



Revista Brasileira de Cartografia (2014) N^o 66/1, p. 29-43
Sociedade Brasileira de Cartografia, Geodésia, Fotogrametria e Sensoriamento Remoto
ISSN: 1808-0936

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@dpi.inpe.br, corina@dpi.inpe.br, sidnei@dpi.inpe.br

²Diretoria de Serviço Geográfico - DSG

Quartel General do Exército, Bloco “F”, 2^o Piso, Setor Militar Urbano – 70630-901 – Brasília – DF – Brasil

saldanha@dsg.eb.mil.br

Recebido em 31 de Março, 2013/ Aceito em 02 de Novembro, 2013

Received on March 31, 2013/ Accepted on november 02, 2013

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.

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 b . Neste caso, n depende de m e do número de visadas do dado de intensidade da entrada, e o parâmetro b 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, $G(n_x, b_x)$ e $G(n_y, b_y)$, com função densidade de probabilidade dada por:

$$f(z; n_v, \beta_v) = \frac{n_v^{n_v}}{\Gamma(n_v)\beta_v^{n_v}} z^{n_v-1} \exp\left\{-\frac{n_v z}{\beta_v}\right\} \quad (1)$$

onde, n pode assumir x ou y .

Neste caso, o teste usado no PolSeg para agrupar duas regiões consiste de um teste de igualdade dos parâmetros b_x e b_y . Pode-se provar que, sob a hipótese nula, $H_0: b_x = b_y = b$, a razão \bar{Y}/\bar{X} possui uma distribuição F, de modo que:

$$\frac{\bar{Y}}{\bar{X}} \sim F(2n_y, 2n_x) \quad (2)$$

A região crítica do teste se apresenta na forma:

$$\frac{\bar{Y}}{\bar{X}} \leq q_1 \text{ ou } \frac{\bar{Y}}{\bar{X}} \geq q_2 \quad (3)$$

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,

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

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.

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.

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.

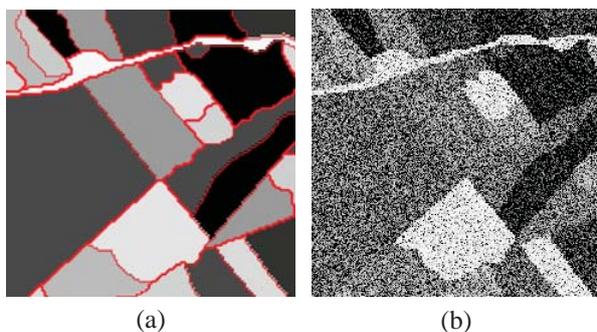


Fig. 1 - Imagens originais (a) de referência (*phantom*) com os contornos das regiões (b) SAR simulada.

Tabela 2: Intensidades médias das classes utilizadas na simulação dos dados

Classes	Intensidade Média (x 10 ⁻⁴)
1	7,61
2	128,59
3	29,63
4	14,06
5	48,93
6	18,70

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,...,*J*, e as regiões de *S* denotadas por *s_k*, *k* = 1,...,*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,...,*J*, e *k* = 1,...,*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 $m_x(t)$ e $m_y(t)$ representam, respectivamente, os valores médios das abcissas e das ordenadas da região t , (isto é, $(m_x(t), m_y(t))$ representa o centro geométrico da região t); $d(t)$ é o número de *pixels* da região t ; e $m_v(t)$ é o nível de cinza médio dos *pixels* da região t . Portanto, $a(r_j, s_k)$ e $l(r_j, s_k)$ representam, respectivamente, as distâncias entre as coordenadas dos centros geométricos das regiões r_j e s_k ; $g(r_j, s_k)$ 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 $f(r_j, s_k)$ 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 \overline{M}_{pos} , \overline{M}_{val} , \overline{M}_{dim} , \overline{M}_{for} , e \overline{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.

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 (\overline{M}_{pos} , \overline{M}_{val} , \overline{M}_{dim} , \overline{M}_{for} , e \overline{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

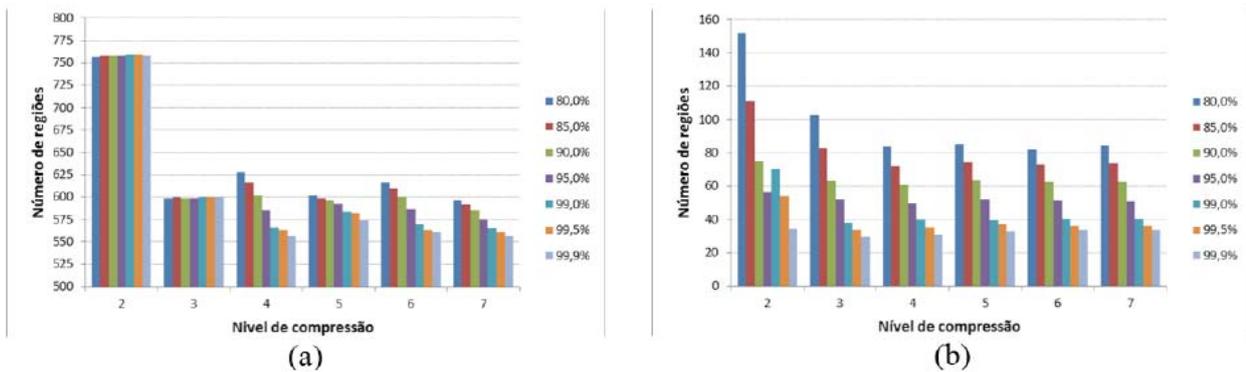


Fig. 2 - Desempenho segundo a quantidade de regiões geradas na segmentação: (a) SegSAR e (b) PolSeg.

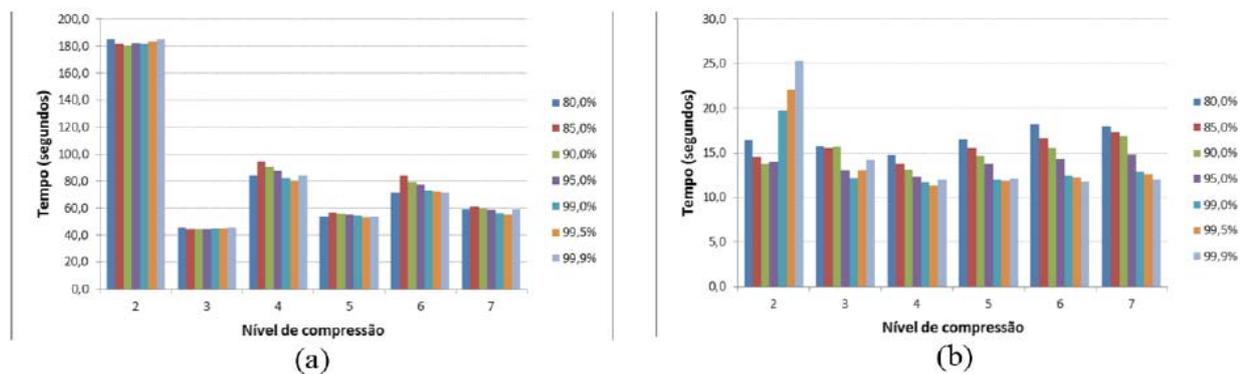


Fig. 3 - Desempenho segundo o tempo de processamento das imagens: (a) SegSAR e (b) PolSeg.

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

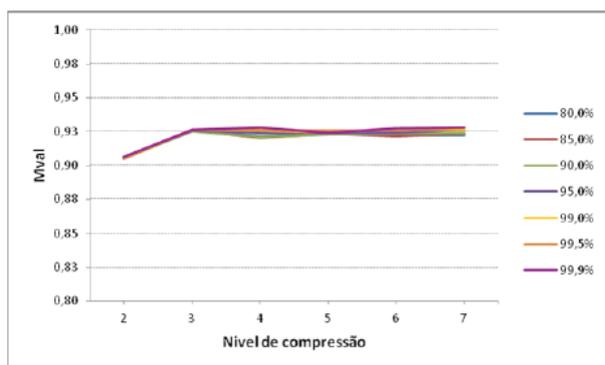
Tabela 3: Medidas de ajuste relativas aos melhores resultados de segmentação e os respectivos testes de igualdade de médias

Medidas	SegSAR (7; 99,9%)		PolSeg (4; 90,0%)		Teste de médias	
	Média	DP	Média	DP	z	Valor-p
Intensidade	0,928	0,012	0,959	0,011	19,08	< 0,001
Dimensão	0,531	0,030	0,850	0,027	78,62	< 0,001
Posição	0,957	0,006	0,957	0,009	0,098	0,461
Forma	0,342	0,025	0,720	0,027		< 0,001
Geral	0,690	0,014	0,871	0,016	86,04	< 0,001

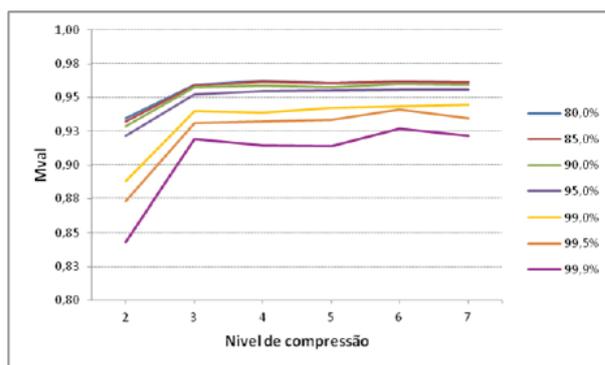
teste estatístico de igualdade de médias destas medidas para os dois algoritmos de segmentação. Os resultados indicam a superioridade do algoritmo PolSeg para as medidas de intensidade, dimensão, forma e geral, e a igualdade estatística para a medida de posição.

Desta forma pode-se considerar que o PolSeg apresenta desempenho de segmentação superior ao SegSAR.

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

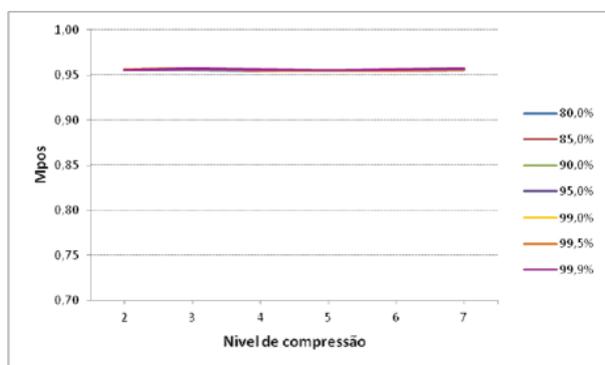


(a)

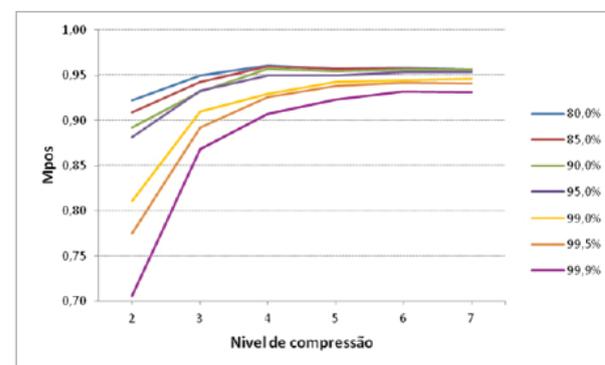


(b)

Fig. 4 - Desempenho segundo a medida de ajuste de intensidade (\bar{M}_{val}): (a) SegSAR e (b) PolSeg.

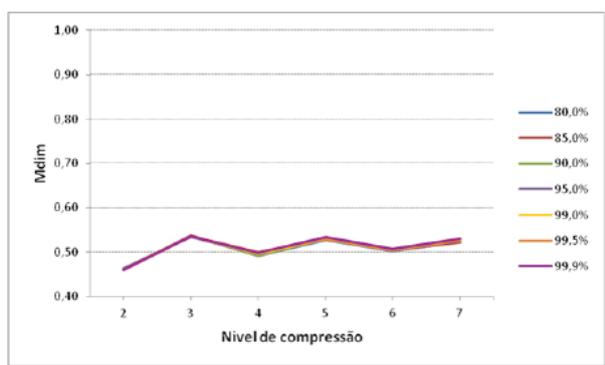


(a)

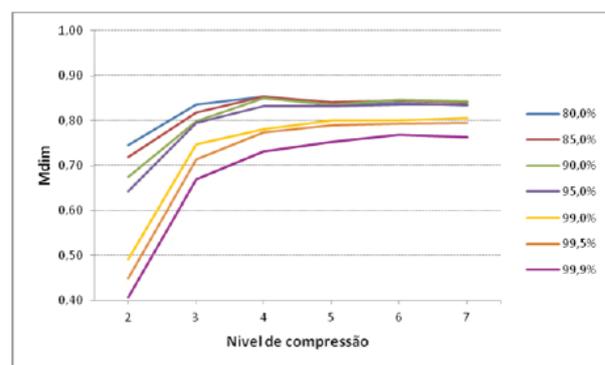


(b)

Fig. 5 - Desempenho segundo a medida de ajuste de posição (\bar{M}_{pos}): (a) SegSAR e (b) PolSeg.



(a)



(b)

Fig. 6 - Desempenho segundo a medida de ajuste de dimensão (\bar{M}_{dim}): (a) SegSAR e (b) PolSeg.

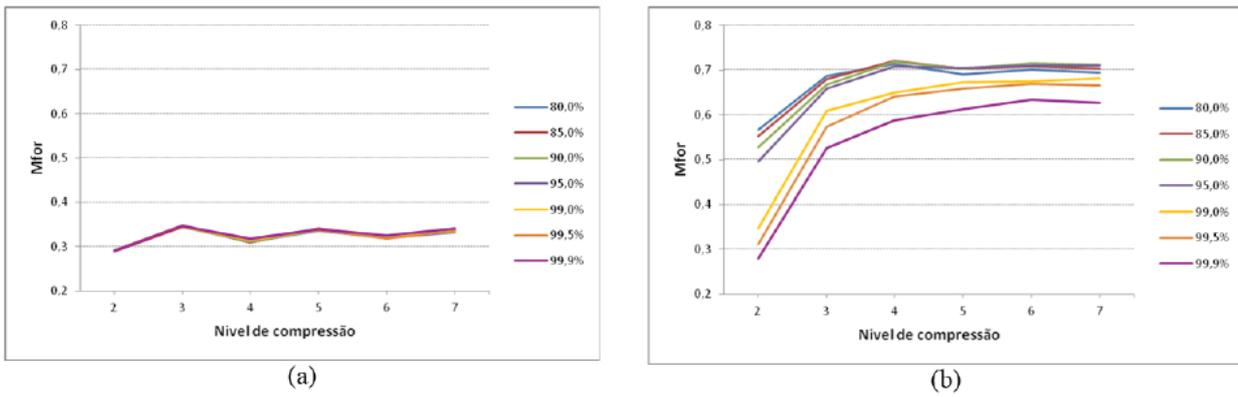


Fig. 7 - Desempenho segundo a medida de ajuste de forma (\bar{M}_{for}): (a) SegSAR e (b) PolSeg.

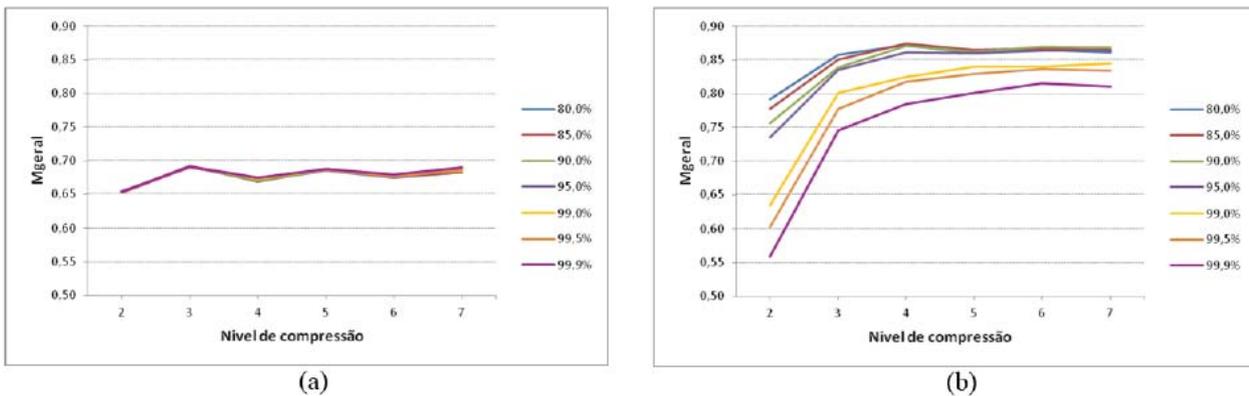


Fig. 8 - Desempenho segundo a medida de ajuste geral (\bar{M}_{geral}): (a) SegSAR e (b) PolSeg.

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.

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

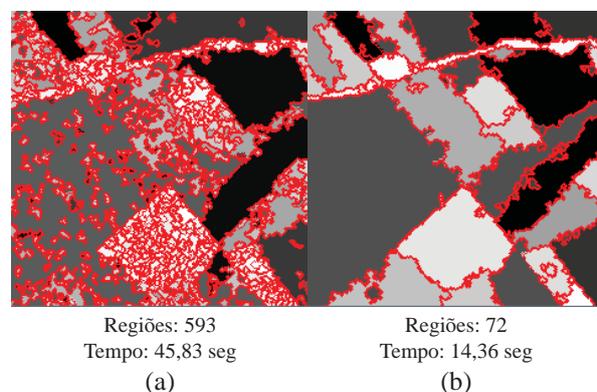


Fig. 9 - Imagem segmentada: (a) SegSAR e (b) PolSeg.

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.
- SHUAI, 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.