

# Segmentador Incremental Multi-nível para Imagens

Manoel de Araújo Sousa Júnior  
Luciano Vieira Dutra  
Corina da Costa Freitas  
Divisão de Processamento de Imagens - INPE  
{manoel, dutra, corina}@dpi.inpe.br

## Resumo

*O processo de segmentação de imagens de radar de abertura sintética SAR é muito importante quando se deseja fazer uma classificação posterior. No presente trabalho está descrita uma metodologia para segmentar imagens SAR que apresenta inovações significativas. O uso dos métodos hierárquico de pirâmide, crescimento e agrupamento de regiões, teste de bordas e segmentação incremental dirigida, são abordados nesta metodologia. O método de segmentação incremental representa uma inovação significativa, devido à possibilidade de selecionar determinadas regiões de interesse durante o processo de segmentação, para serem segmentadas em maior detalhe. Uma outra inovação é a possibilidade de se ter resultados intermediários durante o processo de segmentação.*

## 1. Introdução

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

Com o aumento da utilização de dados SAR, faz-se necessário o desenvolvimento de técnicas automáticas de processamento e análise, para tornar operacional o uso dessas imagens.

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

A distribuição Gaussiana é comumente usada em algoritmos de segmentação, sendo um dos fatores desse freqüente

uso a facilidade na implementação da mesma. Entretanto, essa distribuição não é a mais adequada para representar os dados de imagens SAR.

O presente trabalho tem como principal objetivo o desenvolvimento de um segmentador para imagens, com as seguintes características:

- Que tenha flexibilidade para trabalhar com imagens SAR e imagens ópticas.
- Que seja multi-nível, com isso:
  1. Possa fazer segmentação de grandes imagens, sem ter problemas de memória;
  2. Faça segmentação incremental dirigida a regiões na imagem de maneira que regiões de interesse, possam ser segmentadas em maior detalhe;
  3. Gere resultados intermediários durante o processo de segmentação;
  4. Produza uma estrutura onde estejam representadas as características de *backscatter*, textura e forma das regiões.

## 2. Metodologia

A seguir será descrita a metodologia para segmentação de imagens. Para um melhor entendimento e tornar mais fácil o acompanhamento do processo de segmentação aqui proposto, a presente metodologia foi dividida em quatro etapas. Cada etapa engloba um conjunto de rotinas e procedimentos usados para segmentar a imagem. O fluxograma de todo o processo pode ser visto na Figura 1.

### 2.1 Primeira etapa

Nesta primeira parte, tem início o processo de segmentação (Figura 2). O dado de entrada é uma imagem que está representada em vários níveis por uma estrutura hierárquica de pirâmide [1]. Esse procedimento é definido aqui como

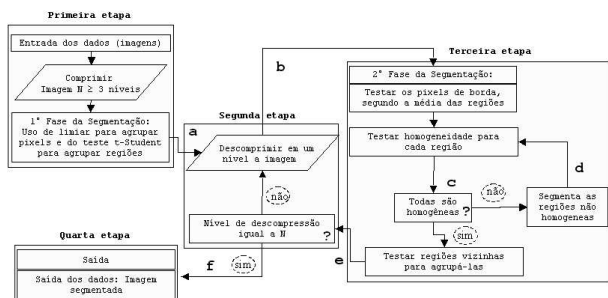


Figura 1. Fluxograma de todo o processo

compressão. A saída desta primeira fase é uma imagem segmentada intermediária.




Figura 2. Fluxograma da primeira etapa

### 2.1.1 Compressão

A compressão dos dados é feita seguindo o critério hierárquico de pirâmide, no qual a cada nível a imagem é representada por uma imagem de médias, que apresenta a metade do número de linhas e colunas da imagem anterior. Isso ocorre porque cada *pixel* da imagem que está sendo gerada, é formado pela média de quatro *pixels* da imagem anterior (um nível abaixo). A imagem de entrada é armazenada no seu formato original.

A imagem resultante pode então ser novamente comprimida. O número de níveis da pirâmide pode ser determinado a princípio pelo usuário.

A principal vantagem do uso de representação por pirâmide, é que mesmo trabalhando com grandes imagens, a segmentação inicial sempre é feita sobre uma imagem com dimensões bem reduzidas, com isso reduz-se muito a quantidade de memória requerida para o processo de segmentação, diminuindo possíveis problemas com a mesma. Outros segmentadores que fazem abordagem hierárquica podem ser encontrados em [2] e [3].

### 2.1.2 Segmentação no nível $N$

Nesta etapa, ocorre a segmentação da imagem representada no nível mais alto ( $N$ ), ou máxima compressão. Por exemplo para  $N = 3$ , a imagem estaria no nível 3 da pirâmide. Neste nível, cada *pixel* é formado pela média de 64 *pixels* da imagem original.

Regiões homogêneas na imagem de radar, podem ser representadas por uma distribuição *Gamma* ( $\Gamma(n, n)$ ), em imagens intensidade, a suposição de normalidade é válida quando se têm um número equivalente de *looks* (*nel*) elevado. O comportamento dos dados de imagens em intensidade, com diferentes *nel* ( $n$ ), onde  $n = 1$  representa uma distribuição *Exponencial*, e  $n \geq 2$  representam distribuições *Gamma*. Para valores de  $n > 8$ , a distribuição tende para uma distribuição Gaussiana (Figura 3).




Figura 3. Função densidade de probabilidade de imagens em intensidade com diferentes números de *looks* ( $n$ ).

As imagens em amplitude têm um comportamento similar, sendo que para  $n = 1$  tem-se uma distribuição *Rayleigh*, para  $n \geq 2$  tem a distribuição *Raiz da Gamma* ( $\Gamma^{1/2}(n, n)$ ). Para valores de  $n \geq 8$ , a distribuição se aproxima de uma distribuição Gaussiana.

A suposição de gaussianidade dos dados neste nível é válido, e é usado o teste *t-Student* para agrupar as regiões, definindo uma probabilidade de aceitação para agrupar regiões e um limiar para agrupar *pixels* [4].

Para evitar tendenciosidade no processo de crescimento de regiões (*Region Growing*), os *pixels* sementes são escolhidos aleatoriamente. Cada *pixel* semente é testado com os seus 4 vizinhos (vizinhança quatro) e o que apresentar menor diferença em módulo é um provável *pixel* a ser agrupado para formar uma região.

O processo continua enquanto estiver agrupando *pixels* a nova região. Todos os *pixels* que agora pertencem a essa nova região são automaticamente eliminados da lista de *pixels* a serem visitados na imagem. Quando não houver mais *pixels* que satisfaçam os critérios de agrupamento citados acima, o processo de crescimento de região pára e um novo *pixel* é escolhido como *pixel* semente.

A partir do segundo *pixel* semente já é possível que ocorra agrupamento de regiões (*Region Merging*), pois uma região pode ter sido formada pela primeira semente da segmentação. Os critérios de união entre duas regiões são definidos pelo teste *t-Student*, para o qual é escolhido um valor de probabilidade de aceitação.

Para identificar se duas regiões são significativamente diferentes ou não, é preciso testar a hipótese de que elas representem uma mesma região. Para se fazer este teste, é preciso propor um modelo para os dados presentes na imagem.

O teste *t-Student* é usado para comparar as semelhanças entre duas regiões e definir se essas regiões podem ser unidas [5]. Como exemplo, suponha que existam duas regiões adjacentes, uma região *A* que contém um conjunto de *pixels*  $N_A$  com média igual a  $\bar{X}_A$  e variância dada por  $Var(A)$  e uma região *B* com média igual a  $\bar{X}_B$  e variância  $Var(B)$  e número de *pixels* representado por  $N_B$ . Sendo as hipóteses de aceitação e rejeição para a igualdade de médias, o critério utilizado para o agrupamento das regiões *A* e *B*, dado por:

$$H_0 : \mu_A = \mu_B \quad (1)$$

$$H_1 : \mu_A > \mu_B \quad (2)$$

e sabendo que

$$t \equiv \frac{(\bar{X}_A - \bar{X}_B) - (\mu_A - \mu_B)}{\sqrt{Var(A+B)}} \quad (3)$$

segue uma distribuição *t-Student* com  $\nu = N_A + N_B - 2$  graus de liberdade, tem-se que, sob a hipótese  $H_0$  verdadeira, a estatística

$$t^* \equiv \frac{|\bar{X}_A - \bar{X}_B|}{\sqrt{Var(A+B)}} \quad (4)$$

também seguirá a mesma distribuição.  $Var(A+B)$  representa a variância conjunta das regiões *A* e *B*.

Aplicando o teste *t-Student*, a hipótese  $H_0$  é rejeitada se


$$P(t > |t^*|) < p_0 \quad (5)$$

onde  $p_0$  é probabilidade de aceitação do teste definida pelo usuário.

A Figura 4 ilustra um caso onde o teste *t-Student* rejeitou a hipótese  $H_0$ , ou seja, considera as médias das regiões *A* e *B* diferentes e, neste caso, as regiões não são agrupadas.

O processo de segmentação só faz uso de informações locais, o que o torna capaz de preservar detalhes de pequenos alvos na imagem, pois os mesmos não sofrem influência de parâmetros globais.

As propriedades de uma nova região como média, variância e tamanho, podem ser deduzidas das regiões que foram agrupadas. Cada nova região é caracterizada pela sua relação de vizinhança com as outras regiões.



**Figura 4. Teste *t-Student* indicando diferença entre médias.**

O algoritmo armazena uma lista com os *pixels* ligados, não sendo necessário guardar a forma de cada região, com isso o custo computacional de cada agrupamento é relativamente baixo.

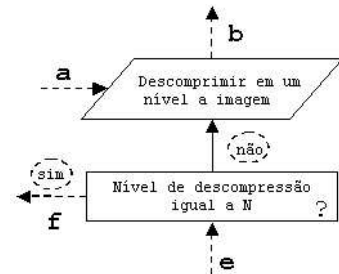
Após o término da primeira fase, a imagem segmentada é mostrada para que o usuário escolha quais regiões da imagem devem permanecer ativas nos demais níveis da pirâmide. Essa inovação permite que se faça uma segmentação incremental dirigida às regiões de maior interesse, já que o usuário pode escolher sub-áreas na imagem, nas quais ele deseja fazer uma segmentação mais detalhada.

[6] aplicam um algoritmo de segmentação para imagens SAR, e concluem que é necessário interromper a segmentação em algumas regiões, para priorizar o processo em outras regiões específicas, reduzindo o tempo de processamento e evitando que ocorra sub-segmentação em algumas áreas, e super-segmentação em outras.

Concluída esta primeira parte da segmentação, passa-se à etapa seguinte do fluxograma.

## 2.2 Segunda etapa

Nesta etapa, é feita a descompressão dos dados, a imagem gerada na primeira etapa é descomprimida em um nível  $(N - 1)$ . Com isso, as regiões formadas na primeira segmentação passam a ser representadas por uma imagem com o dobro do seu tamanho, e a imagem passa para a terceira etapa (Figura 5).



**Figura 5. Fluxograma da segunda etapa**

As imagens resultantes da terceira etapa (ver mais a frente) voltam a passar por esta rotina, para testar se a imagem já

está no nível mais baixo (resolução original). Se isso ocorrer, não é mais necessário fazer descompressão e essa é a imagem segmentada final. Caso contrário, é feita uma nova descompressão, descendo um nível na pirâmide e a imagem descomprimida passa para a terceira etapa.

Após cada descompressão a imagem segmentada é armazenada em disco, gerando assim resultados intermediários. Essa é outra inovação no segmentador, pois permite que o usuário possa trabalhar nas segmentações intermediárias, enquanto o processo de segmentação está sendo executado.

Fica opcional para o usuário armazenar todas as imagens geradas durante o processo de segmentação. Por exemplo, o usuário pode escolher armazenar em disco somente a segmentação final.

Esta etapa pode ser denominada de intermediária do processo de segmentação, por ser responsável somente pelo controle de descompressão da imagem, armazenamento dos dados e parada do processo de segmentação.

## 2.3 Terceira etapa

Nesta etapa, a imagem de entrada é uma imagem segmentada e tem sempre uma resolução menor ou igual a resolução da imagem original (Figura 6).

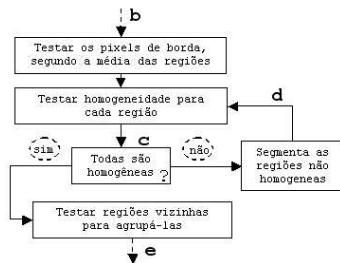


Figura 6. Fluxograma da terceira etapa

Essa rotina ao ser iniciada, recebe a imagem com  $N - 1$  níveis de compressão, como esta é uma imagem segmentada, o próximo passo é aplicar testes às regiões para buscar melhorar a segmentação. O primeiro passo é fazer um teste de bordas. Após a redefinição das regiões é feito um teste de homogeneidade para cada região. Quando todas as regiões forem homogêneas faz-se um teste de homogeneidade entre regiões, com o objetivo de agrupar regiões similares. Esses procedimentos são detalhados a seguir.

### 2.3.1 Teste de bordas

O teste de bordas é feito para corrigir possíveis exclusões ou inclusões de *pixels* numa região. É feito percorrendo a borda da região e comparando os *pixels* vizinhos com relação à média das regiões que estão sendo testadas, usando

para isso, um critério de limiaridade para saber se os *pixels* que formam as bordas pertencem à região com média  $\bar{X}_A$  ou a região com média  $\bar{X}_B$ .

Quando um *pixel* for adicionado a uma nova região, é recalculada a média das duas regiões. O próximo passo é fazer o teste de homogeneidade para cada região.

### 2.3.2 Teste de homogeneidade para regiões

Quando uma imagem desce um nível, o *nel*  $n$  tende a aumentar em aproximadamente 4 vezes o valor do que apresentava a imagem do nível acima.

Uma maneira fazer o teste de homogeneidade é ver quais regiões apresentam valores de *nel* maior que 4 vezes o *nel* da região na imagem um nível acima, depois fazer um ordenamento crescente dos valores, e escolher um percentual dos mesmos (por exemplo os 30% dos valores mais altos), as regiões que contem esses valores seriam segmentadas novamente. A principal vantagem de se fazer isso é a simplicidade e rapidez do método.

Uma outra abordagem seria fazer um teste de hipótese para saber se o *nel* da região na imagem com um nível abaixo, tem aproximadamente 4 vezes o valor do *nel* da região na imagem um nível acima, mas para isso é preciso conhecer a função densidade de probabilidade do estimador  $\hat{n}$ .

#### Regiões não homogêneas

As regiões não homogêneas são segmentadas novamente para formar novas regiões, essas novas regiões são testadas e as que não forem homogêneas voltam a ser segmentadas. O processo de segmentação das regiões é feito pelo método de crescimento de região, e pára quando não houver mais regiões heterogêneas.

### 2.3.3 Teste de homogeneidade entre regiões

Nesta etapa, é feito um teste *t-Student* para saber se regiões vizinhas são homogêneas, se forem, elas são agrupadas e se não são permanecem como estão. A princípio, será utilizado um limiar para as médias das regiões. Depois que todas as regiões homogêneas forem agrupadas, a imagem com as novas regiões é armazenada em disco e processo retorna para a segunda etapa.

A definição de outros testes para homogeneidade entre regiões estão sendo estudados, para uma melhor adequação do segmentador às características das imagens SAR.

## 2.4 Quarta etapa

Nesta etapa se obtém a imagem segmentada final. O programa armazena em disco a imagem segmentada e com isso termina o processo de segmentação.

## 2.5 Avaliação dos resultados

A avaliação do segmentador será feita usando a metodologia utilizada no trabalho de [7], que usa critérios qualitativos e quantitativos, capazes de identificar o bom desempenho de um classificador. Será avaliado também o tempo de processamento para cada etapa do classificador.

O primeiro passo no processo de avaliar a qualidade de uma segmentação produzida por um algoritmo, é comparar as regiões resultantes de uma segmentação com regiões de uma imagem de referência, através da comparação de pares de elementos [8].

As medidas de ajuste de posição, ajuste de intensidade, ajuste de tamanho e ajuste da forma, descritas em [8], serão as medidas utilizadas para medir a qualidade da segmentação.

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

Após quantificar a segmentação, é possível compará-la com uma outra segmentação produzida por outro algoritmo e desta forma comparar os algoritmos entre si a partir de seus resultados.

## 3. Resultados Preliminares

Os resultados preliminares da segmentação para imagens ópticas e SAR gerados no nível mais alto da pirâmide serão mostrados a seguir. O resultado da segmentação para uma imagem TM/Landsat (imagem original  $400 \times 400 \text{ pixels}$ ) pode ser visto na Figura 7, a segmentação foi feita na imagem com  $100 \times 100 \text{ pixels}$ . Já o resultado para uma imagem Sir-C/X-SAR (imagem original  $1200 \times 1200 \text{ pixels}$ ) pode ser visto na Figura 8, a segmentação foi feita na imagem com  $150 \times 150 \text{ pixels}$ .

## 4. Considerações Finais

O presente trabalho mostrou que existem muitas técnicas desenvolvidas para o processamento de imagens SAR e que, pela importância dos dados gerados, deve-se buscar melhorias para essas técnicas.

Na segmentação das imagens SAR, é preciso definir qual modelagem dará bons resultados e para isto foi proposta uma nova metodologia para se ter uma segmentação melhorada. Isso pode ser possível pelo uso de técnicas híbridas de segmentação. Para que os algoritmos se tornem eficientes é preciso buscar teste estatísticos que dêem bons resultados para esse tipo de imagem.




Figura 7. Imagem TM/Landsat segmentada




Figura 8. Imagem SAR segmentada

Este trabalho apresenta inovações de grande relevância para segmentação de imagens. O uso da representação hierárquica por pirâmide permite a obtenção de segmentações intermediárias, uma inovação no processo de segmentação. E permite também um melhor uso na alocação da memória, quando se deseja trabalhar com grandes imagens.

A segmentação incremental é mais uma inovação neste trabalho. Esse tipo de segmentação tem como principal van-

tagem à possibilidade de escolha por parte do usuário de quais regiões devem continuar sendo segmentadas, e quais não. Essa inovação é tida como uma das mais importantes em todo o processo de segmentação, pois vários autores citam que essa abordagem pode trazer melhorias na segmentação de regiões que apresentam supersegmentação ou sub-segmentação.

Uma outra vantagem do segmentador aqui proposto é sua flexibilidade para segmentar tanto imagens *SAR* como imagens ópticas, obtido pelo testes que vão ser implementados para segmentar a imagem.

O objetivo final da análise das imagens é obter uma boa classificação e para que isso ocorra, é preciso melhorar o processo de segmentação.

## 5. Referências

- [1] Jain, R.; Kasturi, R.; Schunck, B.G. *Machine Vision*. New York, McGraw-Hill, Inc., 1995. 549p.
- [2] Tilton, J. C. Hierarchical image segmentation: as applied to remotely sensed multispectral or hyperspectral imagery.  
<http://backserv.gsfc.nasa.gov/code935/tilton/index.html>
- [2] Tilton, J. C.; Lawrence, W. T. Interactive analysis of hierarchical image segmentation. In: 2000 International Geoscience and Remote Sensing Symposium (IGARSS'00). Honolulu, HI, 24-28 July 2000. *Proceedings*.
- [4] Oliver, C.; Quegan, S. *Understanding synthetic aperture radar images*. London, Artech House Inc., 1998. 479p.
- [5] Cook, R.; McConnell, I.; Stewart, D.; Oliver, C. MUM (Merge Using Moments) segmentation for SAR images. In: *Proc. EurOpto SAR Data Processing for Remote Sensing*, Vol. *SPIE*, Rome, Italy. 1994. pp. 92-103.
- [6] Beaulieu, J. M.; Touzi, R. Hierarchical segmentation of Polarimetric SAR Images. In: 2002 International Geoscience and Remote Sensing Symposium (IGARSS'02) and 24<sup>th</sup> Canadian Symposium on Remote Sensing. Toronto, Canada, 24-28 June 2002. *Proceedings*.
- [7] Lucca, E.V.D. *Avaliação e comparação de algoritmos de segmentação de imagens de radar de abertura sintética*. Dissertação de Mestrado em Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais, São José dos Campos, SP, Dezembro de 1998.
- [8] Delves, L.M.; Wilkinson, R.; Oliver, C.J.; White, R.G. Comparing the performance of SAR segmentation algorithms. *International Journal of Remote Sensing*, Vol. 13, No. 11, pp. 21221-21249, 1992.