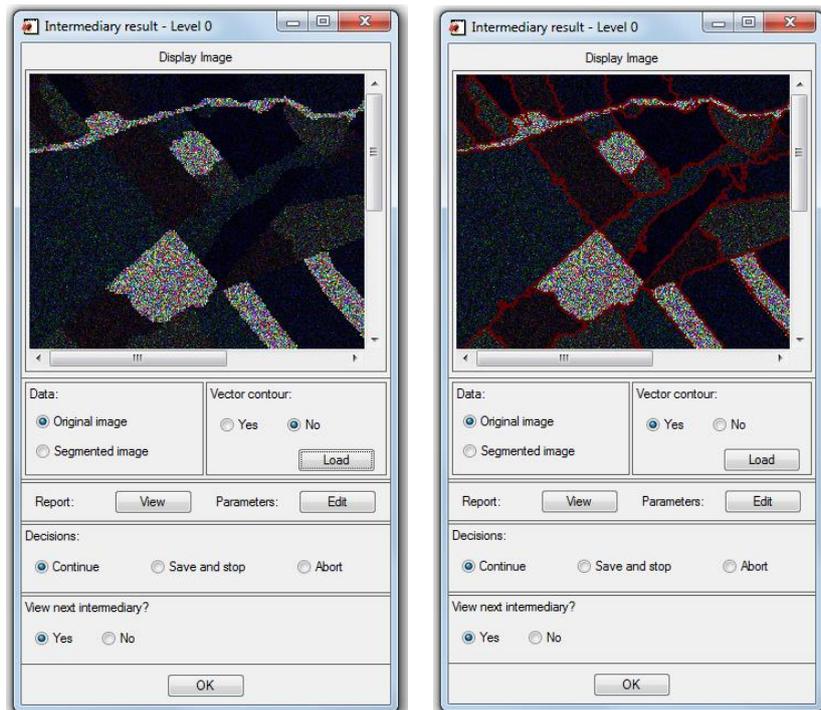
O bloco é dividido em duas partes dispostas em colunas delimitadas por molduras. A primeira parte, denominada *Data*, é constituída por dois botões, *Original Image* e *Segmented Image*, que permitem a seleção de um dos dois tipos de dado que podem ser visualizados. Quando selecionado o botão *Original Image*, o segmentador assume como imagem a ser carregada na janela de visualização os dados em intensidade da matriz de covariância. Por sua vez, se selecionado o botão *Segmented Image* assume como imagem a ser carregada na janela de visualização a imagem segmentada representada pela intensidade média das regiões. Para as duas opções, se a ordem da matriz de covariância for maior que dois é preparado para a visualização uma imagem colorida formada pelos três primeiros canais em intensidade da matriz de covariância. Caso contrário é preparado para visualização uma imagem em tons de cinza formada pelo primeiro canal em intensidade da matriz de covariância.

A segunda parte, denominada *Vector Contour*, é constituída por dois botões de seleção, *Yes* e *No*, e por um botão de acionamento de processo, *Load*. Os botões de seleção são exclusivos, ou seja, somente uma das duas opções pode ser selecionada. Quando selecionado o botão *Yes* o PolSeg prepara para carregar sobre a imagem selecionada os contornos obtidos a partir das regiões segmentadas. Por outro lado, quando selecionado o botão *No* o segmentador entende que a imagem selecionada deve ser carregada sem a sobreposição dos contornos. O botão de acionamento de processo é usado para carregar os dados selecionados para visualização. Quando este botão é acionado a imagem selecionada com ou sem contorno é disponibilizada para visualização na janela do bloco *Display Image*. Os modos de apresentação dos resultados oriundos da seleção das opções descritas são apresentados na Figura B.12.

c. Bloco de Visualização e Alteração de Parâmetros

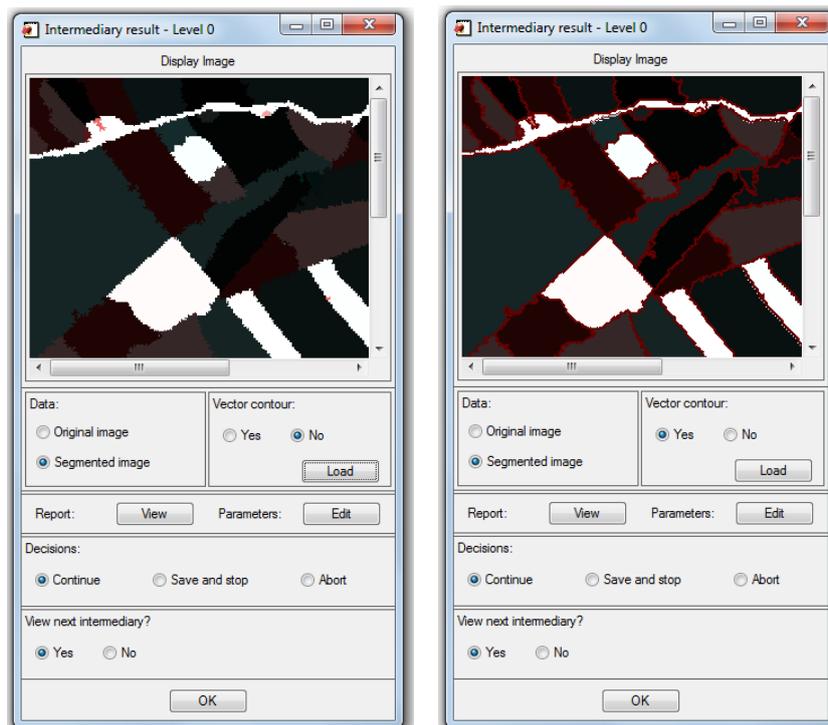
Este bloco é formado por dois botões de acionamento de processo. O primeiro botão, intitulado *View*, posicionado a direita do texto *Report*, quando acionado disponibiliza uma interface gráfica contendo um relatório do resultado intermediário do processamento (Figura B.13).

O relatório é constituído de três blocos delimitados por molduras. O primeiro bloco, denominado *Data*, apresenta informações de número equivalente de *looks*, dimensão em coluna e linha, e a quantidade de *pixels* da imagem de entrada (caixa intitulada *Original*) e da imagem no nível de processamento considerado (caixa intitulada *Processed*). O segundo bloco, denominado *Results*, apresenta o nível de compressão selecionado no início do processamento, o nível de compressão em que o processo de segmentação se encontra e do fator de compressão desse nível na caixa denominada *Levels*. Apresenta ainda, na caixa *Segmentation*, a quantidade de segmentos gerados e a quantidade média de *pixels* por segmento. O terceiro bloco apresenta o tempo computado para o processamento executada no nível de compressão considerado. Na parte inferior da interface o botão de acionamento de processo intitulado *Close* quando acionado fecha a interface.



(a)

(b)



(c)

(d)

Figura B.12 - Modos de apresentação de resultados disponíveis na interface do módulo interação com o usuário: (a) canais de intensidade da imagem original; (b) canais de intensidade da imagem original com contornos obtidos a partir dos segmentos; (c) intensidade média dos segmentos gerados; e, (d) intensidade média dos segmentos com a sobreposição dos contornos.

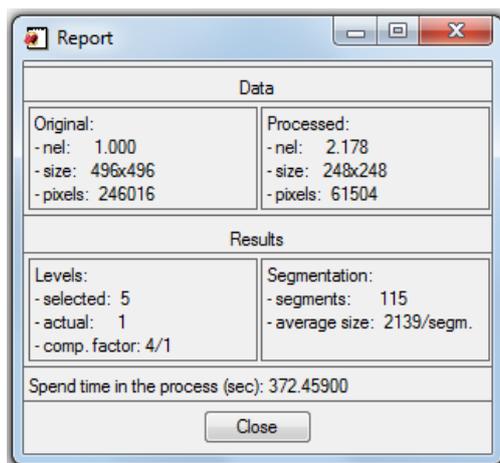


Figura B.13 - Interface do relatório intermediário de processamento.

O segundo botão de acionamento de processo, intitulado *Edit*, posicionado a direita do texto *Parameters*, quando acionado disponibiliza uma interface gráfica contendo opções para visualização e alteração dos parâmetros de segmentação (Figura B.14). Esta interface é constituída por quatro caixas dispostas em coluna delimitadas por molduras.

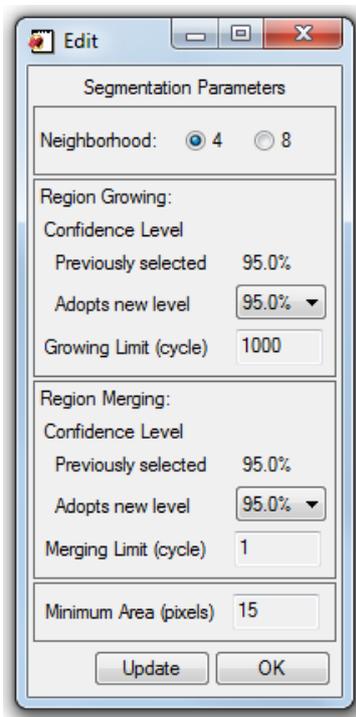


Figura B.14 - Interface de alteração de parâmetros de segmentação.

A primeira caixa permite que seja alterado por meio da seleção de um dos dois botões disponíveis, posicionados a direita do texto *Neighborhood*, o tipo de conectividade para a continuidade do processo de segmentação. A segunda caixa permite que sejam alterados os parâmetros adotados para realizar a segmentação por crescimento de regiões. A terceira caixa permite que sejam alterados os parâmetros adotados para realizar a o agrupamento de regiões. A quarta caixa permite que seja alterado a dimensão mínima das regiões em *pixels*. Na parte inferior da interface o botão de acionamento de processo intitulado *Update* quando acionado realiza a atualização dos parâmetros selecionados, enquanto o botão intitulado *OK* fecha a interface.

d. Bloco de Decisões

O bloco de decisões (*Decisions*) da interface de visualização de resultados intermediários tem por finalidade fornecer as opções que permitam ao usuário decidir o que pretende fazer com o processamento que esta sendo realizado. O bloco é constituído por três botões de seleção exclusivos, ou seja, somente uma das três opções pode ser selecionada. Se a primeira opção (*Continue*) for selecionada o PolSeg irá continuar o processamento executando mais uma descompressão ou continuará até sua finalização. Se a segunda opção (*Save and Stop*) for selecionada o algoritmo interrompe o processamento no nível de compressão no qual se encontra e gera o resultado final da segmentação. Por fim, se a terceira opção (*Abort*) for selecionada o processamento é finalizado e o segmentador é fechado.

e. Bloco de Continuidade de Visualização

O bloco de continuidade de visualização (*View next intermediary?*) tem por finalidade fornecer ao usuário a opção de continuar visualizando os dados intermediários. O bloco é formado por dois botões de seleção exclusivos (somente uma das duas opções pode ser selecionada). Se a primeira opção (*Yes*) for selecionada a interfase de visualização será disponibilizada a cada nível de compressão. Se a segunda opção (*No*) for selecionada a interface de visualização não será mais disponibilizada durante o processamento.

As decisões quanto a alteração ou não dos parâmetros de processamento pelo usuário e seus respectivos valores são armazenados no relatório de processamento. Dessa forma, são armazenados no relatório, os valores referentes ao tipo de conectividade, o nível de confiança e o limite de ciclos de crescimento para a segmentação, e o nível de confiança e o limite de ciclos de agrupamento para o agrupamento.

b.2.2.3. SAÍDA DE DADOS

Os resultados finais do processo de segmentação obtidos são armazenados no caminho de saída informado pelo usuário no início do processamento.

Como saída final do algoritmo são geradas as imagens de *Id's* dos segmentos e a imagem de intensidade média dos segmentos, no formato de arquivo *.tif*, e o arquivo de dados das regiões, em formato *.txt*. Além disso, são gerados os arquivos, em formato *.txt*, do relatório de processamento contendo todas as informações a respeito dos resultados obtidos em cada módulo de processamento executado e do relatório de análise de homogeneidade contendo os dados de homogeneidade das regiões obtidos a cada nível de compressão.

ANEXO – ARTIGOS GERADOS

SEGMENTAÇÃO DE IMAGENS SAR USANDO ABORDAGEM PROBABILÍSTICA BASEADA NA DISTRIBUIÇÃO GAMA

SAR Images Segmentation using Probabilistic Approach Based on Gamma Distribution

Marcus Fabiano Silva Saldanha^{1,2}, Corina da Costa Freitas¹, Sidnei João Siqueira Sant'Anna¹

¹Instituto Nacional de Pesquisas Espaciais - INPE

Divisão de Processamento de Imagens - DPI

Av. dos Astronautas, 1.758 – 12227-010 – São José dos Campos – SP – Brasil

{marcus,corina,sidnei}@dpi.inpe.br

²Diretoria de Serviço Geográfico - DSG

Quartel General do Exército, Bloco “F”, 2º Piso, Setor Militar Urbano – 70630-901 – Brasília – DF
– Brasil

saldanha@dsg.eb.mil.br

RESUMO

A disponibilidade de imagens SAR polarimétricas e seu potencial de uso têm gerado a necessidade de desenvolvimento de técnicas automáticas de processamento e análise deste tipo de dado. Dentre estas técnicas se destaca a segmentação, responsável pela extração automática de feições a partir de uma cena para uma tarefa posterior. Para o desenvolvimento dos algoritmos de segmentação é comum adotar modelos estatísticos para explicar o comportamento dos dados. Este trabalho tem por objetivo avaliar comparativamente os resultados de segmentação de dois algoritmos especificamente desenvolvidos para trabalhar com dados SAR. O primeiro algoritmo, denominado SegSAR, foi desenvolvido para trabalhar com dados em intensidade e utiliza propriedades estatísticas das distribuições Gama e Gaussiana para efetuar a segmentação. O segundo algoritmo, denominado PolSeg, adota a distribuição Wishart como modelo para dados polarimétricos representados pela matriz de covariância e a distribuição Gama para dado monocanal em formato de intensidade. A análise comparativa é efetuada utilizando a simulação de dados SAR monocanal no formato de intensidade. Os resultados obtidos mostraram que o PolSeg apresentou melhores índices de ajustes para medidas quantitativas que avaliam propriedades de forma, dimensão e intensidade dos segmentos. Estas medidas foram, respectivamente, 111%, 3% e 60% melhores que aquelas obtidas pelo SegSAR. Além disso, o PolSeg gera uma quantidade de regiões mais próxima da imagem de referência e, em média, 10 vezes menor que o SegSAR. O tempo computacional dispendido pelo PolSeg é, em geral, 4,5 vezes menor que o gasto pelo SegSAR.

Palavras chaves: Segmentação de Imagens SAR, RADAR, SegSAR, PolSeg, Modelagem Estatística.

ABSTRACT

The availability of polarimetric SAR images and its potential use have generated a need for developing automated techniques for image processing and analysis. Among these techniques can be highlighted the segmentation, used for automatic extractions of features from scenes for future tasks. The development of segmentation algorithms is usually based on statistical models to explain the patterns of the data. This paper aims to evaluate the segmentation results of two algorithms, especially designed for SAR data processing. The first algorithm, called SegSAR, was developed for SAR intensity data, employing the statistical properties of Gaussian and Gamma distributions to segment the data. The second algorithm, called PolSeg, adopts the Wishart distribution as the model for the polarimetric data and Gamma distribution for single channel data in intensity format. The comparative analysis is done using simulated SAR intensity data. The results showed that the PolSeg presented better quantitative measurements that assess properties of shape, size and intensity of the segments. These measures were respectively 111%, 3% and 60% better than those obtained by SegSAR. In addition, the PolSeg generates an amount of regions closer to the reference image and, on average, 10 times less than the SegSAR. The computational time spent by PolSeg is, in general, 4.5 times lower than that consumed by SegSAR.

Keywords: SAR Image Segmentation, RADAR, SegSAR, PolSeg, Statistical Modeling.

1. INTRODUÇÃO

Diversos campos da atividade humana atualmente têm utilizado imagens obtidas por sensores remotos para obter informações a respeito da superfície terrestre. Dentre os tipos de sensores disponíveis para obtenção de informações destaca-se o radar de abertura sintética (SAR), pela sua capacidade de gerar imagens em praticamente qualquer condição climática e possuir fonte de energia própria para imagear o alvo.

A existência de grande número destes sensores de radar, associado à aquisição contínua de imagens da superfície terrestre, tem ocasionado a disponibilização de um enorme volume de dados. O potencial destes dados para as atividades humanas tem sido mostrado nas aplicações onde a cobertura de nuvens inviabiliza o uso de imagens óticas, tais como, monitoramento de florestas tropicais (SERVELLO *et al.*, 2010) e mapeamento de áreas de inundações (MARINHO *et al.*, 2012), bem como, nas aplicações de detecção de deformação da superfície terrestre (Paradella *et al.*, 2012). Este panorama, associado às propriedades peculiares do dado SAR devido à sua formação e geração, demanda o desenvolvimento de técnicas automáticas e específicas para processamento e análise deste tipo de imagens. Dentre estas técnicas destaca-se a segmentação de imagens.

Uma abordagem comumente adotada no desenvolvimento dos algoritmos de segmentação de dados SAR é a probabilística. Esta abordagem se baseia na suposição que o sinal de retorno dos alvos contidos numa cena pode ser modelado por distribuições estatísticas. Sendo assim, a adoção desta suposição faz com que o preciso conhecimento das propriedades estatísticas e a adoção de uma modelagem apropriada se torne fundamental para obter resultados confiáveis na segmentação das imagens.

As propriedades estatísticas de dados SAR são utilizadas em vários algoritmos de segmentação, tais como o MUM (*Merge Using Moments*), descrito em Oliver e Quegan (2004), o SegSAR apresentado por Sousa Junior (2005), o PolSeg, descrito em Saldanha *et al.* (2012), e vários outros relatados por Weisenseel *et al.* (1998), Benboudjema *et al.* (2007), Pellizzeri *et al.* (2003), Lombardo e Oliver (2002), Skriver *et al.* (2002), Bombrum *et al.* (2011), Beaulieu e Touzi (2004) e Hänsch *et al.* (2008).

Além de técnicas baseadas em abordagem probabilística, diversas outras têm sido usadas na segmentação de dados SAR monocanal. Dentre estas se encontram as que tomam por base a limiarização de histograma, com trabalhos realizados por Lee e Jurkevich (1989), Smith (1996), Zaart *et al.* (1999), e Orbanz e Buhmann (2005); as baseadas em *wavelet*, com pesquisas desenvolvidas por Shi *et al.* (2004); as fundamentadas em técnicas de contornos ativos, com trabalhos apresentado por Shuai *et al.* (2007) e Ayed *et al.* (2005); e as baseadas em teoria de grafos, como o trabalho de Xu *et al.* (2007).

Tanto o SegSAR quanto o PolSeg possuem propriedades e inovações importantes por se tratarem de algoritmos híbridos, que utilizam métodos hierárquicos de pirâmide, técnicas de crescimento e agrupamento de regiões, de detecção de regiões heterogêneas, e de ajuste de bordas. As diferenças primordiais destes dois algoritmos consistem em que o primeiro efetua segmentações somente de dados em intensidade e utiliza, na grande parte de sua fundamentação, propriedades da distribuição Gaussiana, enquanto que o segundo foi desenvolvido para dados polarimétricos, e é totalmente fundamentado em propriedades da distribuição Wishart para a matriz de covariância complexa e, conseqüentemente, em propriedades da distribuição Gama para dados monocanal, a qual é mais adequada para dados em intensidade. Saldanha *et al.* (2012) apresentam uma análise comparativa preliminar entre estes dois algoritmos, baseada em uma única imagem do sensor R-99B e em uma única medida descrita pela razão entre a intensidade dos pixels e a intensidade média dos segmentos, refletindo a homogeneidade dos segmentos. Os resultados apontam para uma possível superioridade do algoritmo PolSeg com relação ao SegSAR. Como este experimento foi realizado utilizando dados monocanais e em intensidade, acredita-se que esta superioridade do Polseg se deva tão somente à modelagem mais apropriada dos dados realizada neste algoritmo.

Dentro deste contexto, o presente trabalho tem como objetivo realizar um estudo comparativo aprofundado dos algoritmos PolSeg e SegSAR. Para tal, é utilizado, como dados de entrada para as segmentações, um conjunto de 100 imagens simuladas. Estes dados representam imagens de radar monocanal no formato intensidade, sob a suposição de que os pixels dentro de cada região são independentes e identicamente distribuídos segundo uma distribuição Gama. A avaliação destas segmentações é efetuada comparando-se as segmentações dos dois algoritmos com uma imagem de referência (*phantom*) a partir da qual as imagens simuladas foram originadas. Nesta avaliação utilizou-se as medidas quantitativas de ajuste de forma, posição, dimensão e intensidade média das regiões, propostas por Delves *et al.* (1992).

Este trabalho está organizado da seguinte maneira: na seção 2 é efetuada uma descrição dos segmentadores SegSAR e PolSeg; na seção 3 é descrita a metodologia empregada neste trabalho para atingir os objetivos propostos; a avaliação dos resultados é realizada na seção 4, e por fim, as conclusões são apresentadas na seção 5.

2. ALGORITMOS DE SEGMENTAÇÃO: SEGSAR E POLSEG

O objetivo da segmentação é particionar a imagem em um conjunto de regiões distintas e uniformes com relação a alguma propriedade, como o nível de cinza, textura ou cor (ROSENFELD e KAK, 1982). Conforme apresentado por Gonzalez e Woods

(2002), os métodos de segmentação de imagem baseiam-se em duas propriedades básicas dos *pixels* com relação à sua vizinhança: descontinuidade e similaridade. A segmentação de imagens SAR segue o mesmo princípio aplicado para as imagens óticas, podendo ser feita por meio de detecção de bordas e de similaridades entre *pixels*.

A detecção de bordas tem como meta a separação de áreas por meio de mudanças nos valores dos *pixels*, originando os métodos baseados em contornos. Por sua vez, a detecção de similaridades é realizada por meio do uso da uniformidade interna das regiões existentes nas imagens em relação a algum parâmetro, tal como a intensidade dos valores dos *pixels*, dando origem aos métodos baseados em regiões.

As características de descontinuidade e similaridade, entretanto, sofrem influência de ruídos e por isso nem sempre podem ser deterministicamente modeladas de forma adequada, o que acaba implicando no uso de modelos probabilísticos. Devido a este fato, boa parte das abordagens usadas para fundamentar o desenvolvimento dos algoritmos de segmentação de imagens adotam modelagens estatísticas para explicar o comportamento dos dados contidos em uma cena. Um modelo comumente usado nos dados SAR é o multiplicativo (FREITAS *et al.*, 2005). Este modelo, toma por base a suposição que, sob certas circunstâncias (TUR *et al.*, 1982), o valor observado em cada célula de resolução de uma imagem SAR é a ocorrência de uma variável aleatória Z dada por,

$$Z = X \cdot Y \quad (1)$$

onde X é a variável aleatória que modela a componente da informação retroespalhada pelos alvos, comumente denominada por retroespalhamento e Y é a variável aleatória que modela o ruído *speckle*. Para dados oriundos dos sensores SAR, dependendo do grau de homogeneidade das diferentes regiões imageadas, as distribuições associadas à modelagem de X variam, produzindo diferentes distribuições para representar Z (FRERY *et al.*, 1997; FRERY *et al.*, 2007).

Oliver e Quegan (2004) fazendo uso das características dos dados gerados pelo SAR e do modelo multiplicativo, definiram dois tipos de modelos para representar as imagens SAR: o *cartoon* (manchas), para o qual se supõe que as imagens são compostas por regiões, separadas por bordas, dentro das quais o retroespalhamento possui um valor constante; e o *texture* (textura) para o qual se supõe uma variação interna no retroespalhamento dentro de cada região. Estes dois modelos de representação têm sido adotados no desenvolvimento de diversos algoritmos.

Dentre os algoritmos existentes que usam a modelagem estatística e o modelo de representação de dados definidos por Oliver e Quegan (2004) para realizar a segmentação de imagens SAR monocanais pode-se citar o MUM, proposto por Cook *et al.* (1994), o RWSEG, proposto por White (1986), o SegSAR, desenvolvido por Sousa Junior (2005), e o PolSeg (Saldanha *et al.*, 2012), desenvolvido para trabalhar com

dados polarimétricos, e que tem, como casos especiais, a segmentação de dados univariados e multivariados em intensidade. Por apresentarem características de concepção e de implementação semelhantes, e por serem alvos de comparação neste trabalho, os algoritmos SegSAR e PolSeg são discutido a seguir mais detalhadamente.

2.1. O algoritmo SegSAR

O SegSAR foi desenvolvido para processar dados multivariados polarizados em intensidade e é considerado um algoritmo híbrido por fazer uso das técnicas de crescimento de regiões, de agrupamento de regiões, de ajuste de bordas e de separação de regiões não homogêneas. Além disso, pode ser considerado multi-nível, uma vez que faz uso do critério de pirâmides hierárquicas (JAIN, 1989) para comprimir os dados antes de iniciar o processamento e hierárquico, já que usa informações de um nível de compressão para a segmentação da imagem no outro nível (Sousa Junior, 2005). O algoritmo além de realizar a segmentação de imagens SAR também processa imagens óticas, e pode adotar tanto o modelo de manchas como o modelo de textura para representar os dados.

Os parâmetros de segmentação usados para realizar a segmentação no SegSAR são: o modelo de representação dos dados (manchas ou textura), o tipo de imagem (óptica ou de radar), o limiar de similaridade usado nos testes de crescimento e agrupamento de regiões (valor em dB), a área mínima para a definição de uma região (em quantidade de *pixels*), o nível de confiança adotado para todos os testes estatísticos e, finalmente, o nível máximo de compressões desejado.

A segmentação realizada no SegSAR tem início com a compressão em pirâmides da imagem a ser segmentada até o nível máximo de compressão selecionado. No processo de compressão a imagem de entrada é considerada a base da pirâmide, a qual em cada nível de compressão tem sua dimensão em linha e em coluna reduzida pela metade. Nesta redução uma nova imagem é gerada na qual cada *pixel* é formado pela média de quatro *pixels* da imagem no nível anterior. Após a compressão tem início o processo de crescimento de regiões, onde cada *pixel* é considerado como uma região. A seleção do *pixel* a partir do qual ocorrerá o processo de crescimento é feita sobre uma lista gerada de forma aleatória contendo os *pixels* da imagem. Após o término do crescimento de regiões tem-se uma imagem segmentada com resolução degradada, devido às compressões aplicadas sobre a imagem original. O próximo passo é a descompressão dos dados, onde as regiões formadas na segmentação passam a ser representadas por regiões com o quádruplo do número de *pixels*. Dado o aumento da resolução da imagem, as bordas geradas podem ser grosseiras, com isso aplica-se um ajuste de bordas para melhorar a segmentação.

No algoritmo SegSAR são consideradas três diferentes situações durante o processo de crescimento de regiões: agrupamento *pixel a pixel*, *pixel a região* e *região a região*. Existe um teste específico para cada uma destas situações. O agrupamento de dois *pixels* é realizado usando a distância Euclidiana e o limiar de similaridade. Um teste baseado na distribuição Gama é empregado para agrupar um *pixel* a uma região, o qual consiste em determinar a probabilidade deste *pixel* pertencer à região. Duas regiões são agrupadas pelo algoritmo aplicando o teste t-Student, que é usado para comparar a igualdade da média para dados distribuídos de acordo com uma Gaussiana. A justificativa para o emprego de testes t no agrupamento de regiões do algoritmo SegSAR, é que, para dados comprimidos, a distribuição Gama se aproxima de uma distribuição Gaussiana para número equivalente de visadas suficientemente grande (YANASSE *et al.*, 1995).

2.2. O algoritmo PolSeg

O PolSeg foi desenvolvido para segmentar dados SAR multivariados polarimétricos e usa as mesmas técnicas de processamento adotadas no SegSAR, podendo ser por este motivo classificado como híbrido. Além disso, o algoritmo também faz uso de processamento multi-nível e hierárquico, trabalhando com imagens comprimidas em diversos níveis, de acordo com o critério de pirâmides hierárquicas.

O algoritmo PolSeg faz uso do modelo de manchas para representar os dados SAR e da modelagem estatística, via modelo multiplicativo, para realizar a segmentação. Os parâmetros de segmentação usados no algoritmo são: nível de compressão máximo desejado, níveis de confiança para os testes estatísticos realizados nos processos de crescimento e agrupamento de regiões, o número máximo de ciclos para o crescimento e agrupamento de regiões, e a área mínima (em *pixels*) das regiões no resultado final da segmentação.

O processo de segmentação no PolSeg é realizado em três fases, as quais por sua vez foram divididas em módulos de processamento individuais. A primeira fase é constituída dos módulos de *Entrada de Dados*, *Geração da Matriz de Covariância*, *Compressão da Imagem* e *Segmentação*. No módulo *Entrada de Dados* é calculado o nível máximo de compressão possível e são definidos pelo usuário os parâmetros a serem usados na segmentação. O módulo de *Geração da Matriz de Covariância* é responsável pelo cálculo da matriz de covariância a partir dos dados de entrada. A matriz de covariância é então comprimida no módulo de *Compressão da Imagem*, para o nível selecionado pelo usuário no módulo de entrada de dados. Este dado comprimido é segmentado, no módulo de *Segmentação*, por meio do processo de crescimento de regiões, usando o teste de hipótese baseado na distribuição Gama para a matriz de covariância formada por um único elemento, ou usando o teste baseado na distribuição Wishart para matrizes de covariância de ordens maiores que um. A descrição do teste de

igualdade de médias para distribuições Gama usado pelo algoritmo é apresentada na seção 2.2.1, enquanto que a descrição do teste de igualdade de matrizes de covariância sob a hipótese de distribuição Wishart pode ser encontrado em Conradsen *et al.* (2003).

A segunda fase de processamento é formada pelos módulos: *Descompressão da Imagem* em um nível, onde o resultado obtido no módulo de *Segmentação* é descomprimido para ser usado como base para o processamento pelos módulos subsequentes; *Ajuste de Bordas*, onde as regiões segmentadas no nível superior têm seus contornos “refinados”; *Análise de Homogeneidade*, onde as regiões segmentadas são submetidas a um teste de homogeneidade considerando a distribuição Gama; *Segmentação de Regiões Heterogêneas*, onde as regiões rejeitadas na análise de homogeneidade são submetidas a novo processo de segmentação por crescimento de regiões; e *Agrupamento de Regiões*, onde uma região é agrupada a outra região adjacente dependendo do resultado do teste de hipóteses. A segunda fase de processamento é repetida até que o nível de compressão atinja o mesmo nível da imagem de entrada.

A terceira e última fase de processamento consiste dos módulos de *Área Mínima* e *Saída de Dados*. As regiões com número de *pixels* menor que o limiar definido pelo usuário no módulo de *Área Mínima* são agrupadas às regiões vizinhas. A imagem segmentada final é armazenada em disco rígido no módulo de *Saída de Dados*.

Para realizar o processo de crescimento de regiões no PolSeg, envolvendo agrupamentos *pixel a pixel*, *pixel a região* e *região a região*, é usado o teste de hipótese de igualdade de matrizes de covariância. Para dados monocanais em intensidade, situação analisada neste trabalho, este teste estatístico reduz-se ao teste de igualdade de médias de variáveis aleatórias possuindo distribuições Gama. Este fato, em particular, faz com que o PolSeg possua uma modelagem estatística mais adequada e rigorosa para os dados SAR em intensidade, quando comparada à modelagem utilizada pelo SegSAR.

As principais características dos dois algoritmos comparados são apresentadas resumidamente na Tabela 1.

Tabela 1: Principais características dos algoritmos SEGSAR e POLSEG

Características	SegSAR	PolSeg
Tipo de algoritmo	Híbrido, multibandas, multi-nível e hierárquico	Híbrido, multibandas, multi-nível e hierárquico
Tipo de dados processados	SAR polarizados em intensidade e óticos	SAR polarimétricos complexos e polarizados em intensidade
Modelagem estatística	Distribuição Gaussiana e distribuição Gama	Distribuição Wishart para dados polarimétricos; e distribuição Gama para dados monocanais em intensidade

2.2.1. Teste de igualdade de médias para distribuições Gama

Para o caso de dados em intensidade de regiões homogêneas (*backscatter* constante), a variável aleatória representando a média de m pixels independentes possui uma distribuição Gama com parâmetros n e β . Neste caso, n depende de m e do número de visadas do dado de intensidade da entrada, e o parâmetro β está relacionado à intensidade média da região.

Considere agora duas regiões, sendo a média dos dados de intensidade destas regiões representadas pelas variáveis aleatórias \bar{X} e \bar{Y} . Estas variáveis aleatórias são distribuídas conforme uma Gama, $\Gamma(n_x, \beta_x)$ e $\Gamma(n_y, \beta_y)$, com função densidade de probabilidade dada por

$$f(z; n_\nu, \beta_\nu) = \frac{n_\nu^{n_\nu}}{\Gamma(n_\nu)\beta_\nu^{n_\nu}} z^{n_\nu-1} \exp\left\{-\frac{n_\nu z}{\beta_\nu}\right\} \quad (2)$$

onde, ν pode assumir x ou y .

Neste caso, o teste usado no PolSeg para agrupar duas regiões consiste de um teste de igualdade dos parâmetros β_x e β_y . Pode-se provar que, sob a hipótese nula, $H_0: \beta_x = \beta_y = \beta$, a razão \bar{Y} / \bar{X} possui uma distribuição F, de modo que

$$\frac{\bar{Y}}{\bar{X}} \sim F(2n_y, 2n_x) \quad (3)$$

A região crítica do teste se apresenta na forma

$$\frac{\bar{Y}}{\bar{X}} \leq q_1 \text{ ou } \frac{\bar{Y}}{\bar{X}} \geq q_2 \quad (4)$$

onde, q_1 e q_2 são obtidos pelos centis da distribuição F com $2n_y$ e $2n_x$ graus de liberdade.

O algoritmo PolSeg usa o teste descrito acima para obter a segmentação do dado SAR, durante o processo de crescimento de regiões, para agrupar dois *pixels*, ou um *pixel* a uma região ou duas regiões. Cabe mencionar que os valores de n_x e n_y serão diferentes para cada nível de compressão. Estes valores são calculados a cada nível considerando o número de visadas dos dados da imagem em intensidade e a autocorrelação espacial dos *pixels*.

3. METODOLOGIA

Para atingir os objetivos deste trabalho, foi desenvolvida uma metodologia baseada nas fases a seguir relacionadas:

- Obtenção de imagens SAR simuladas;
- Segmentação das imagens simuladas;
- Obtenção das métricas de avaliação das segmentações;
- Análise dos resultados.

A seguir, é feita uma descrição destas fases.

3.1. Obtenção de imagens SAR simuladas

O uso de imagens simuladas permite a condução de experimentos controlados, isto é, experimentos cujo comportamento dos alvos é conhecido a priori, além de permitir a realização de avaliações sem a influência de uma imagem particular.

Inicialmente foi criada uma imagem de referência (*phantom*), com 240 x 240 pixels, contendo 6 classes distintas, distribuídas em 29 regiões. Para que a imagem simulada se assemelhasse a uma imagem real, as intensidades médias das classes foram determinadas a partir de uma imagem SAR real. A imagem usada para este fim foi adquirida na região de Paulínea, SP, pelo sensor R99B da Força Aérea Brasileira (FAB), na banda L (23,9 cm de comprimento de onda ou 1,27 GHz), polarização HH, em 27 de junho de 2007. Na Tabela 2 são apresentados os valores das intensidades médias das seis classes, utilizados no processo de simulação.

Tabela 2: Intensidades médias das classes utilizadas na simulação dos dados

Classes	Intensidade Média ($\times 10^{-4}$)
1	7,61
2	128,59
3	29,63
4	14,06
5	48,93
6	18,70

Na Figura 1(a) é apresentada a imagem *phantom*, contendo as 29 regiões. O nível de cinza nestas regiões representam as intensidades médias. Para gerar uma imagem simulada, o valor de cada pixel em cada região foi obtido através da geração aleatória da ocorrência de uma variável possuindo uma distribuição Gama, com uma visada, e com média dada pela intensidade média da respectiva região. O exemplo de uma imagem simulada é apresentado na Figura 1(b). Este processo de simulação foi utilizado para a geração de um conjunto constituído por 100 imagens simuladas.

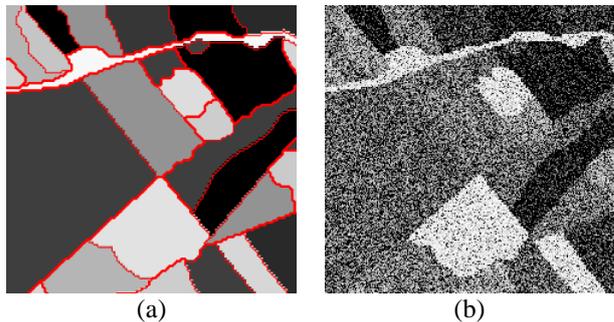


Fig. 1 - Imagens originais (a) de referência (*phantom*) com os contornos das regiões (b) SAR simulada.

3.2. Segmentação das imagens simuladas

As segmentações das imagens simuladas foram realizadas utilizando, em ambos os algoritmos, sete valores distintos dos parâmetros *nível de confiança* (variando de 80% a 99,9%), seis valores do parâmetro *nível de compressão* (variando de 2 a 7), e um valor fixo de 15 *pixels* como *área mínima* para a definição das

regiões. Para o SegSAR foi adotado ainda um valor igual a 0,6 dB para o parâmetro *similaridade*.

Para cada combinação de parâmetros, em ambos os algoritmos, foram segmentadas todas as 100 imagens do conjunto de imagens simuladas, totalizando 4.200 segmentações para cada algoritmo.

3.3. Obtenção das métricas de avaliação das segmentações

Uma maneira de avaliar o desempenho de um algoritmo de segmentação é comparar os resultados obtidos com um resultado esperado. Neste trabalho, este resultado esperado é constituído pela imagem de referência (*phantom*) apresentada na Figura 1(a). As medidas quantitativas apresentadas em Delves *et al.* (1992), e descritas a seguir, foram então utilizadas para realizar a avaliação das segmentações.

Segundo Delves *et al.* (1992), o coeficiente de ajuste entre as regiões da imagem de referência e as respectivas regiões segmentadas pode ser calculado por critérios de posição, valor médio dos *pixels* da região, dimensão e forma. Sendo assim, considere R e S as imagens de referência e segmentada, de mesma dimensão, com l linhas e c colunas, particionadas respectivamente em J e K regiões. Sejam as regiões de R denotadas por r_j , $j = 1, \dots, J$, e as regiões de S denotadas por s_k , $k = 1, \dots, K$. O processo de ajuste é efetuado de maneira que para cada região de R seja selecionada uma região em S que melhor a represente. Para esta seleção são definidas inicialmente, para todos os pares de regiões (r_j, s_k) $j = 1, \dots, J$, e $k = 1, \dots, K$, as seguintes medidas entre regiões:

$$\alpha(r_j, s_k) = \frac{|\mu_x(r_j) - \mu_x(s_k)|}{c} \quad (5)$$

$$\lambda(r_j, s_k) = \frac{|\mu_y(r_j) - \mu_y(s_k)|}{l} \quad (6)$$

$$\gamma(r_j, s_k) = \frac{|d(r_j) - d(s_k)|}{d(r_j) + d(s_k)} \quad (7)$$

$$\phi(r_j, s_k) = \frac{|\mu_v(r_j) - \mu_v(s_k)|}{\mu_v(r_j) + \mu_v(s_k)} \quad (8)$$

onde $\mu_x(t)$ e $\mu_y(t)$ representam, respectivamente, os valores médios das abcissas e das ordenadas da região t , (isto é, $(\mu_x(t), \mu_y(t))$ representa o centro geométrico da região t); $d(t)$ é o número de *pixels* da região t ; e $\mu_v(t)$ é o nível de cinza médio dos *pixels* da região t . Portanto, $\alpha(r_j, s_k)$ e $\lambda(r_j, s_k)$ representam, respectivamente, as distâncias entre as coordenadas dos centros geométricos das regiões r_j e s_k ; $\gamma(r_j, s_k)$ representa a porcentagem da discrepância do número de pixels das regiões r_j e s_k , em relação ao total de pixels destas regiões; e $\phi(r_j, s_k)$

representa a porcentagem da discrepância das intensidades médias das regiões r_j e s_k , em relação à soma de suas intensidades.

Sobre estas medidas, são definidas as seguintes matrizes, de dimensão $J \times K$:

$$G = (g_{jk})_{J,K} : g_{jk} = \frac{d(r_j \cap s_k)}{d(r_j \cup s_k)} \quad (9)$$

$$F = (f_{jk})_{J,K} : f_{jk} = \frac{\alpha(r_j, s_k) + \beta(r_j, s_k) + 0,5[\gamma(r_j, s_k) + \phi(r_j, s_k)]}{g_{jk}} \quad (10)$$

Os elementos g_{jk} da matriz G fornecem indicações sobre a sobreposição entre os pares de regiões (r_j, s_k) . Valores destes elementos iguais a 1 indicam uma perfeita sobreposição das regiões, e valores iguais a zero indicam que as regiões são disjuntas (Lucca, 1998). Os elementos da matriz F fornecem uma medida de ajuste entre os pares de regiões, considerando o tamanho, posição, forma e valor do nível de cinza das mesmas. Para cada região r_j da imagem de referência R , define-se como sua *região ajustada*, à região de S que fornecer o mínimo valor de f_{jk} ($k = 1, \dots, K$). A região ajustada de r_j é denotada por s_j^* , $j = 1, \dots, J$.

Depois de identificadas as regiões ajustadas correspondentes para todas as regiões da imagem de referência, a qualidade da segmentação pode ser computada a partir das seguintes medidas de ajuste de intensidade (M_{val}), posição (M_{pos}), dimensão (M_{dim}) e forma (M_{for}):

$$M_{val}(r_j, s_j^*) = 1 - \phi(r_j, s_j^*) \quad (11)$$

$$M_{pos}(r_j, s_j^*) = 1 - \frac{\alpha(r_j, s_j^*) + \lambda(r_j, s_j^*)}{2} \quad (12)$$

$$M_{dim}(r_j, s_j^*) = 1 - \gamma(r_j, s_j^*) \quad (13)$$

$$M_{for}(r_j, s_j^*) = g_{jj^*} \quad (14)$$

Estas medidas quantificam o ajuste individual de cada região j ($j = 1, \dots, J$). Para mensurar o ajuste de uma imagem segmentada, é computada, para cada uma das medidas de ajuste, a média aritmética sobre todas as J regiões de modo a obter um valor global para cada medida, denominadas \bar{M}_{val} , \bar{M}_{pos} , \bar{M}_{dim} , e \bar{M}_{for} . Estas medidas estão contidas no intervalo $[0, 1]$, sendo 0 o pior nível de ajuste e 1 o melhor. É possível ainda definir uma medida geral de ajuste das regiões, computando a média das citadas medidas:

$$M_{geral} = \frac{\bar{M}_{val} + \bar{M}_{pos} + \bar{M}_{dim} + \bar{M}_{for}}{4} \quad (15)$$

3.4. Análise dos resultados

Para cada segmentação realizada foram computadas as médias (sobre o conjunto de regiões da imagem de referência) das medidas de ajuste de posição (\bar{M}_{pos}), de ajuste de intensidade (\bar{M}_{val}), de ajuste de dimensão (\bar{M}_{dim}), de ajuste de forma (\bar{M}_{for}) e de ajuste geral (M_{geral}). Além disso, após a execução das 100 segmentações, para uma dada configuração de parâmetros, foram computadas a média e o desvio padrão de cada medida, denotadas por \bar{M}_{pos} , \bar{M}_{val} , \bar{M}_{dim} , \bar{M}_{for} , e \bar{M}_{geral} , respectivamente. O número médio de regiões e o tempo médio de processamento também foram utilizados na análise. Estas estatísticas foram utilizadas para identificar os valores dos parâmetros que proporcionaram o melhor resultado de segmentação para cada um dos algoritmos analisados. Por fim, estes melhores resultados foram comparados para se determinar se havia diferença significativa entre eles.

4. RESULTADOS

Nesta seção são apresentadas análises comparativas entre os resultados obtidos com o processamento de dados SAR realizados com o SegSAR e o PolSeg, para o conjunto das 100 imagens simuladas. A comparação é baseada no número médio de regiões,

no tempo médio de processamento, e nas métricas de avaliação de segmentação apresentadas na subseção 3.3.

Na Figura 2 é apresentado o número médio de regiões geradas na segmentação final dos algoritmos SegSAR e PolSeg, para diferentes valores de nível de compressão máximo e de níveis de confiança. O tempo médio para efetuar estas segmentações é apresentado na Figura 3. Percebe-se na Figura 2(a) que, para o SegSAR, a partir do nível de compressão maior que três, a quantidade de regiões geradas na segmentação diminui com o aumento do nível de confiança adotado na segmentação. Este comportamento também é observado para o PolSeg (Figura 2(b)), mas para todos os níveis de compressão. Na Figura 3(a) nota-se que o tempo de processamento do SegSAR oscilou de valores altos a valores baixos a cada nível de compressão. Para o PolSeg pode-se verificar que a partir do nível de compressão maior ou igual a cinco o tempo de processamento tende a diminuir com o aumento do nível de confiança. Em média, para todos os níveis de confiança e de compressão, o SegSAR gera aproximadamente dez vezes mais regiões, com um tempo de processamento 4,5 vezes superior ao PolSeg. Da comparação dos resultados apresentados nestas figuras pode-se afirmar que o PolSeg obteve um resultado superior ao obtido pelo SegSAR, no sentido que o PolSeg foi capaz de gerar um número de regiões mais próximo ao número de regiões contidos na imagem de referência (29 regiões) com um tempo de processamento significativamente inferior ao obtido com o SegSAR.

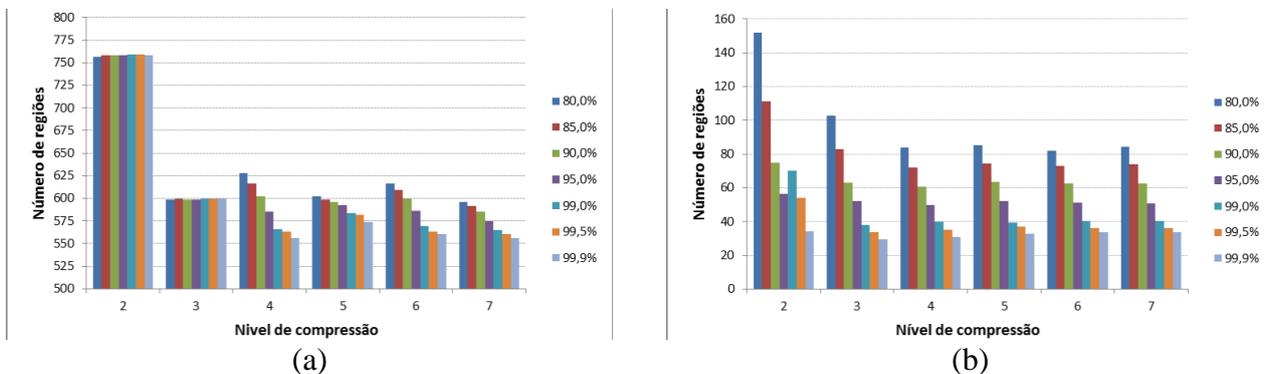


Fig. 2 - Desempenho segundo a quantidade de regiões geradas na segmentação: (a) SegSAR e (b) PolSeg.

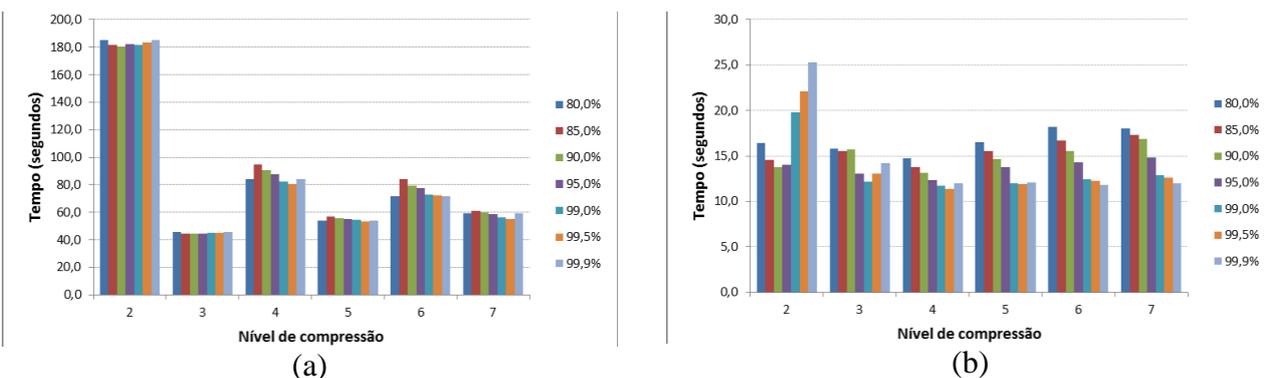


Fig. 3 - Desempenho segundo o tempo de processamento das imagens: (a) SegSAR e (b) PolSeg.

Os resultados das medidas de ajuste obtidos na aplicação dos algoritmos SegSAR e PolSeg são apresentados nas Figuras 4 a 8. Nestas figuras as curvas ilustradas nos gráficos representam os valores médios das medidas de ajuste (\bar{M}_{pos} , \bar{M}_{val} , \bar{M}_{dim} , \bar{M}_{for} , e \bar{M}_{geral}) para cada nível de confiança ao variar o nível de compressão. Estes valores médios foram calculados sobre as segmentações das 100 imagens simuladas.

A partir de uma inspeção visual dos gráficos ilustrados nestas figuras pode-se notar que, com exceção da medida de ajuste de posição obtida com o SegSAR, ambos os algoritmos apresentaram os menores valores de medidas de ajuste (piores resultados) no nível de compressão máximo igual a dois, ressaltando a importância do método hierárquico de pirâmides. A partir deste nível os valores das medidas tendem a se estabilizar.

Pode-se observar que para o SegSAR o nível de confiança praticamente não interfere nos resultados das medidas, independentemente do nível de compressão adotado. Nota-se também que ao aumentar o nível de compressão ocorre uma leve variação nas medidas, a qual se apresenta na forma de valores altos e valores baixos intercalados. Para o PolSeg, o uso de níveis de confiança com valores mais baixos acarreta em maiores valores para as medidas de ajuste, independentemente do nível de compressão adotado. A consequência direta da diminuição do nível de confiança é o aumento na quantidade de regiões, o qual pode ser constatado na Figura 2(b), e consequente aumento do tempo de processamento, conforme pode ser verificado na Figura 3(b). Nota-se ainda que com o aumento do nível de compressão ocorre um aumento nos valores das medidas, os quais tendem a se estabilizar a partir do nível de compressão igual a quatro. Este resultado indica que ao aumentar o nível de compressão, a influência do ruído *speckle*, que causa incerteza na definição das regiões dificultando a segmentação, é minimizada melhorando o desempenho do algoritmo.

A fim de constatar estatisticamente a igualdade dos valores das medidas, foram realizados testes de hipóteses para cada algoritmo separadamente. Inicialmente, estes testes foram feitos para cada nível de confiança, variando-se apenas o nível de compressão. Uma vez determinado o nível de compressão ideal, variou-se o nível de confiança para se determinar o melhor par de valores dos parâmetros nível de compressão e nível de confiança.

Para o SegSAR, os resultados destes testes mostraram que para um dado nível de confiança, os valores das medidas de ajuste de intensidade e de ajuste de posição podem ser consideradas estatisticamente iguais para praticamente todos os níveis de compressão. Para as demais medidas os testes indicaram que níveis de compressão ímpares (3, 5 ou 7) fornecem medidas de ajustes estatisticamente iguais entre si e superiores aos níveis de compressão pares. Não foi encontrado um motivo para este comportamento atípico do SegSAR. A

partir destes resultados selecionou-se o par de valores de 7 e 99,9% para os níveis de compressão e de confiança, respectivamente, devido ao menor número de regiões geradas com este par de valores.

Para o PolSeg os valores das medidas de ajuste tendem a ser considerados estatisticamente iguais a partir de níveis de compressão aproximadamente maiores ou iguais a quatro. Este fato, associado aos valores altos apresentados pelas medidas, à quantidade de regiões praticamente iguais para os níveis de compressão superiores a quatro (Figura 2(b)) e ao tempo de processamento menor (Figura 3(b)), faz com os níveis de compressão 4 ou 5 sejam considerados mais indicados para serem usados na segmentação com o PolSeg. Fixando-se o nível de compressão em quatro, os testes estatísticos indicaram que as segmentações efetuadas com níveis de confiança de 80%, 85% e 90% fornecem medidas de ajuste geral estatisticamente iguais entre si e superiores às demais. Como o número de regiões mais próximo do real e o menor tempo de processamento é geralmente obtido para maiores níveis de confiança, os níveis de confiança de 85 ou 90% são os mais indicados para a segmentação das imagens em intensidade. Portanto, para o PolSeg o par de valores de 4 e 90% para os níveis de compressão e de confiança, respectivamente, foram selecionados como os apropriados.

A Tabela 3 apresenta os valores das médias e desvios padrões das medidas de ajuste, referentes aos pares de valores selecionados dos parâmetros, assim como o resultado do teste estatístico de igualdade de médias destas medidas para os dois algoritmos de segmentação. Os resultados indicam a superioridade do algoritmo PolSeg para as medidas de intensidade, dimensão, forma e geral, e a igualdade estatística para a medida de posição.

Desta forma pode-se considerar que o PolSeg apresenta desempenho de segmentação superior ao SegSAR.

Tabela 3: Medidas de ajuste relativas aos melhores resultados de segmentação e os respectivos testes de igualdade de médias.

Medidas	SegSAR (7; 99,9%)		PolSeg (4; 90,0%)		Teste de médias	
	Médi a	DP	Médi a	DP	z	Valor- p
Intensidade	0,928	0,01 2	0,959	0,01 1	19,08	< 0,001
Dimensão	0,531	0,03 0	0,850	0,02 7	78,62	< 0,001
Posição	0,957	0,00 6	0,957	0,00 9	0,098	0,461
Forma	0,342	0,02 5	0,720	0,02 7	104,1 0	< 0,001
Geral	0,690	0,01 4	0,871	0,01 6	86,04	< 0,001

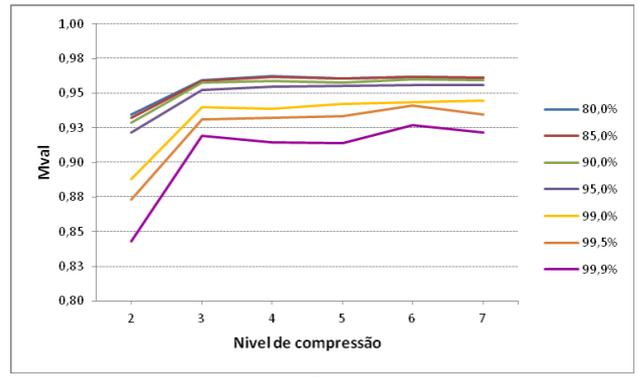
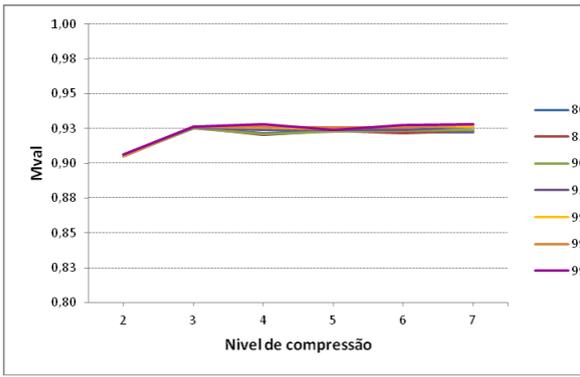


Fig. 4 - Desempenho segundo a medida de ajuste de intensidade (\bar{M}_{val}): (a) SegSAR e (b) PolSeg.

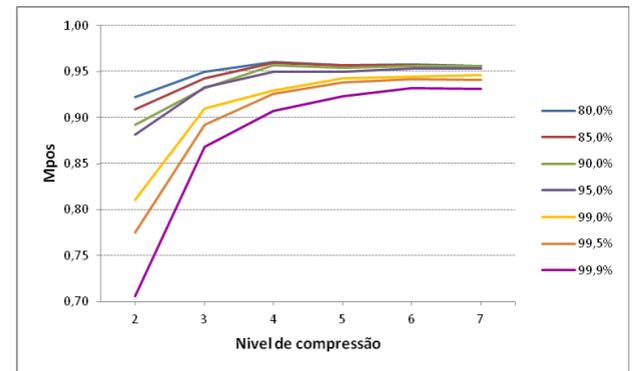
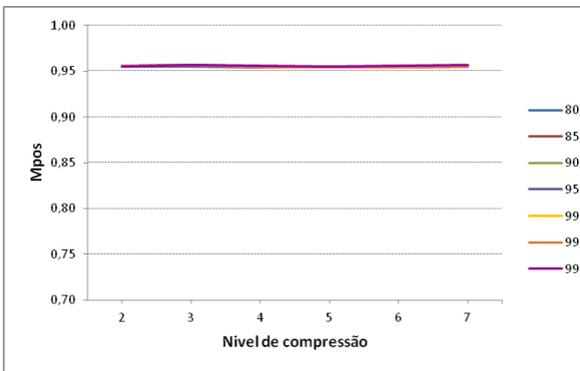


Fig. 5 - Desempenho segundo a medida de ajuste de posição (\bar{M}_{pos}): (a) SegSAR e (b) PolSeg.

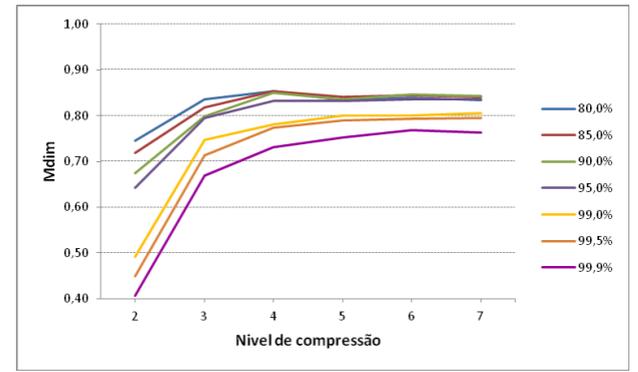
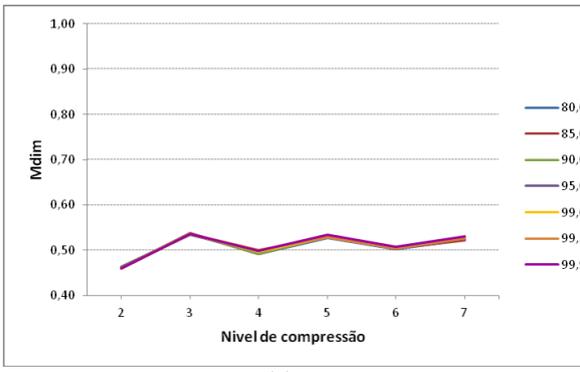
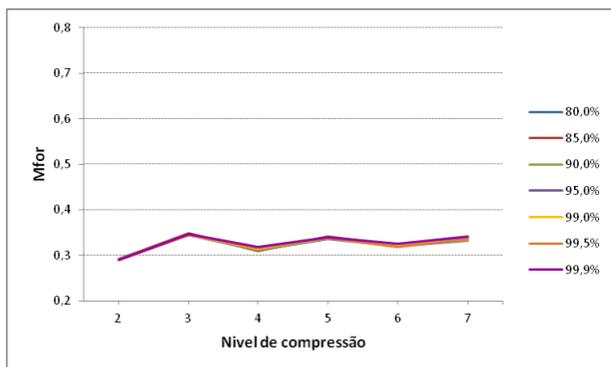
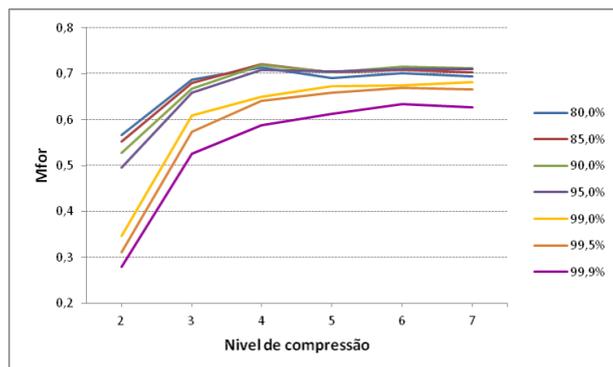


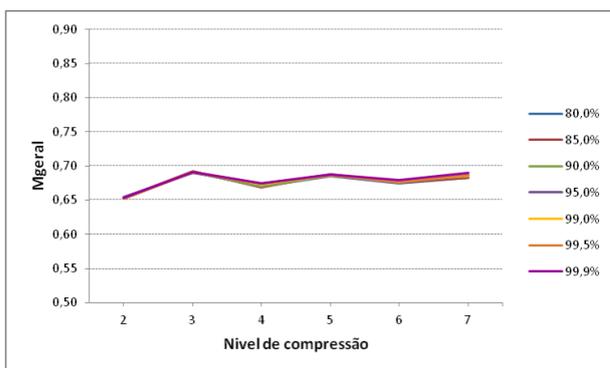
Fig. 6 - Desempenho segundo a medida de ajuste de dimensão (\bar{M}_{dim}): (a) SegSAR e (b) PolSeg.



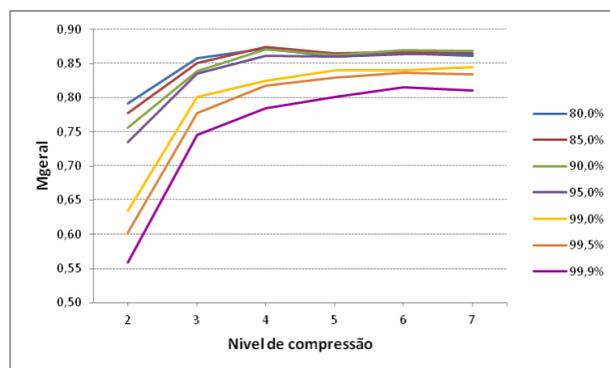
(a)



(b)

Fig. 7 - Desempenho segundo a medida de ajuste de forma (\bar{M}_{for}): (a) SegSAR e (b) PolSeg.

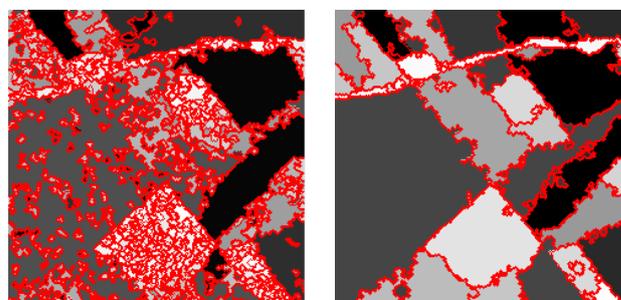
(a)



(b)

Fig. 8 - Desempenho segundo a medida de ajuste geral (\bar{M}_{geral}): (a) SegSAR e (b) PolSeg.

Na Figura 9 são ilustrados os resultados de segmentação, dos dois algoritmos, de uma das 100 imagens simuladas. Esta imagem simulada é apresentada na Figura 1, juntamente com a imagem de referência. O nível de cinza das regiões representa a intensidade média dos pixels destas regiões na imagem original. A segmentação efetuada pelo SegSAR gerou 593 regiões em um tempo de processamento de 45,83 segundos, enquanto a segmentação realizada pelo PolSeg contém 72 regiões e consumiu um tempo de processamento de 14,36 seg. Pode-se perceber visualmente que o PolSeg apresentou um melhor resultado, com regiões mais bem definidas e um número total de regiões mais próximo ao da imagem de referência. Quanto ao SegSAR, pode-se observar a geração de uma grande quantidade de regiões, caracterizando uma super-segmentação.

Regiões: 593
Tempo: 45,83 seg

(a)

Regiões: 72
Tempo: 14,36 seg

(b)

Fig. 9 - Imagem segmentada: (a) SegSAR e (b) PolSeg.

5. CONCLUSÕES

Neste trabalho foram descritos e comparados dois algoritmos de segmentação de imagem SAR, denominados SegSAR e PolSeg. Ambos os algoritmos possuem como características comuns serem híbridos, multibandas, multi-níveis e hierárquicos. O PolSeg ao contrário do SegSAR é baseado, para dados monocanais, nas propriedades da distribuição Gama em todos os seus testes estatísticos. Os desempenhos dos algoritmos

foram avaliados através das segmentações de um conjunto de imagens SAR monocanais simuladas, no formato de intensidade.

Os resultados apresentados mostraram, para as imagens estudadas, que os dois algoritmos devem ser usados com níveis de compressão maiores que dois, ressaltando a relevância do método hierárquico de pirâmide na segmentação de imagens SAR. Os resultados de segmentação dos algoritmos PolSeg e SegSAR, quando comparados com a imagem de referência (*phantom*), mostraram que as regiões geradas pela segmentação do PolSeg apresentaram formas mais bem definidas, intensidades médias e dimensões mais próximas da “verdade”. Estas medidas foram, respectivamente, 111%, 3% e 60% melhores que as obtidas pelo SegSAR. O desempenho dos algoritmos quando medido através da posição das regiões foi estatisticamente igual para ambos os algoritmos.

A avaliação das segmentações baseada em outros critérios tais como o número total de regiões da imagem segmentada e o tempo de processamento indicam que o PolSeg também possui melhor desempenho que o algoritmo SegSAR. O PolSeg produz, em média, 10 vezes menos regiões que o SegSAR em um tempo de processamento 4,5 vezes menor.

Portanto, mediante os critérios adotados, pode-se afirmar que o algoritmo de segmentação PolSeg é superior ao algoritmo SegSAR.

AGRADECIMENTOS

Os autores agradecem ao CNPq (Processo: 302966/2009-9) e à Fapesp (Processo:08/58112-0 e 08/57719-9) pelo suporte financeiro.

REFERÊNCIAS BIBLIOGRÁFICAS

AYED, I. B.; MITICHE, A.; BELHADJ, Z. Multiregion Level-Set Partitioning of Synthetic Aperture Radar Images. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 27, n. 5, p. 793-800, 2005.

BEAULIEU, J. M.; TOUZI, R. Segmentation of textured polarimetric SAR scenes by likelihood approximation. **IEEE Transactions on Geoscience and Remote Sensing**, v. 42, n. 10, p. 2063-2072, 2004.

BENBOUDJEMA, D.; TUPIN, F.; PIECZYNSKI, W.; SIGELLE, M.; NICOLAS, J. M. Unsupervised segmentation of SAR images using Triplet Markov fields and Fisher noise distributions. **IEEE International Geoscience and Remote Sensing Symposium (IGARSS)**, 2007, Barcelona, Spain. **Proceedings**. p. 3891-3894, 2007.

BOMBRUN, L.; VASILE, G.; GAY, M.; TOTIR, F. Hierarchical segmentation of polarimetric SAR images using heterogeneous cluster models. **IEEE Transactions on Geoscience and Remote Sensing**, v. 49, n. 2, p. 726-737, 2011.

CAVES, R.; QUEGAN, S.; WHITE, R. G. Quantitative comparison of the performance of SAR segmentation algorithms. **IEEE Transactions on Image Processing**, v. 7, n. 11, p. 1534-546, 1998.

CONRADSEN, K.; NIELSEN, A. A.; SCHOU, J.; SKRIVER, H. A test statistic in the complex Wishart distribution and its application to change detection in polarimetric SAR data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 1, p. 4-19, 2003.

COOK, R.; MC CONNELL, I.; STEWART, D.; OLIVER, C. MUM (Merge Using Moments) segmentation for SAR images. **EurOpto SAR Data Processing for Remote Sensing**, Rome, Italy, 1994. p. **Proceedings**. 92-103, 1994.

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.2, p. 2121-2149, 1992.

FREITAS C.C.; FRERY, A. C. ; CORREIA, A. H. The polarimetric G distributions for SAR data analysis. **Environmetrics**, v. 16, n.1, p. 13-31, 2005.

FRERY A. C.; MULLER, H. J.; YANASSE, C. C. F.; SANT'ANNA, S. J. S. A model for extremely heterogeneous clutter. **IEEE Transactions on Geoscience and Remote Sensing**, v. 35, n. 3, p. 648-659. 1997.

FRERY, A. C.; CORREIA, A. H. ; FREITAS, C. C. Classifying Multifrequency Fully Polarimetric Imagery With Multiple Sources of Statistical Evidence and Contextual Information. **IEEE Transactions on**

Geoscience and Remote Sensing, v. 45, n. 10, p. 3098-3109, 2007.

GONZALEZ, R. C.; WOODS, R. E. **Digital image processing**. Addison-Wesley, New York, 2002. 976 p.

GOODMAN, N. R. Statistical analysis based on a certain multivariate complex Gaussian distribution. **Annals of Mathematical Statistics**, v. 34, n. 1, p. 152-177, 1963.

HÄNSCH, R.; JÄGER, M.; HELLWICH, O. Clustering by deterministic annealing and Wishart based distance measures for fully-polarimetric SAR-data. 7th European Conference on Synthetic Aperture Radar (EUSAR 2008), 2008. Graf-Zeppelin-Haus, Friedrichshafen, Germany. **Proceedings**. p. 419-422, 2008.

JAIN, A. K. **Fundamentals of digital image processing**. New Jersey, Prentice-Hall, 1989. 569p.

LEE, J. S.; JURKEVICH, I. Segmentation of SAR images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 27, n. 6, p. 674-680, 1989.

LOMBARDO, P.; OLIVER, C. Optimal classification of polarimetric SAR images using segmentation. IEEE Radar Conference, Long Beach, California, 2002. **Proceedings**. p. 8-13, 2002.

LUCCA, E. V. D. **Avaliação e comparação de algoritmos de segmentação de imagens de radar de abertura sintética**. 1998. 211 p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1998.

MARINHO, R. R.; PARADELLA, W. R.; RENNÓ, C. D.; OLIVEIRA, C. G. Aplicação de imagens SAR orbitais em desastres naturais: mapeamento das inundações de 2008 no vale do Itajaí, SC. **Revista Brasileira de Cartografia**, n. 64/5, p. 565-579, 2012.

OLIVER, C.; QUEGAN, S. **Understanding Synthetic Aperture Radar Images**. North Carolina, SciTech Publishing, 2004. 479 p.

ORBANZ, P. E.; BUHMANN, J. M. SAR images as mixtures of Gaussian mixtures. International Conference on Image Processing, Genoa, Italy, 2005. **Anais**. p. II-209-12, 2005.

PARADELLA, W. R.; MURA, J. C.; GAMA, F. F.; SANTOS, A. R. Radar interferometry in surface deformation detection with orbital data. **Revista Brasileira de Cartografia**, n. 64/6, p. 797-811, 2012.

PELLIZZERI, T.; LOMBARDO, P.; OLIVER, C.; SCIOTTI, M.; MELONI, M.; McConnell, I. A comparison of statistical segmentation technique for polarimetric SAR: region growing versus simulated annealing. POLinSAR 2003: Workshop on Applications of SAR Polarimetry and Polarimetric Interferometry, Frascati, Italy, 2003. **Proceedings**. 2003.

ROSENFELD, A.; KAK, A. **Digital picture processing - vol. 2**, Florida, Academic Press, 1982. 349 p.

SALDANHA, M. F. S.; FREITAS, C. C.; SANT'ANNA, S. J. S. Single channel SAR image segmentation using gamma distribution hypothesis test. IEEE International Geoscience and Remote Sensing Symposium, Munich, Germany, 2012. **Proceedings**. p. 4323-4326, 2012.

SERVELLO, E. L.; KUPLICH, T. M.; SHIMABUKURO, Y. E. Análise preliminar de imagens SAR polarimétricas e potencial de aplicações em florestas tropicais. **Revista Brasileira de Cartografia**, n. 62/03, p. 551-562, 2010.

SHI, Q.; LI, Y.; ZHANG, Y. A New Automatic Segmentation for Synthetic Aperture Radar Image. International Symposium on Intelligent Multimedia Video and Speech Processing, Hong Kong, China, 2004. **Proceedings**. p. 739-742, 2004.

SHUAL, Y.; Sun H.; XU, G. A fast segmentation scheme based on level set for SAR images. 1st Asian and Pacific Conference on Synthetic Aperture Radar, Huangshan, China, 2007. **Proceedings**. p. 503-506, 2007.

SKRIVER, H.; SCHOU, J.; NIELSEN, A. A.; CONRADSEN, K. Polarimetric segmentation using the complex Wishart test statistic. IEEE International Geoscience and Remote Sensing Symposium, Toronto, Canada, 2002. **Proceedings**. v.2, p. 1011-1013, 2002.

SMITH, D. M. Speckle reduction and segmentation of synthetic aperture radar images.

International Journal of Remote Sensing, v. 17, n. 11, p. 2043-2057, 1996.

SOUSA JUNIOR, M. A. **Segmentação multi-níveis e multi-modelos para imagens de radar e óptica**. 2005. 136 p. (INPE-14466-TDI/1147). Tese (Doutorado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2005.

TUR, M.; CHIN, K. C.; GOODMAN, J. W. When is speckle noise multiplicative? **Applied Optics**, v. 21, n. 7, p. 1157-1159, 1982.

WEISENSEEL, R. A.; KARL, W. C.; CASTAÑON, D. A.; BROWER, R. C. MRF-based algorithms for segmentation of SAR images. International Conference on Image Processing, Chicago, Illinois, 1998. **Proceedings**. p. 770-774, 1998.

WHITE, R. G. **Low-level segmentation of noise imagery**. DRA, Royal Signal and Radar Establishment: Works (Memorandum 3900), 1986. 50 p.

XU, H.; TIAN, Z.; DING, M. Graph Spectral Segmentation of SAR Image Based on Information Similarity Measure (FSKD 2007), 2007. 4th International Conference on Fuzzy Systems and Knowledge Discovery, Haikou, China, 2007. **Proceedings**. p. 708-711, 2007.

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. 31 p.

ZAART, A. E.; ZIOU, D.; WANG, S.; JIANG, Q.; BÉNIÉ, G. B. SAR Images Segmentation Using Mixture of Gamma Distribution. 12th Vision Interface Conference, Trois-Rivières, Canada 1999. **Proceedings**. p. 125-130, 1999.

SINGLE CHANNEL SAR IMAGE SEGMENTATION USING GAMMA DISTRIBUTION HIPOTHESIS TEST

Marcus F. S. Saldanha, Corina da Costa Freitas, Sidnei J. S. Sant'Anna

National Institute for Space and Research, São José dos Campos - SP, Brazil

ABSTRACT

Segmentation is a low-level operation extremely important for the extraction of information from digital images. A commonly adopted approach for the development of segmentation algorithms is that based on statistical modeling of data. For SAR images, the precise knowledge of the statistical properties and the adoption of an appropriate modeling are considered essential to obtain reliable results. Depending on the type of data and the degree of homogeneity of the imaged target, different statistical distributions can be used to obtain an appropriate modeling. Within this context, this paper aims to present the results obtained in the segmentation of a single channel SAR data in the intensity format using two different algorithms. The first, called SegSAR [1] uses the Gaussian and Gamma distributions to represent the data and the statistical tests are based on these distributions. The second algorithm, called PolSeg, adopts the Wishart distribution as the model for the polarimetric data. For the case of segmenting a single channel data this algorithm uses the test on equality of two Gamma parameters.

Index Terms— SAR data segmentation, Gamma distribution, statistical modeling

1. INTRODUCTION

The segmentation is performed using characteristics of similarity and discontinuity existing in the image targets. In most cases, this implies the use of probability density functions for modeling the data. The optimal result of segmentation process, when using this approach, is directly linked to the choice of appropriate model to represent the data. Different distributions can be applied for SAR images, depending on the type of data format (amplitude, intensity or complex) and the number of looks. Furthermore, the degree of homogeneity of the surface targets contained in a scene can also

influence the choice of a more appropriate statistical model [2].

The most common approach to the development of algorithms for segmentation of SAR data is to assume that the targets contained in the scene are homogeneous. This approach has been adopted in various algorithms, such as Merge Using Moments - MUM [3] and SegSAR [1]. The first was originally designed to work with single channel data, and subsequently processed to handle multi channel SAR data [4]. The second was originally designed to process both single channel SAR data and multi channel data. Both algorithms use region growing techniques for performing the segmentation on intensity data SAR. However, these two algorithms do not use a model based only on the Gamma distribution, which is more suitable to represent SAR data in the intensity format.

As an extension of the SegSAR, a new segmentation algorithm, called PolSeg, is under development. It is based on the polarimetric SAR data properties, modeling the complex covariance matrix by the Wishart distribution, and uses the test on equality of two complex Wishart matrices, as proposed in [5]. In the special case, where the covariance matrix is formed by a single element, which is equivalent to a single intensity data, the algorithm generates the segments using a hypothesis test based on the Gamma distribution. The objective of this work is to present the results obtained by segmentation of single channel SAR data in intensity format using PolSeg algorithm, and compare them with those obtained by SegSAR algorithm.

2. SEGMENTATION ALGORITHMS

The PolSeg algorithm is an extension of SegSAR, since the latter was design to deal with single channel data, while the former uses polarimetric images. Both algorithms use known segmentation techniques such as region growing, split and merging of regions, with heuristics that perform the adjustment of borders and detect

regions that are not homogenous. In addition, the algorithms have been developed to perform multi-level and hierarchical processing, working with compressed images in several levels, according to the hierarchical pyramid criterion [6].

The PolSeg algorithm is designed to perform segmentation into three steps, which are split into modules for computational processing.

The first step consists of the *Input Data*, *Generation of the Covariance Matrix*, *Image Compression* and *Segmentation* modules. In the *Input Data* module, the polarimetric SAR image is loaded. In this module are calculated the minimum and maximum number of possible compression levels, and it is defined, by the user, the parameters to be used in the segmentation process (number of compressions, confidence level for statistical tests, the minimum number of pixels to form segments, and maximum number of growth cycles for the region growing). The *Generation of the Covariance Matrix* module consists of computing the covariance matrix based on the input data. The covariance matrix is then compressed in the *Image Compression* module, according to the level selected by the user. This compressed data is segmented, in the *Segmentation* module, by a region growing process, using a hypothesis test based on the Gamma distribution for covariance matrix formed by a single element, or on the Wishart distribution for the highest order covariance matrix.

The second step consists of the modules: *Decompression of the image* at one level, where the results obtained in the *Segmentation* module is decompressed to be used as the basis for subsequent processing modules; *Edges Adjustment*, where the regions segmented in the upper level have their contours "refined"; *Homogeneity Analysis*, where the segments are subjected to a test of homogeneity considering the Gamma distribution; *Segmentation of Heterogeneous Regions*, where the segments rejected in the analysis of homogeneity are split and subjected to a new region growing process; and, *Regions Merging*, where a segment is merged to another adjacent segment, depending on a hypothesis test result. The second step processing flow is repeated until the compression level reaches the same level of the input image.

The third step consists of *Minimum Area* and *Output Data* modules. In the *Minimum Area* module segments smaller than a threshold (number of pixels) are incorporated by neighbor regions. The final segmented image is stored in the hard disk during the *Output Data* module.

3. MODELING INTENSITY DATA AND STATISTICAL TEST

Generally, the modeling of intensity data for homogenous regions is made by a Gamma distribution $\Gamma(n, \beta)$, where n represents the equivalent number of looks of the SAR image and β its intensity mean [2]. Intensity SAR segmentation algorithms are usually based on this assumption in order to perform hypothesis tests during the segmentation process, as, for example, during the region growing stages of SegSAR and PolSeg algorithms. Sections 3.1 and 3.2 present brief descriptions of the tests for a single channel intensity data, used during the region growing processes of these algorithms.

3.1. SegSAR tests

The SegSAR algorithm considers three different situations during the region growing process: pixel to pixel, pixel to region, and region to region merging. There is a specific test for each of these situations. The merging of two pixels is performed using the Euclidean distance and a similarity threshold. A test based on the Gamma distribution is employed to merge a pixel to a region, consisting of determining the probability that this pixel belongs to the region. Two regions are merged by the algorithm by applying the t-Student's test, which is used to compare the equality of means for Gaussian distributed data. The SegSAR algorithm justifies the application of t-tests for segmenting compressed data, since the Gamma distribution approaches a Gaussian distribution for n sufficiently large [7].

3.2. PolSeg statistic test for single channel data

For the case of single channel Gamma distributed data, the random variable representing the sum of the m intensity data values has also a Gamma distribution with parameters n and β . Note that n depends on m and on the number of looks of the input intensity data, and β is related to the mean value of the intensity data.

Consider now two regions, having estimated covariance matrix represented by the random variables X and Y . The random variables $n_x X$ and $n_y Y$ are Gamma distributed, $\Gamma(n_x, \beta_x)$ and $\Gamma(n_y, \beta_y)$, with probability density function given by

$$f(z; n_z, \beta_z) = \frac{1}{\Gamma(n_z)} \frac{1}{\beta_z^{n_z}} z^{n_z-1} \exp\left\{-\frac{z}{\beta_z}\right\}, \quad (1)$$

where z can assume x or y .

In this way, the PolSeg test for grouping two regions consists of a test for equality of the two parameters β_x and β_y . Under the null hypothesis $H_0: \beta_x = \beta_y = \beta$, the ratio $n_x Y / (n_y X)$ has a Fisher's F distribution, so that

$$\frac{n_x}{n_y} \frac{Y}{X} \sim F(2n_y, 2n_x) \quad (2)$$

The critical regions of the test, with a significance level α , present the form

$$\frac{n_x}{n_y} \frac{Y}{X} \leq q_1 \quad \text{or} \quad \frac{n_x}{n_y} \frac{Y}{X} \geq q_2 \quad (3)$$

where q_1 and q_2 are determined by means of $\alpha/2$ quantiles in the F -distribution.

The PolSeg algorithm uses this test described above to obtain the image segmentation of SAR data, during the region growing process, to merge two pixels, or a pixel to region or two regions. Note that n_x and n_y values will be different for each compression level. This algorithm computes these values each level taking into account the number of looks of the input intensity image and the pixel spatial autocorrelation.

4. RESULTS

The selected study area covers part of the Paulínea municipality at São Paulo state, Brazil. This region is mainly characterized by agriculture fields and areas of environmental preservation. A four-look and L-band (1.27 GHz) fully polarimetric SAR image acquired in October 2005 by sensor aboard the aircraft R99-B of the Brazilian Air Force was used to evaluate the segmentation algorithms. The HH polarization channel sizing 400x400 pixels is shown in Figure 1.

The HH SAR image was segmented by SegSAR and by PolSeg using the same compression parameters, confidence levels and minimum area. For the compression was adopted three levels, where each pixel of the compressed image is represented by the arithmetic mean intensity of 256 pixels in the original image. The hypothesis tests were performed using 95% as confidence level and 20 pixels was considered the minimum area possible for each final segment.

The result of the processing performed by SegSAR is shown in Figure 2, where 2,505 segments were generated. The segmented image

presents regions with 63.8 pixels of average size of per segment, and consumed 302.02 seconds to perform segmentation. Alternatively, the PolSeg processed the same image in 526.25 seconds, generating an image having 2,259 segments with average size of 70.82 pixels per segment. This segmented image can be seen in Figure 3. The value of normalized log measure for entire image, as suggested by [8], was used to quantitatively evaluate the performance of the algorithms. The normalized log measured obtained by SegSAR algorithm was -0.475, while the value obtained by PolSeg was -0.466. From these values (global measures) it can be seen that PolSeg algorithm presents better segmentation performance than SegSAR algorithm.



Figure 1 – Intensity SAR image of the R99-B sensor.

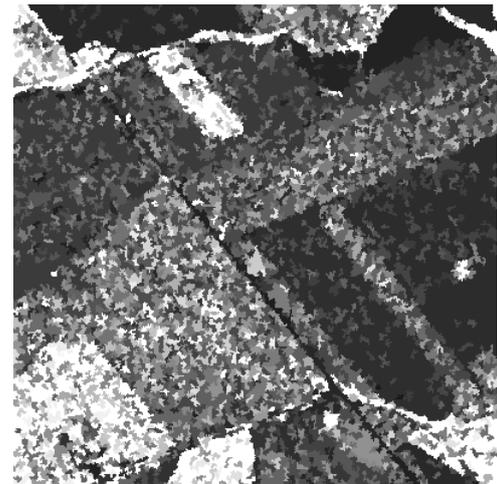


Figure 2 – SegSAR segmentation result (mean intensity of segments).

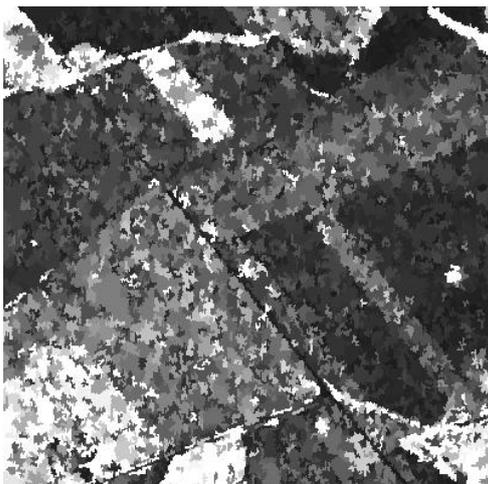


Figure 3 – PolSeg segmentation result (mean intensity of segments).

5. CONCLUSIONS

The preliminary results show that the PolSeg algorithm generated segmented image with fewer segments than the SegSAR does. On the other hand, the former algorithm spent more time to generate the result than the later one. This fact shows that the statistical test for two Gamma distributions is less restrictive than the test statistic employed by the SegSAR algorithm. The quantitative analysis (through the normalized log intensity) indicates that PolSeg algorithm presents better performance than SegSAR. From these preliminary evaluations it can be concluded that statistical test based on the Gamma distribution, for segmentation and grouping of regions, is leading to satisfactory results. However, the fully potentiality of this statistical test must be better evaluated by using simulated images and other segmentation performance metrics.

6. REFERENCES

- [1] M. A. Sousa Junior *Segmentação multi-níveis e multi-modelos para imagens de radar e óptica*, Thesis (Doctorate in Applied Computing), National Institute for Space Research, São José dos Campos, Brazil, (INPE-14466-TDI/1147), 2005.
- [2] A. C. Frery, H. J. Müller, C.C.F. Yanasse, and S. J. S. Sant'Anna A model for extremely heterogeneous clutter, *IEEE Transactions on Geoscience and Remote Sensing*, Piscataway, v. 35, n. 3, p. 648-659, 1997.
- [3] C. Oliver, and S. Quegan *Understanding Synthetic Aperture Radar Images*. Raleigh, North Carolina: SciTech Publishing, Inc., 2004.
- [4] R. G. Caves, I. McConnell, R. Cook, and S. Quegan Multi-channel SAR segmentation: algorithms and application, *Image Processing for Remote Sensing*, IEE Colloquium, Conference Publications, p. 2/1 - 2/6, 1996.
- [5] K. Conradsen, A. A. Nielsen, J. Schou, and H. Skriver A test statistic in the complex Wishart distribution and its application to change detection in polarimetric SAR data. *IEEE Transactions on Geoscience and Remote Sensing*, v. 41, n. 1, p. 4-19, 2003.
- [6] R. Jain, R. Kasturi, and B. G. Schunck *Machine vision*, McGraw-Hill, New York, 1995.
- [7] C. C. F. Yanasse, A. C. Frery, and S. J. S. Sant'Anna *Stochastic distributions and the multiplicative model: relations, properties, estimators and applications to SAR image analysis*. National Institute for Space Research, São José dos Campos, Campos, Brazil, (INPE-5630-NTC/318), 1995.
- [8] R. Caves, S. Quegan, and White R. Quantitative comparison of the performance of SAR segmentation algorithms, *IEEE Trans. Image Processing*, vol. 7, pp. 1534-1546, 1998.