

## **Avaliação quantitativa do SegSAR através de medidas de borda e regiões em imagens ópticas sintéticas**

Graziela Balda Scofield  
Sidnei João Siqueira Sant'Anna  
Corina da Costa Freitas  
Luciano Vieira Dutra

Instituto Nacional de Pesquisas Espaciais - INPE  
Caixa Postal 515 - 12245-970 - São José dos Campos - SP, Brasil  
{graziela,sidnei,corina,dutra}@dpi.inpe.br

**Abstract.** SegSAR is a hierarchical segmentation algorithm where “region growing” is used in the highest compression level and “split and merge” technique is used in the intermediate levels. Also specially developed border refinement algorithm is applied to each level, before the “split and merge” procedure application, to enhance the regions frontiers resolution. To evaluate SegSAR performance 3 test sets of 100 optical images following Gaussian distribution with same standard deviation varying expected values were created. Each set of test data was created with region average difference equal to 0.5, 1 and 2 of the adopted standard deviation. The segmented images were compared with the reference one. Then border and region fitness quantitative measures were applied. The maximum compression levels 3, 4 and 5 showed the best performance for the 3 data sets.

**Palavras-chave:** remote sensing, image segmentation, sensoriamento remoto, segmentação de imagens.

### **1. Introdução**


A segmentação é um dos primeiros passos na análise de uma imagem. É um processo de agrupamento dos pixels de uma imagem em partições ou regiões adjuntas de acordo com algum critério de agrupamento como intensidade, média, contraste ou textura. Devido à importância da segmentação, vários algoritmos têm sido desenvolvidos com o intuito de prover de forma automática o particionamento de uma imagem. Entre eles podem ser citados o algoritmo de crescimento de regiões presente no SPRING (Câmara et al., 1996), MUM (Cook et al., 1994), RWSEG (White, 1986) e o SegSAR (Sousa Jr, 2005), entre outros.

A correta localização das regiões que representam feições distintas do terreno, é fundamental em várias aplicações de sensoriamento remoto. No entanto, não existe um algoritmo de segmentação ideal em sua formulação e/ou implementação. Estes algoritmos subsegmentam ou supersegmentam uma dada imagem. Desta forma, se faz necessário avaliar e quantificar o desempenho dos algoritmos de segmentação. Diversos métodos foram desenvolvidos para avaliar e comparar o desempenho de algoritmos de segmentação do ponto de vista de suas limitações, vantagens, aplicabilidade em relação às regiões (Caves et al., 1998; Delves et al., 1992 e Quegan et al., 1988) e às bordas (Pratt, 1991; Román-Roldán et al., 2001 e Neubert and Meinel, 2001).

O objetivo deste trabalho é avaliar o desempenho do segmentador SegSAR com imagens ópticas simuladas. A avaliação é realizada através das medidas quantitativas de ajuste de região propostas por Delves et al. (1992) e também utilizando-se medidas de qualidade de bordas. Estas medidas são obtidas pela comparação das segmentações geradas pelo algoritmo SegSAR com uma segmentação de referência, suposta como verdade.

## 2. Dados

Para avaliar o desempenho do SegSAR quando aplicado às imagens ópticas foram criados três conjuntos de 100 imagens. As imagens geradas sinteticamente possuem tamanho de 260 x 260 pixels, contendo apenas duas classes de alvos, porém com 40 regiões distintas. Na geração das imagens, admitiu-se que os níveis de cinza de cada classe fossem provenientes de uma distribuição gaussiana com mesmo desvio padrão, porém com médias diferentes. Esta diferença entre as médias das classes foi adotada ser 0,5 desvio padrão para o conjunto 1, 1 desvio padrão para o conjunto 2 e 2 desvios padrões para conjunto 3. A classe com menor radiometria possui média e desvio padrão iguais a 100 e 5, respectivamente. Exemplos de imagens simuladas são vistos na **Figura 1**.



**FIGURA 1** – Exemplos de imagem simulada em cada um dos conjuntos: (a) conjunto 1; (b) conjunto 2 e (c) conjunto 3.

## 3. Segmentador SegSAR

O algoritmo utilizado para a segmentação das imagens ópticas sintéticas é o SegSAR (Sousa Jr, 2005). O SegSAR é um segmentador híbrido, pois utiliza técnicas de crescimento de regiões, agrupamento de regiões, ajuste de bordas e separação de regiões não homogêneas. É multi-níveis, pois utiliza o critério hierárquico de pirâmide; multi-bandas e tanto pode ser aplicado para imagens radar como ópticas. O SegSAR foi implementado em linguagem IDL - *Iterative Data Language*, na plataforma ENVI - *The Environment for Visualizing Images*.

Os parâmetros de entrada do SegSAR são: o modelo de representação dos dados (manchas ou textura), o tipo de imagem (óptica ou de radar), a similaridade, a área mínima (ambas usadas nos testes de crescimento e de agrupamento de regiões); o coeficiente de variação (utilizado no teste de homogeneidade de regiões), o nível de confiança adotados nos testes e, finalmente, o número máximo de compressões desejado.

O processo de segmentação inicia-se com a compressão dos dados pelo critério de pirâmide, onde na base da pirâmide encontra-se a imagem original sem compressão. No próximo nível após a base, a imagem é comprimida um nível, sendo cada pixel da imagem formado pela média de quatro pixels da imagem anterior. Este processo continua até atingir o nível N desejado. O processo de crescimento de regiões começa na imagem mais comprimida, onde cada pixel é considerado como uma região. Os pixels são listados de forma aleatória para então começar o processo de crescimento de regiões pelo primeiro pixel da lista e posteriormente o teste de agrupamento de pixel com região. Após o término dos testes de agrupamento, tem-se uma imagem segmentada a partir da imagem com resolução mais degradada, devido às compressões aplicadas sobre a imagem original. O próximo passo é a descompressão dos dados em que 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 o teste de ajuste de bordas para as regiões para melhorar a segmentação inicial na imagem segmentada. Ao término da sucessiva descompressão até a imagem original, a segmentação está completa, e passa pelo teste de área mínima, para identificar se existem regiões menores que o limiar.

### 3.1. Medidas de avaliação das regiões

As avaliações sobre a imagem segmentada podem ser feitas de forma qualitativas ou quantitativas, de acordo com o uso e aplicação da segmentação. Neste estudo, foi feita a avaliação quantitativa utilizando o método empírico de discrepância (Delves et al., 1992). Este método avalia o algoritmo de segmentação através da comparação da segmentação produzida, com uma imagem de referência. A medida da qualidade da segmentação é feita medindo o tamanho, a posição e o valor médio de intensidade dos segmentos.

Assim, sejam as imagens original e segmentada possuindo  $x$  colunas e  $y$  linhas. Uma região nas imagens de referência e segmentada é referenciada como  $1 \leq i \leq N$  e  $1 \leq f \leq M$ , respectivamente. As médias na imagem original  $g$  de uma região nas imagens de referência e segmentada são denotadas por  $\langle g_i \rangle$  e  $\langle g_f \rangle$ , e  $N(i)$  e  $N(f)$  denotam o número de pixels nas regiões  $i$  e  $f$ , respectivamente. Definem-se duas matrizes de  $N \times M$  elementos,  $G$  e  $Fit$ , por:

$$G(i, f) = \frac{N(i \cap f)}{N(i \cup f)} \quad (1)$$

$$Fit(i, f) = \frac{xd + yd + \left(\frac{pd + id}{2}\right)}{G(i, j)} \quad (2)$$

onde:  $xd = \frac{|\langle x_i \rangle - \langle x_f \rangle|}{x}$ ,  $yd = \frac{|\langle y_i \rangle - \langle y_f \rangle|}{y}$ ,  $pd = \frac{|N(i) - N(f)|}{|N(i) + N(f)|}$  e  $id = \frac{|\langle I_i \rangle - \langle I_f \rangle|}{|\langle I_i \rangle + \langle I_f \rangle|}$

Os valores de  $\langle x_k \rangle$ ,  $\langle y_k \rangle$  e  $\langle I_k \rangle$  representam, respectivamente as médias das abscissas, das ordenadas e dos níveis de cinza na região  $k$ .

A matriz  $G$  relaciona pares de regiões  $(i, f)$  que têm pixels em comum, enquanto os valores na matriz  $Fit$  representam uma medida de ajuste entre regiões levando em consideração o tamanho, forma, posição e nível de cinza médio das regiões. Para cada região  $i$  na imagem de referência, sua região ajustada correspondente  $f$  é tomada como o valor mínimo de  $Fit(i, f)$ .

Uma vez definidas as regiões que melhor se ajustaram às regiões da imagem de referência, faz-se a avaliação da qualidade do ajuste através de medidas de ajuste de posição ( $Fit_{xy}$ ), ajuste de intensidade ( $Fit_i$ ), ajuste de tamanho ( $Fit_n$ ) e ajuste de forma ( $G_{forma}$ ) (Delves et al., 1992). Essas medidas são obtidas pelas **Equações** (3) a (6), respectivamente:

$$Fit_{xy} = 1 - \frac{(xd + yd)}{2} \quad (3)$$

$$Fit_i = 1 - \frac{|\langle I_i \rangle - \langle I_f \rangle|}{|\langle I_i \rangle + \langle I_f \rangle|} \quad (4)$$

$$Fit_n = 1 - \frac{(N(i) - N(f))}{N(i) + N(f)} \quad (5)$$

$$G_{forma} = \frac{N(i \cap f)}{N(i \cup f)} \quad (6)$$

Essas medidas variam entre 0 e 1, onde o valor 1 representa o ajuste perfeito. Uma medida global que leve em conta todas estas quatro últimas é a distância euclidiana ( $d_{\epsilon 2}$ ) em  $\mathbb{R}^4$ , em relação ao ponto (1,1,1,1), que é expressa por:

$$d_{\epsilon 2} = \sqrt{(Fit_{xy} - 1)^2 + (Fit_i - 1)^2 + (Fit_n - 1)^2 + (Gforma - 1)^2} \quad (7)$$

A variação de  $d_{\epsilon 2}$  é entre 0 e 2. O melhor resultado de segmentação é aquele que produzir a menor distância  $d_{\epsilon 2}$ , ou seja, busca-se a melhor segmentação através da minimização de  $d_{\epsilon 2}$ .

### 3.2. Medida de avaliação das bordas

Critérios comuns de desempenho de detecção de bordas são: baixa taxa de erro de detecção, localização, e a distância entre os pontos de borda detectados na segmentação e na imagem de referência. A discrepância entre as bordas da imagem segmentada e da imagem de referência pode ser calculada através da avaliação quantitativa das seguintes medidas:

- Percentagem dos pixels de bordas que foram corretamente detectados ( $P_{co}$ ):

$$P_{co} = \frac{\text{número de pixels da borda detectados corretamente}}{\text{número de pixels de borda ideal}} \quad (8)$$

- Percentagem dos pixels de bordas que não foram detectados ( $P_{mi}$ ):

$$P_{mi} = \frac{\text{número de pixels da borda não detectados}}{\text{número de pixels de borda ideal}} \quad (9)$$

- Percentagem dos pixels de bordas que foram erroneamente detectados como pixels de borda ( $P_{fa}$ ):

$$P_{fa} = \frac{\text{número de pixels de falso alarme}}{\text{número de pixels de borda detectados}} \quad (10)$$

- Figura de mérito de Pratt ( $FigMer$ ):

$$FigMer = \frac{1}{R} \sum_{i=1}^S \frac{1}{1 + \alpha d(i)^2}, \quad (11)$$

onde  $R$  e  $S$  são o número de pixels da borda da imagem de referência e segmentada, respectivamente;  $\alpha$  é o fator de escala (geralmente igual a 1); e  $d(i)$  é a distância entre os pixels de borda nas imagens segmentada e de referência (Pratt, 1991).

As medidas, descritas pelas **Equações** (8) a (11), variam entre 0 e 1, onde o valor 1 representa o ajuste perfeito para as medidas  $P_{co}$  e  $FigMer$ , e 0 para  $P_{mi}$  e  $P_{fa}$ . Novamente, se utiliza a distância euclidiana ( $d_{\epsilon 2}$ ) em  $\mathbb{R}^4$ , como uma medida global do desempenho da segmentação, com relação à qualidade das bordas detectadas. Neste caso, é calculada a distância ao ponto  $P = (1,0,0,1)$ :


$$d_{\epsilon 2} = \sqrt{(P_{co} - 1)^2 + P_{mi}^2 + P_{fa}^2 + (FigMer - 1)^2}, \quad (12)$$

A  $d_{\epsilon 2}$  varia entre 0 e 2, com o valor 0 sendo o ajuste perfeito para esta medida, ou seja, a melhor segmentação será julgada aquela que minimizar esta distância.

## 4. Resultados e Discussões

As imagens sintéticas utilizadas para segmentação com SegSAR são referentes aos três conjuntos de imagens ópticas. A segmentação foi feita para imagens ópticas, usando modelo manchas e diferentes níveis máximos de compressão (N variando 2 à 6). Os parâmetros usados nas segmentações com o SegSAR variaram de acordo com o conjunto utilizado. Através de alguns teste preliminares foram selecionados os valores de similaridade de 60 e área mínima de 120 para o conjunto 1; e similaridade de 52 e área mínima de 60 para os conjuntos 2 e 3. Na **Figura 2** são apresentadas as imagens segmentadas, a segmentação de

referência pode ser vista na **Figura 2(a)**, enquanto exemplos de segmentação para cada conjunto de imagem são ilustrados nas **Figuras 2(b)**, **2(c)** e **2(d)**.



**Figura 2** – Imagens segmentadas: (a) de referência, (b) do conjunto 1 com  $N = 3$ ; (c) do conjunto 2 com  $N = 4$ ; e (d) do conjunto 3 com  $N = 4$ .

A **Figura 3** mostra as medidas quantitativas de bordas e regiões, para cada conjunto de dados, para todos os níveis máximos de compressão estudados. Sendo que os resultados apresentados referem-se à média das 100 imagens analisadas e apresentam uma barra de erro de 1 desvio padrão. As medidas de borda para o conjunto 1 são mostradas na **Figura 2 (a)**. O valor de figura de mérito (*FigMer*) aumenta de  $N = 2$  até 3, estabilizando para os demais níveis. A probabilidade de pixels corretamente detectados ( $P_{co}$ ) cresce do nível 2 ao 5 e decresce para o nível 6. Segundo o teste Z realizado ao nível de confiança de 95 %, os valores de  $P_{co}$  são iguais para todos os níveis, exceto para o nível 2. A probabilidade de pixels não detectados ( $P_{mi}$ ) decresce do nível 2 ao 3, mantêm-se quase constante entre 3 e 5 e volta crescer para o nível 6. Pelo teste Z, os valores de  $P_{mi}$  são iguais para os níveis 3, 4 e 5. A probabilidade de falso alarme ( $P_{fa}$ ) cresce até  $N = 3$  e decresce até  $N = 6$ . O cálculo da distância euclidiana ( $d_{\ell 2}$ ) mostra que o menor valor ocorre para  $N = 5$ , sendo que os  $N = 3, 4$  e 6 apresentam valores um pouco maior mas próximos ao  $d_{\ell 2}$  mínimo.

Observando-se a **Figura 3(b)**, nota-se que a medida de intensidade (*Fitl*) apresenta valor constante igual a 0,98, para os níveis máximo de compressões de 3 a 6, enquanto que para  $N = 2$  é igual a 0,97, ou seja, não ocorre modificação da intensidade para todas as compressões, exceto para  $N$  igual a 2. A medida de posição (*Fitxy*) apresenta menor valor para  $N$  igual a 2 e mantêm-se constante para os outros níveis máximo de compressões. O *Fitn* cresce de  $N$  igual a 2 até 5 e decresce para 6. Os valores de *Fitn* variam de 0,68 a 0,72, entre os níveis de compressão de 3 e 6 mas o teste Z mostra que as medidas são iguais. Com relação a medida de *Gforma*, os valores decrescem até o nível máximo de compressão de 5 e cresce para  $N$  igual a 6. O valor da menor distância euclidiana em relação às medidas quantitativas das regiões ocorre para  $N$  igual a 3, crescendo suavemente até 6, e abruptamente para 2. Neste caso, pode-se afirmar que o nível máximo de compressão mais indicado para

estimar regiões é o 3, seguido pelos  $N = 4, 5$  e 6. Analisando as medidas de bordas e regiões para o conjunto 1, o nível máximo de compressão que apresenta o melhor desempenho é o  $N = 3$ , entretanto este é o pior em relação ao RMSE. Os níveis 4 e 5 apresentaram também bons resultados, podendo ser utilizados com boa confiabilidade.

Com relação ao número de regiões geradas em cada imagem segmentada deste conjunto, verifica-se que o número de regiões, pelo teste Z, são iguais para os  $N = 3$  e 4. Estes níveis máximos de compressão apresentam o mesmo número de regiões em torno de 100. Nenhum nível máximo de compressão apresentou número de regiões próximo ao ideal (40), como visto na **Tabela 1**. Nesta tabela estão mostrados os números mínimos e máximos de regiões obtidas em cada conjunto de dados e nível máximo de compressão, assim como o número médio de regiões (entre parêntese). Quanto ao erro médio quadrático (RMSE), o menor valor ocorre para  $N = 6$ , aumentando com a diminuição dos níveis máximos de compressão, exceto para o nível 2 que apresenta valor semelhante ao  $N = 5$ .

A **Figura 3(c)** apresenta as medidas de bordas para o conjunto 2. A medida de figura de mérito cresce até o nível 5 e decresce para o nível 6. A probabilidade de acerto cresce dos níveis 2 a 3, mantêm-se constante nos níveis 3 e 4 e decresce até 6. As probabilidades de pixels não detectados apresentam os menores valores nos níveis 3 e 4, crescendo para ambos os lados da curva. Já a probabilidade de falso alarme decresce até o  $N = 5$  e cresce para nível 6. A distância euclidiana considera todas as medidas de região simultaneamente, mostrando que seu menor valor ocorre para o nível máximo de compressão igual a 5. Observa-se que os valores são aproximados para os níveis 4 e 6.

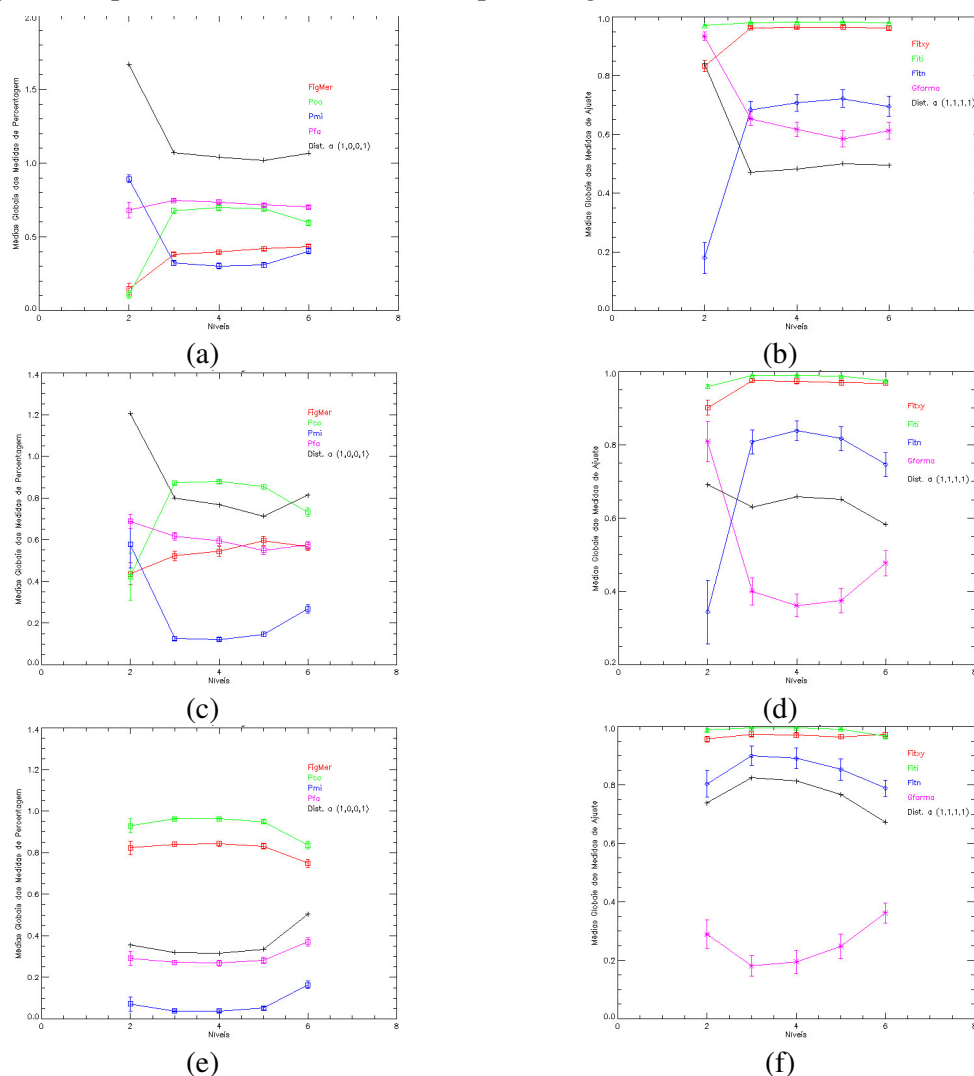
A **Figura 3 (d)** mostra as medidas de regiões para o conjunto 2. A *Fiti* é constante entre os níveis de 3 e 5, e ligeiramente menor para os outros níveis. A *Fitxy* apresenta o mesmo valor, segundo o teste Z, para os níveis 3 a 6, com menor valor para  $N = 2$ . O maior valor de *Fitn* ocorre para  $N = 4$ . No entanto, o teste Z mostra que os valores são iguais para os níveis 3, 4 e 5. A medida de *Gforma* tem o maior valor para o nível 2, decrescendo abruptamente até o mínimo em  $N = 4$ , voltando a crescer até 6. A distância euclidiana é menor em  $N = 6$ , seguida de  $N = 3$ , e os níveis 4 e 5 apresentam valores semelhantes. Como resultado da análise quantitativa de regiões e bordas do conjunto 2, pode-se afirmar que o nível máximo de compressão de 4 e 5 apresentam os melhores desempenhos estatísticos, tanto para as medidas de borda quanto de regiões.

Com relação o número de regiões encontradas, nota-se que nenhum nível máximo de compressão engloba o número de regiões existentes na imagem de referência (40), como mostrado na **Tabela 1**, apresentando valores iguais nos níveis 2 e 6, segundo o teste Z. Os menores RMSE encontrados foram para os níveis 6 e 2, respectivamente.

Analisando-se a **Figura 3(e)**, que mostra as medidas de bordas para o conjunto 3, nota-se que os valores de figura de mérito são quase constante. E por apresentar um desvio padrão maior que os outros valores encontrados, o nível 2 apresenta valores iguais para os níveis 3, 4 e 5. A probabilidade de acerto ( $P_{co}$ ) é máxima para os níveis 3 a 5, que apresentam valores iguais, segundo o teste Z. A probabilidade de pixels não detectados ( $P_{mi}$ ) é mínima nos níveis 3 e 4, seguido imediatamente do  $N = 5$ . Finalmente, a menor  $P_{fa}$  ocorre para os  $N = 3$  e 4. Como conclusão para a avaliação do teste de borda, o cálculo da distância euclidiana mostra que o nível máximo de compressão que apresenta melhor desempenho é o 3, mas o 4 tem quase o mesmo desempenho, não deixando de ser um bom nível a ser usado.

A **Figura 3(f)** apresenta as medidas quantitativas de regiões. O *Fitxy* é igual para os níveis 3, 4 e 6, com valores muito próximos para os outros níveis. O *Fiti* é constante entre 3 e 5, e como ocorre para o *Fitxy*, os outros valores são bem próximos. Pelo teste Z, todos os valores são iguais, exceto com relação ao nível 6. O *Fitn* apresenta valores iguais e máximos para  $N = 3$  e 4. Devido ao desvio padrão, todos os valores encontrados são iguais, exceto para

os pares 3 e 6; e 4 e 6, pelo resultado obtido no teste Z. A medida de *Gforma* apresenta o valor máximo para o nível máximo de compressão 6, decrescendo até o mínimo em 3 voltando a crescer para o  $N = 2$ . Apesar deste comportamento, o teste Z mostra que todos os valores são iguais. Para o conjunto 3, o desempenho das medidas estatísticas de regiões e bordas mostra que os valores das medidas são muito semelhantes para todos os níveis máximo de compressões, devido a melhor discriminação entre as regiões. Isto acarreta em bons resultados principalmente para os níveis máximo de compressão igual a 3 e 4.



**Figura 3** – Valores das medidas quantitativas de (a) bordas e (b) regiões para o conjunto 1; (c) bordas e (d) regiões para o conjunto 2; e (e) bordas e (f) regiões para o conjunto 3, para os diferentes níveis máximos de compressões.

Quanto ao número de regiões, nota-se que todos os níveis máximos de compressão englobam o número de regiões existente na imagem de referência, como visto na **Tabela 1**, apresentando visualmente uma segmentação considerada boa, como pode-se notar na **Figura 2**. O menor valor de distância euclidiana ocorre para  $N = 6$ . O RMSE menor ocorre para o nível 6 crescendo de 3 até o 5.

Comparando-se as **Figuras 3(b), (d) e (e)**, nota-se que os valores de *Fity* e *Fiti* são iguais para os níveis máximos de compressão de 3, 4, 5 e 6. Para *Fim*, houve um crescimento dos valores do conjunto 1 para o 3, tendendo para 1. Já, a medida de *Gforma* ocorreu um

decréscimo do conjunto 1 para 3. Na comparação das Figuras 2(a), (c) e (f), verifica-se que os valores de  $FigMer$  e  $P_{co}$  aumentaram e seu valores tenderam para 1, enquanto que  $P_{fa}$  e  $P_{mi}$  diminuíram de tal modo que tenderam para 0, principalmente o  $P_{mi}$ . Estas tendências mostram que com o aumento do desvio padrão entre as regiões as medidas tendem ao ajuste perfeito.

**Tabela 1** – Número de regiões para cada nível máximo de compressão por conjunto de dados.

	N=2	N=3	N=4	N=5	N=6
<b>Conjunto 1</b>	3 a 7 (5)	104 a 124 (115)	95 a 110 (104)	72 a 84 (78)	47 a 57 (52)
<b>Conjunto 2</b>	45 a 65 (19)	109 a 135 (123)	84 a 106 (96)	54 a 66 (60)	46 a 54 (50)
<b>Conjunto 3</b>	32 a 38 (6)	37 a 43 (40)	34 a 40 (40)	36 a 42 (39)	37 a 43 (40)

## 5. Conclusões

Com resultado final, as medidas de bordas e regiões para o conjunto 1 mostram que o nível máximo de compressão que apresenta bom desempenho é o 3, apesar dos  $N = 4$  e  $5$  apresentarem também bons resultados, podendo ser utilizados com boa confiabilidade. Pode-se afirmar a partir da análise quantitativa de regiões e bordas para o conjunto 2 que o nível máximo de compressão com melhor desempenho das medidas são os 4 e 5. Para o conjunto 3, o desempenho das medidas de regiões e bordas mostra que os valores das medidas são muito semelhantes para todos os níveis máximo de compressões, devido a melhor discriminação entre as regiões nas imagens. Finalmente, pode-se concluir que o nível 4 pode ser utilizado com bom desempenho para os três conjuntos de dados estudados.

## Referências

- Camara, G. et al. SPRING: Integrating remote sensing and GIS by object-oriented data modeling. *Elmsford, Computers & Graphics*, v.20, n.3, p.395-403, 1996.
- Caves, R.; Quegan, S.; White, R. G. Quantitative comparison of the performance of SAR segmentation algorithms. *IEEE Transactions on Image Processing*, v.7, n.11, p.1534-1546, 1998.
- Cook, R.; McConnell, I; Stewart, D.; Oliver, C. MUM (Merge Using Moments) segmentation for SAR images. In: Euro SAR Data Processing for Remote Sensing, Vol. SPIE. **Proceeding**. Rome, Italy, 1994. p.92-103.
- Delves, L. M.; Wilkinson, R.; Oliver, C. J.; White, R. G. Comparing the performance of SAR segmentation algorithms. *International Journal of Remote Sensing*, v. 13, n.11, p. 2121-2149, 1992.
- Lucca, E. V. D. **Avaliação e comparação de algoritmos de segmentação de imagens de radar de abertura sintética**. 1998. 211p. (INPE-7507-TDI/721). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 1998.
- Pratt, W. **Digital Image Processing**. New York Wiley-Interscience, 1991.
- Neubert, M.; Herold; H. Meinel, G. Evaluation of remote sensing segmentation quality-further results and concepts. In: International Conference on Object-based Image Analysis, **Proceedings** Salzburg, Salzburg University, 2006. Available in: [http://www.commission4.isprs.org/obia06/Papers/10\\_Adaption%20and%20further%20development%20II/OBIA2006\\_Neubert\\_Herold\\_Meinel.pdf](http://www.commission4.isprs.org/obia06/Papers/10_Adaption%20and%20further%20development%20II/OBIA2006_Neubert_Herold_Meinel.pdf) Access in: Nov. 14<sup>th</sup> 2006.
- Quegan, S.; Rye, A. J.; Hendry, A.; Skingley, J.; Oddy, C. J. Automatic interpretation strategies for synthetic aperture radar images. *Philosophical Transactions of the Royal Society of London*. A324, p.409-421, 1988.
- Román-Roldán, R.; Gómez-Lopera, J. F.; Atae-Allah, C; Martínez-Aroza, J.; Luque-Escamilla, P. L. A measure of quality for evaluating methods of segmentation and edge detection. *Pattern Recognition*., v.34, p:969-980, 2001.
- Sousa Jr, M. A. **Segmentação multi-níveis e multi-modelos para imagens de radar e ópticas**. (a ser publicada) 133p. Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2005
- White, R. **Low-level segmentation of noise imagery**. Memorandum 3900, 1986. DRA, Royal Signal and Radar Establishment, Works.

## 5. Agradecimentos

Os autores agradecem o suporte financeiro do CNPq (processo n<sup>os</sup> 384469/2006-0, 304274/2005-4 e 305546/2003-1).