

# Uso de algoritmos genéticos no ajuste de parâmetros da segmentação de imagens

Giovana Mira de Espindola

Instituto Nacional de Pesquisas Espaciais – INPE  
Caixa Postal 515 – 12245-970 – São José dos Campos – SP, Brasil  
giovana@dpi.inpe.br

**Abstract.** Methods of image segmentation are important for remote sensing image analysis. Image segmentation tries to divide an image into spatially continuous, disjunctive and homogenous regions. Segmentation algorithms have many advantages over pixel-based image classifiers. Among the image segmentation techniques in the literature, region-growing techniques are being widely used for remote sensing applications, because they guarantee creating closed regions. Since most region-growing segmentation algorithms for remote sensing imagery need user-supplied parameters, one of the challenges for using these algorithms is selecting suitable parameters to ensure best quality results. This scientific research addresses this problem, proposing the use of genetic algorithms to select the best parameter settings of segmentation results.

**Palavras-chave:** Algoritmos de Crescimento de Regiões, Segmentação de Imagens, Ajuste de Parâmetros, Otimização, Algoritmos Genéticos.

## 1. Introdução

As áreas de visão computacional, de análise de imagens e de mineração de dados apresentam em comum a questão central da simplificação de uma imagem pela sua partição em um conjunto finito de regiões homogêneas. Neste contexto, o processo de segmentação tem por objetivo extrair informações das imagens pela agregação de objetos em classes de atributos.

Segundo Meinel e Neubert (2004), segmentar uma imagem significa agrupar pixels vizinhos em regiões com base em critérios de similaridade. Pekkarinen (2002) descreve tal processo como a divisão de uma imagem em regiões espacialmente contínuas, disjuntas e homogêneas. Moigne e Tilton (1995) definem a segmentação de imagens como o processo onde pixels individuais são agrupados em partições de acordo com alguma propriedade intrínseca da imagem, tal como intensidade dos níveis de cinza, contraste ou textura.

De uma maneira geral, a eficiência dos algoritmos de segmentação de imagens está vinculada à extração automática dos objetos de interesse. Neste sentido, há métodos que são adaptados a tipos particulares de aplicação, sendo que não existem algoritmos de segmentação convenientes a todos os tipos de imagens (Beauchemin e Thomson, 1997). Em seus trabalhos, Pal e Pal (1993), Haralick e Shapiro (1985) e Fu e Mui (1980) apresentam uma revisão completa das principais classes de algoritmos de segmentação descritos na literatura.

Meinel e Neubert (2004) apresentam uma comparação entre os principais algoritmos de segmentação aplicados às imagens de sensoriamento remoto, entre os quais destacam-se os software SPRING e e-Cognition®. Apesar da crescente variedade de métodos destinados a essa aplicação, Tilton e Lawrence (2000) sustentam que o método de crescimento de regiões é preferível, visto que considera a característica espacial dos dados e garante a formação de segmentos fechados. Outrossim, salienta-se que alguns dos softwares de segmentação de imagem de aplicação em sensoriamento remoto implementam o método de crescimento de regiões em suas rotinas, podendo-se citar o SPRING (Bins et al., 1996; Câmara et al., 1996) e o e-Cognition® (Baatz e Schape, 2000).

Grande parte dos algoritmos de segmentação por crescimento de regiões requer de seus usuários a escolha de parâmetros que definam os limiares da segmentação. O algoritmo do SPRING requer que sejam definidos limiares de área e de similaridade. Por sua vez, o algoritmo do e-Cognition® requer que sejam definidos quatro parâmetros: fator de escala,

pesos para cada uma das bandas espectrais, peso para cor e peso para compacidade. Para os usuários destes algoritmos, um dos desafios consiste em selecionar os parâmetros que resultem nos melhores resultados da segmentação.

O ajuste automático de parâmetros da segmentação envolve duas questões principais: a primeira é a seleção de uma função (função objetivo) que expresse adequadamente a qualidade da segmentação; a segunda é o método de otimização dos parâmetros, que consiste em procurar os valores que minimizem a função objetivo escolhida.

Diversos métodos visam orientar a escolha de parâmetros em algoritmos de segmentação por crescimento de regiões (Espindola et al., 2005, 2006). Nesta linha, Zhang (1996) destaca que, apesar de a literatura apresentar inúmeras técnicas de segmentação, poucos são os métodos de avaliação desenvolvidos para julgar a qualidade da segmentação. Alguns métodos têm sido propostos para avaliar e comparar o desempenho de algoritmos de segmentação, entre os quais se destacam os apresentados por Oliveira et al. (2003), Kartikeyan et al. (1998), Lucca (1998), Beauchemin e Thomson (1997), Jiang e Toriwaki (1993) e Levine e Nazif (1985).

A segunda questão importante relativa ao ajuste de parâmetros, diz respeito à otimização propriamente dita. Muitas vezes, a função objetivo escolhida não apresenta as propriedades exigidas pelos métodos de otimização baseados em cálculo. Nestes casos, métodos estocásticos, como Algoritmos Genéticos (AG) (Davis, 1990, Bhanu, 1991; Bhanu, 1994; Kueblbeck, 1997), são a alternativa mais usual, uma vez que não impõem qualquer restrição sobre a função objetivo a ser otimizada. Os AGs têm, contudo, um elevado custo computacional associado. O presente trabalho aborda estes tópicos e propõe um método supervisionado para o ajuste de parâmetros de segmentação, no qual se utiliza uma função objetivo particular que avalia numericamente as regiões da segmentação, e um AG na etapa de otimização.

## **2. Algoritmos Genéticos**

Algoritmos Genéticos (AG) representam uma técnica computacional de busca por soluções para problemas complexos de otimização, de difícil formulação matemática ou com espaços de busca muito grandes. A técnica é inspirada na Teoria da Evolução das Espécies proposta por Charles Darwin (Darwin, 1859), baseando-se nos princípios de sobrevivência dos mais aptos e reprodução. Segundo a Teoria de Darwin, características individuais são transmitidas de pais para filhos e os indivíduos melhor adaptados ao ambiente têm maior chance de sobreviver e, por consequência, de passar suas características a um número maior de descendentes.

Os AGs realizam um processo adaptativo e paralelo de busca de soluções análogo ao processo de evolução natural. Adaptativo porque novas soluções são criadas a partir de soluções anteriores, e paralelo porque várias soluções são consideradas em um dado momento. Na terminologia de AGs, um indivíduo representa uma solução potencial para o problema, uma população representa um conjunto de indivíduos e as características relevantes do indivíduo em relação ao problema são chamadas genes. Indivíduos são avaliados em relação à capacidade de resolver o problema, ou aptidão, e essa capacidade é expressa numericamente pela avaliação do indivíduo, através de uma função objetivo (Michalewicz, 1998).

O processamento básico de um AG se inicia com a criação de uma população inicial, onde os valores dos genes são determinados aleatoriamente. Na sequência, os indivíduos são avaliados e os mais aptos são selecionados. O próximo passo é a criação de uma nova população a partir da utilização de operadores genéticos sobre os indivíduos selecionados da geração anterior. Além disso, certos percentuais de indivíduos mais aptos são mantidos na

nova população (Feitosa et al., 2007). O procedimento continua até que seja alcançado um determinado número de gerações ou até que um determinado número de indivíduos tenha sido criado.

## 2.1 Operadores Genéticos

Os operadores genéticos representam regras para a criação de novos indivíduos nos AGs. Os operadores clássicos definidos na literatura são o cruzamento e a mutação. A mutação modifica aleatoriamente o valor de um gene. Esta operação tem a função de aumentar a diversidade genética da população e representa uma forma de tratar o problema de convergência para mínimos locais. Já o operador de cruzamento atua combinando os genes de dois indivíduos para a criação de um novo indivíduo, que desta forma herda características de seus pais.

Admitindo-se que a aptidão de um indivíduo é função de suas características, a combinação de genes entre os indivíduos mais aptos pode produzir novos indivíduos, ainda melhores. Caso indivíduos menos aptos sejam gerados neste processo, a tendência é que eles não sejam selecionados para a criação da nova população (Michalewicz, 1994; Feitosa et al., 2007).

## 3. Procedimento de Segmentação

Borsotti et al. (1998) e Xu et al. (1998) afirmam que o processo de segmentação consiste na subdivisão de uma imagem em regiões homogêneas, considerando alguma de suas características intrínsecas, como, por exemplo, o nível de cinza dos pixels. Além disto, Woodcock e Harward (1992) afirmam que em sensoriamento remoto, o objetivo da segmentação é delimitar as regiões na imagem que correspondem aos objetos da superfície terrestre.

Zucker (1976) descreve o método de segmentação como a divisão da imagem  $X$  em regiões homogêneas  $X_1, X_2, \dots, X_N$ , onde  $P$  é o predicado lógico que mede a homogeneidade de uma região segundo algumas condições. As condições descritas por Zucker (1976) devem ser satisfeitas por todos os algoritmos segmentadores, sendo que essas mesmas condições são válidas para uma infinidade de diferentes algoritmos. De maneira geral, todos os algoritmos de crescimento de regiões apresentam uma seqüência lógica que se inicia pela definição de células sementes, a partir das quais regiões são construídas pela junção de vizinhos similares (Pekkarinen, 2002; Schoenmakers et al., 1991). Baseado na ordem da definição das células iniciais e de seus agrupamentos, cada uma das iterações seguintes pode ainda fornecer resultados diferentes.

A Figura 1 ilustra o processo de segmentação de imagens por crescimento de regiões. Inicialmente, cada pixel da imagem corresponde a uma célula (Figura 1a), da qual são escolhidas as células sementes (Figura 1b). Com base na medida de homogeneidade, cada célula semente é comparada com as células vizinhas e duas células vizinhas são agrupadas se o critério de similaridade for satisfeito (Figuras 1c e 1d). Neste caso, ocorre a formação de uma nova célula, que herda as propriedades das duas células anteriores. Células continuam a ser agrupadas com suas vizinhas enquanto o critério de similaridade for satisfeito (Figuras 1e e 1f) (Bins et al., 1996).

O algoritmo de segmentação de imagens do software SPRING baseia-se na técnica de crescimento de regiões, com algumas modificações que parcialmente resolvem o problema da dependência na ordem de agrupamento das regiões. Tal implementação propõe um agrupamento de regiões baseado no conceito de região vizinha mais similar. Isto significa

dizer que, a cada iteração, o par mais semelhante de regiões espacialmente adjacentes é agrupado.

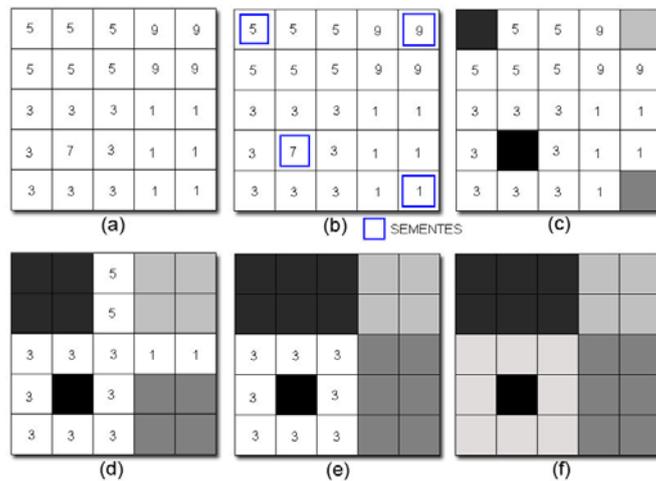


Figura 1 – Algoritmo de Segmentação de Imagens do Software SPRING

#### 4. Ajuste de Parâmetros da Segmentação

##### 4.1 Procedimento de Ajuste

Nesse trabalho propõe-se um método baseado em AG para o ajuste de parâmetros de segmentação. Cada indivíduo corresponde a uma solução possível, ou seja, a um conjunto de valores de parâmetros de segmentação. Cada gene representa um parâmetro específico. A avaliação de uma solução (indivíduo) é calculada comparando-se o resultado do procedimento de segmentação obtido a partir dela com uma segmentação de referência (Figura 2).

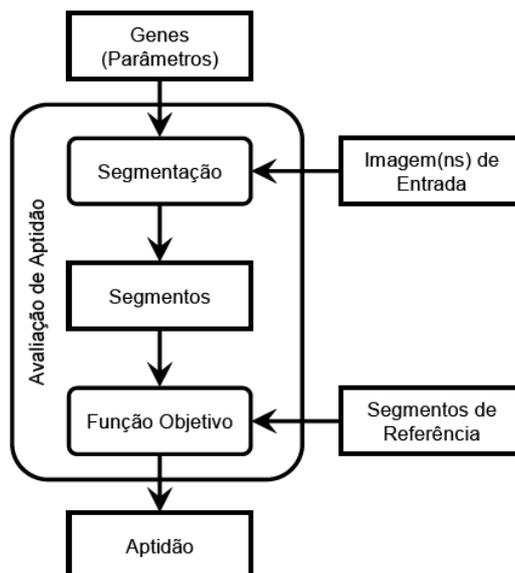


Figura 2 – Avaliação da aptidão (Feitosa et al., 2007).

Os valores dos parâmetros (genes) que compõem o conjunto inicial de soluções (população inicial) são gerados aleatoriamente. Ao longo do processo de otimização, as melhores soluções (indivíduos mais aptos) são selecionadas e novas soluções são criadas a

partir delas (reprodução). A avaliação das soluções (avaliação de aptidão) é a base para a seleção das soluções que serão submetidas à reprodução.

O processo evolucionário termina após um número fixo de ciclos (gerações), e os valores dos parâmetros de segmentação (genes) da melhor solução (indivíduo mais apto) encontrada no último ciclo é o resultado final do procedimento de ajuste (Feitosa et al., 2007).

## 4.2 Reprodução

Os seguintes operadores genéticos foram utilizados (Davis, 1990; Michalewicz, 1994): cruzamento de um ponto: alguns dos valores de parâmetros de segmentação (genes) em duas soluções (indivíduos) são trocados; cruzamento aritmético: uma combinação linear de valores de parâmetros em duas soluções é realizada; mutação: o valor de um parâmetro de segmentação é modificado de maneira aleatória; dois tipos de mutação creep: o valor de um ou mais parâmetros de segmentação em uma solução é ajustado (adicionado ou subtraído) por um valor, grande ou pequeno, gerado aleatoriamente (Feitosa et al., 2007).

## 4.3 Função Objetivo

A tarefa de ajustar os parâmetros de um algoritmo de segmentação consiste em encontrar os valores que levem o algoritmo a produzir um resultado ótimo, medido a partir de um critério de qualidade apropriado. A qualidade de uma solução (aptidão de um indivíduo) deve refletir de algum modo o grau de similaridade entre a segmentação produzida a partir destes valores e uma segmentação de referência. Tal referência consiste de um conjunto de segmentos, tipicamente delimitados sobre a imagem analisada por um intérprete, que representam sua percepção do que seja uma segmentação ideal. O que se procura é o conjunto de valores de parâmetros de segmentação que produza o resultado mais consistente com a referência (Feitosa et al., 2007).

Em termos formais, dado um conjunto de parâmetros  $P$ , e a função objetivo  $F(P_k)$ , a tarefa do AG consiste em procurar o vetor de parâmetros  $P_{opt}$  para qual o  $F$  alcança o seu mínimo. O problema é formulado matematicamente pelas Equações de 1 a 5 (Espindola et al., 2005, 2006).

$$P_{opt} = \arg \min_P [F(P_k)] \quad \text{(Equação 1)}$$

$$F(P_k) = F[Ho_k(v_i), Se_k(\mu_i)] \quad \text{(Equação 2)}$$

$$F(P_k) = (Ho_k - Ho_r) + (Se_k - Se_r) \quad \text{(Equação 3)}$$

$$Ho_k = \frac{\sum_{i=1}^n a_i \cdot v_i}{\sum_{i=1}^n a_i} \quad \text{(Equação 4)}$$

$$Se_k = \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} (\mu_i - \bar{\mu}) \cdot (\mu_j - \bar{\mu})}{\sum_{i=1}^n (\mu_i - \bar{\mu})^2} \quad \text{(Equação 5)}$$

Onde:

$Ho_k$  é a homogeneidade interna da segmentação;

$Se_k$  é a separabilidade entre vizinhos da segmentação;

$Ho_r$  é a homogeneidade interna da segmentação de referência;  
 $Se_r$  é a separabilidade entre vizinhos da segmentação de referência;  
 $v_i$  é a variância estimada dos níveis de cinza dos pixels da região  $R_i$ ;  
 $a_i$  é a área da região  $R_i$ ;  
 $n$  é o número de regiões da segmentação;  
 $\mu_i$  é a média estimada dos níveis de cinza dos pixels da região  $R_i$ ;  
 $\bar{\mu}$  é a média estimada dos níveis de cinza dos pixels nas regiões consideradas; e  
 $w_{ij}$  são os elementos da matriz de proximidade espacial normalizada.

## 5. Experimentos

Para avaliar o desempenho do método proposto a função objetivo (Equação 3) foi testada usando-se a ferramenta Genetic Algorithm Tool do software MATLAB 7.1. A ferramenta Genetic Algorithm Tool é uma interface gráfica que permite usar AG sem programação via linha de comando.

Esta série de experimentos tem o propósito de testar a habilidade do AG de convergir para a solução que minimiza a função objetivo. Todos os resultados discutidos neste trabalho foram produzidos pelo AG operando com a seguinte configuração: população de 50 indivíduos, 40 gerações, com 10% dos indivíduos mais aptos mantidos de uma geração para a seguinte (Feitosa et al., 2007).

A imagem utilizada neste trabalho corresponde a um recorte de 100x100 pixels de uma cena do sensor Landsat-7/ETM+, banda espectral 3 ( $0,63\mu m - 0,69\mu m$ ), resolução espacial de 30 metros, órbita 220/74, de 14 de agosto de 2001. A imagem em questão foi manipulada de forma a melhorar a sua qualidade visual. Tal manipulação foi realizada por meio do aumento do contraste, pela expansão do histograma da imagem com a aplicação da função de contraste linear.

Os resultados obtidos nesta série de experimentos são relativos aos parâmetros  $v_i$ ,  $a_i$ ,  $n$  e  $Se_k$ . A aptidão encontrada foi de 0,11, que gera uma segmentação com valores de limiares de área e similaridades iguais a 22 e 19, respectivamente (Figura 03). A fim de comparação, outras duas segmentações foram geradas e seus valores de aptidão calculados. Os resultados indicam que menores valores de aptidão geram segmentações com melhores resultados visuais.

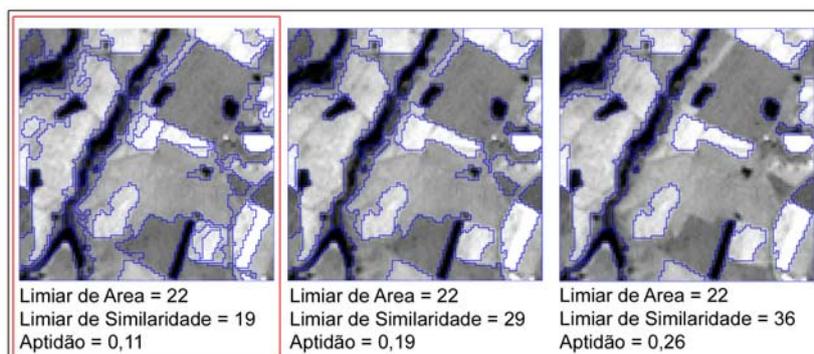


Figura 3 – Segmentação selecionada pelo AG comparada com outras segmentações.

## 6. Conclusões

Este trabalho apresentou um método para o ajuste automático dos valores de parâmetros de segmentação através de algoritmos genéticos. No método, parâmetros de segmentação foram codificados nos genes de indivíduos do AG, e a aptidão dos indivíduos foi calculada através da comparação dos segmentos gerados a partir destes genes com segmentos de referência.

Os resultados experimentais indicam a viabilidade de se utilizar a metodologia como ponto de partida para a criação de operadores de alto nível, para a extração automática de classes específicas de objetos em imagens de sensores remotos. Neste caso, um dos maiores benefícios da utilização desta metodologia seria o de permitir a adaptação dos operadores e dos parâmetros a imagens de diferentes sensores, com diferentes características espaciais ou espectrais.

## Referências Bibliográficas

- Baatz, M.; Schape, A. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. In: *Angewandte Geographische Informationsverarbeitung*, 12, 2000, Wichmann-Verlag. **Proceedings...** Wichmann-Verlag: Heidelberg, 2000.
- Beauchemin, M.; Thomson, K. P. B. The evaluation of segmentation results and the overlapping area matrix. **International Journal of Remote Sensing**, v. 18, n. 18, p. 3895-3899, 1997.
- Bhanu, B.; Ming, J. C.; Lee, S. Closed-loop adaptive image segmentation. In: *IEEE Conference on Computer Vision and Patter Recognition (CVPR)*. **Proceedings...** 1991.
- Bhanu, B.; Lee, S. **Genetic Learning for Adaptive Image Segmentation**. Luwer Academic Publishers, London, 1994.
- Bins, L.; Fonseca, L.; Erthal, G. Satellite imagery segmentation: a region growing approach. In: *Simpósio Brasileiro de Sensoriamento Remoto*, 8, 1996, Salvador. **Anais...** INPE, 1996. p. 677-680. ISBN 85-17-00014-5.
- Borsotti, M.; Campadelli, P.; Schettini, R. Quantitative evaluation of color image segmentation results. **Pattern Recognition Letters**, v. 19, n. 8, p. 741-747, 1998.
- Câmara, G.; Souza, R.; Freitas, U.; Garrido, J. SPRING: Integrating remote sensing and GIS with object-oriented data modelling. **Computers and Graphics**, v. 15, n. 6, p. 13-22, 1996. Disponível em: [www.dpi.inpe.br/gilberto](http://www.dpi.inpe.br/gilberto). Acesso em: 22 abr. 2005.
- Darwin, C. **On the Origin of Species by Means of Natural Selection or the Preservation of Favored Races in the Struggle for Life**. John Murray, 1859.
- Davis, L. **Handbook of Genetic Algorithms**, Van Nostrand Reinhold, New York, 1990.
- Espindola, G. M.; Câmara, G.; Reis, I. A.; Bins, L. S.; Monteiro, A. M. Spatial autocorrelation indicators for evaluation of remote sensing image segmentation Algorithms. In: *GIS and Spatial Analysis Annual Conference of the International Association for Mathematical Geology*, 2005, Toronto. **Proceedings...** Toronto: IAMG, 2005.
- Feitosa, R. Q. ; Costa, Gilson Alexandreostwal Pedro da ; Cazes, Thiago . Ajuste Automático de Parâmetros de Segmentação. In: Thomas Blaschke; Hermann Johann Heinrich Kux. (Org.). **Sensoriamento Remoto e SIG avançados**. 2 ed. São Paulo: Oficina de Textos, 2007, v. 1, p. 129-144.
- \_\_\_\_\_. Parameter selection for region-growing image segmentation algorithms using spatial autocorrelation. **International Journal of Remote Sensing**, v. 27, n. 14/20, p. 3035-3040, 2006.
- Fu, K. S.; Mui, J. K. A survey on image segmentation. **Pattern Recognition**, v. 13, p. 3-16, 1980.
- Haralick, R. M.; Shapiro, L. G. Survey - Image segmentation techniques. **Computer Vision, Graphics, and Image Processing**, v. 29, p. 100-132, 1985.
- Jiang, H.; Toriwaki, J. Comparative performance evaluation of segmentation methods based on region growing and division. **Systems and Computers in Japan**, v. 24, n. 13, p. 28-42, 1993.

- Kartikeyan, B.; Sarkar, A.; Majumder, K. L. A segmentation approach to classification of remote sensing imagery. **International Journal of Remote Sensing**, v. 18, n. 9, p. 1695 - 1709, 1998.
- Kueblbeck C., Wagner, T. Automatic configuration surface inspection systems. In: A. Ravishankar Rao and Ning Chang (editors), 1997, San Jose, California. **Proceedings...** San Jose: SPIE: Machine Vision Applications in Industrial Inspections V, Vol. 3029, 1997.
- Levine, M. D.; Nazif, A. M. Dynamic measurement of computer generated image segmentation. **IEEE Trans. on Pattern Analysis and Machine Intelligence**, v. 7, n. 2, p. 155, 1985.
- Lucca, E. V. D. **Avaliação e comparação de algoritmos de segmentação de imagens de radar abertura sintética**. 1998. 2007p. (INPE - 7507-TDI/721). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1998.
- Meinel, G.; Neubert, M. A comparison of segmentation programs for high resolution remote sensing data. **International Archives of Photogrammetry and Remote Sensing**, v. 35, n. Part B, p. 1097-1105, 2004.
- Michalewicz, Z. **Genetic Algorithms + Data Structures = Evolution Programs**. Springer-Verlag, New York, 1994.
- Moigne, J. L.; Tilton, J. C. Refining image segmentation by integration of edge and region data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 33, n. 3, p. 605-615, 1995.
- Oliveira, J. C.; Formaggio, A. R.; Epiphany, C. N. Index for the evaluation of segmentation (IAVAS): an application to agriculture. **Mapping Science and Remote Sensing**, v. 40, n. 3, p. 155-169, 2003.
- Pal, N. R.; Pal, S. K. A review on image segmentation techniques. **Pattern Recognition**, v. 26, n. 9, p. 1277, 1993.
- Pekkarinen, A. A method for the segmentation of very high spatial resolution images of forested landscapes. **International Journal of Remote Sensing**, v. 23, n. 14, p. 2817-2836, 2002.
- Schoenmakers, R. P. H. M.; Wilkinson, G. G.; Schouten, T. E. Segmentation of remotely sensed images: a re-definition for operational applications. In: International Geoscience and remote Sensing Symposium, 2, 1991, Espoo. **Proceedings...** Espoo: IEEE Press, 1991. p. 1087-1090.
- Soh, L.-K.; Tsatsoulis, C. Segmentation of satellite imagery of natural scenes using data mining. **IEEE Transactions on Geoscience and Remote Sensing**, v. 37, n. 2, p. 1086, 1999.
- Tilton, J.; Lawrence, W. Interactive analysis of hierarchical image segmentation. In: International Geoscience and Remote Sensing Symposium IGARSS-2000, 2000, New York. **Proceedings...** New York: IEEE Press, 2000. p. 733-735. ISBN 0-7803-6359-0.
- Woodcock, C.; Harward, V. J. Nested-hierarchical scene models and image segmentation. **International Journal of Remote Sensing**, v. 13, n. 16, p. 3167-3187, 1992.
- Xu, Y.; Olman, V.; Uberbacher, C. A segmentation algorithm for noisy images: desing and evaluation. **Pattern Recognition Letters**, v. 19, n. 13, p. 1213-1224, 1998.
- Zhang, Y. J. A survey on evaluation methods for image segmentation. **Pattern Recognition**, v. 29, n. 8, p. 1335-1346, 1996.
- Zucker, S. W. Region growing: childhood and adolescence. **Computer Graphics and Image Processing**, v. 15, p. 382-399, 1976.