

Desenvolvimento de um método híbrido para segmentação imagens utilizando crescimento de regiões e lógica *fuzzy*

Diego Mendonça Arantes ¹
Antonio Cesar Germano Martins ²

¹ Universidade de São Paulo - USP/EESC
Av. Trabalhador São-carlense, 400 - Caixa Postal 292 -13560-970 - São Carlos - SP, Brasil
diegomendonca@sc.usp.br

² Universidade Estadual Paulista “Julio de Mesquita Filho” – UNESP/Sorocaba
Av. Três de Março, 511 – 18087-180 - Sorocaba - SP, Brasil
amartins@sorocaba.unesp.br

Abstract. Image segmentation is a process that groups pixels related to one or more local properties obtained from the values of the pixels or numerical results performed on a neighborhood. It is considered as a critical step in the system of image processing, when considering systems that uses classical logic. Errors committed during this step can influence so undesirable the results produced in further analysis. One way to reduce this problem is to introduce the fuzzy paradigm in segmentation techniques, so the appropriate representation of uncertainty allows more information to be maintained throughout the process producing a result with a degree of uncertainty. This article presents a hybrid segmentation method based on region growing technique using classical logic to determine an original region of interest and fuzzy logic to make general segmentation of all features that resemble the original region of interest according to a criterion of similarity predetermined by a membership function.

Palavras-chave: image processing, region growing, fuzzy logic, processamento de imagens, crescimento de regiões, lógica *fuzzy*.

1. Introdução

O processamento digital de imagens de satélite aliado às técnicas de sensoriamento e geoprocessamento vem sendo utilizado na avaliação da evolução de processos de crescimento de regiões urbanas e também agropecuárias que geralmente ameaçam remanescentes florestais, além da identificação e acompanhamento de impactos causados por grandes empreendimentos ou fenômenos naturais.

Neste contexto, é importante que a manipulação das imagens seja eficaz e que permita o diagnóstico e a análise de forma eficiente dos processos por um especialista, para então poder atuar na intervenção dos processos que causam a degradação do meio ambiente.

A correta implementação do processo de segmentação é uma etapa fundamental na análise de uma imagem. Embora não seja um tema novo, é uma área de intensa pesquisa e interesse, uma vez que métodos que funcionam muito bem em determinadas situações, não são adequados em outras.

As imagens do satélite LandSat 5, apesar da baixa resolução espacial, 30 metros, são apropriadas ao estudo do crescimento urbano e tem um custo muito inferior quando comparadas as imagens de equipamentos com maior resolução como, por exemplo, os do QuickBird, com resolução de até 0,61 metros, ou do Ikonos, com até 1 metro (MOREIRA, 2003; SCHOWENGERDT, 1997).

Um pixel em uma imagem de satélite corresponde a uma área na superfície terrestre que pode conter um único ou diversos tipos de uso e ocupação. No caso de regiões com um único tipo de cobertura a classificação dos pixels da imagem pode ser facilmente obtida, no entanto, quando se tem mais de um tipo, podem ocorrer falhas nesta classificação ao se usar a lógica clássica, por isso o uso da lógica *fuzzy* na análise da imagem permite a atribuição de um valor de pertinência aos pixels e suas classificações podem ser realizadas em uma etapa posterior de

acordo com a análise de seus vizinhos (GULIATO, 1998).

Este trabalho tem por objetivo apresentar a metodologia híbrida de segmentação de áreas urbanas em imagens de satélite LandSat 5 baseado em lógica clássica, através de crescimento de regiões, e lógica *fuzzy*.

2. Metodologia de Trabalho

2.1 Segmentação de imagens

O método híbrido de segmentação, que se apresenta neste trabalho, é baseado na técnica de crescimento de regiões utilizando-se lógica clássica para se determinar uma região original de interesse e a lógica *fuzzy* para se fazer a segmentação geral de todas as feições que se assemelham à região original de interesse de acordo com um critério de semelhança pré-estabelecido.

A utilização de duas metodologias trabalhando conjuntamente, uma utilizando os conceitos da lógica clássica e outra utilizando os conceitos da lógica *fuzzy*, constituem um método híbrido de classificação de certa complexidade que merece especial atenção.

A segmentação de imagens é definida como um processo que agrupa pixels com relação a uma ou mais propriedades locais, essas propriedades são obtidas a partir dos valores dos pixels ou resultados numéricos da execução de operações sobre uma vizinhança do pixel em questão, por exemplo, média dos valores de uma vizinhança, brilho ou taxa de variação (GONZALEZ e WOODS, 2000).

A etapa de segmentação de imagens é considerada como uma das etapas críticas no sistema de processamento de imagens, principalmente quando se considera sistemas convencionais, ou seja, aqueles que se utilizam de lógica clássica. Erros cometidos durante esta etapa podem influenciar de forma indesejável resultados produzidos por análises posteriores.

Uma maneira de reduzir este problema é introduzir o paradigma difuso nas técnicas de segmentação, assim a representação adequada da incerteza permite que mais informações sejam mantidas durante todo o processo produzindo um resultado com grau de incerteza associado.

2.2 Métodos clássicos de segmentação

Os métodos de segmentação clássica são aqueles que utilizam funções características para produzir a representação das regiões extraídas da imagem, a partir de uma função binária definida como $f:I \rightarrow \{0,1\}$, onde I é o conjunto de pixels da imagem, sendo 0 (zero) associado aos pixels que não pertencem a região de interesse e 1 (um) aos que pertencem (GULIATO, 1998). A divisão destes métodos está representada na Figura 1.

Os métodos baseados em Limiarização partem do pressuposto de que os pixels pertencentes a uma mesma região possuem características de tonalidade similares entre si. Os limiares são obtidos ao se analisar os histogramas das imagens (GONZALEZ e WOODS, 2000) e se procurar por valores que separem as distribuições de intensidades presentes.

As limitações da aplicação destes métodos advêm do fato de não se levar em conta a distribuição espacial dos pixels, resultando em imagens que contenham pixels que pertencem a objetos ou regiões distintas. Além disto, imagens que possuem textura aleatória não preenchem o requisito básico de pixels com características de tonalidade similares entre si. No entanto, imagens que contenham objetos de interesse com características de tonalidade próximas e formadas por pixels que possam ser identificados como agrupados, podem ser tratados com técnicas de limiares.

Métodos baseados em bordas ou Descontinuidades levam em consideração o fato de que entre duas regiões deve existir uma fronteira. Desta forma, procura-se identificar descontinuidades significativas na imagem que possam representar as bordas da região. A

operação clássica utilizada como exemplo é o gradiente que intensifica as variações de tonalidade presentes resultando em uma imagem com pixels mais intenso, permitindo a binarização da imagem e a identificação dos contornos. Um dos principais problemas na aplicação do gradiente é a obtenção de regiões com bordas abertas devido a ruídos ou uso de iluminação não uniforme quando da aquisição da imagem. Além disto, a operação com o gradiente não se aplica a imagens com textura aleatória.

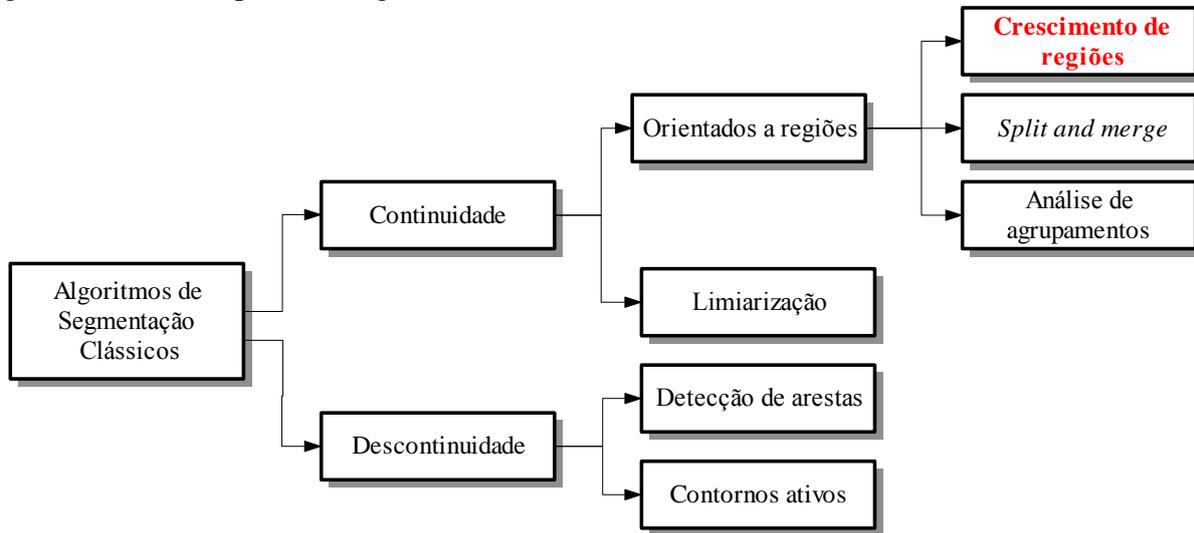


Figura 1. Hierarquia dos métodos de segmentação. Modificado de Guliato (1998).

Uma outra abordagem para se identificar bordas e que resultam em contornos fechados são os modelos baseados em *snakes* (KASS, WITKIN e TERZOPOULOS, 1987) que são curvas paramétricas fechadas que se deformam dinamicamente e movem-se em direção as bordas presentes na imagem sob a influência de forças internas e externas, através da minimização de uma função energia. Apesar dos bons resultados obtidos com estes modelos, os tempos de processamento envolvidos são longos e existem limitações referentes a correta identificação dos parâmetros de parada do processo (JALBA, WILKINSON e ROERDINK, 2004).

Os métodos híbridos procuram utilizar técnicas acopladas que visam minimizar as limitações de cada uma quando usadas separadamente.

O correto reconhecimento de um objeto é um processo bastante complexo e geralmente está ligado à comparação das informações obtidas pela segmentação com aquelas acumuladas em experiências anteriores (SIMÕES e COSTA, 2003).

2.3 Métodos de segmentação orientados a regiões

Estes métodos procuram diretamente a região de interesse, cujos critérios podem ser definidos como áreas que compartilham propriedades comuns. Formalmente definem-se regiões da seguinte maneira (GULIATO, 1998):

Seja X uma imagem e P um predicado lógico definido sobre conjuntos de pontos conectados. A segmentação é então obtida particionando-se X em N conjuntos, X_1, X_2, \dots, X_N , tais que:

$$i) \quad \bigcup_{i=1}^N X_i = X \quad (1)$$

$$ii) \quad X_i \text{ é conectada, } i = 1, 2, \dots, N \quad (2)$$

$$\text{iii) } X_i \cap X_j = \emptyset, \text{ para } i \neq j \quad (3)$$

$$\text{iv) } P(X_i) = \text{verdadeiro}, i = 1, 2, \dots, N \quad (4)$$

$$\text{v) } P(X_i \cup X_j) = \text{falso}, \text{ para } i \neq j \text{ e } X_i X_j \text{ adjacentes} \quad (5)$$

Sobre as equações pode-se entender que a primeira, Equação 1, é uma exigência para que a segmentação seja completa, ou seja, todos os pixels de uma imagem devem pertencer a uma região. A Equação 2 exige que as regiões sejam conectadas. A Equação 3 garante que as regiões não se sobreponham, assim sendo, um pixel não pertence a mais de uma região. O critério de homogeneidade é introduzido na Equação 4, este critério pode avaliar, como no caso, a média dos valores dos pixels vizinhos. E por último, a Equação 5 indica que duas regiões são diferentes no que se refere ao critério de homogeneidade, pois, caso contrário, não seriam regiões diferentes, mas sim iguais (GULIATO, 1998).

2.4 Crescimento de regiões

Algoritmos baseados em crescimento de regiões consistem basicamente de três passos:

- i) primeiramente, um ou mais pixels são selecionados e denominados pixel semente ou região semente da imagem, podendo ser obtidos interativamente ou automaticamente e são assumidos a pertencerem à região de interesse, sendo que a variação da escolha do pixel semente ou da região semente localizados na mesma região de interesse não produzem alterações consideráveis nos resultados finais da segmentação (ARANTES, MARTINS e LOURENÇO, 2006);
- ii) num segundo passo, os pixels vizinhos ao pixel semente ou região semente são examinados para verificar se satisfazem a condição de aceitação;
- iii) por último, os pixels que satisfazem o condição de aceitação devem ser incluídos à região que está sendo analisada, provocando seu crescimento. Os dois últimos passos são repetidos até que nenhum pixel conectado ao pixel semente ou região semente satisfaça a condição de aceitação.

A decisão de incluir um pixel à região sendo analisada é freqüentemente baseada na comparação feita entre a diferença de propriedades locais das sub-regiões envolvidas e um valor pré-definido como limiar. O sucesso do processo de segmentação está diretamente associado á seleção das propriedades locais e de um limiar que define um intervalo de tolerância no qual essas propriedades podem variar.

Em geral, os intervalos de tolerância dos algoritmos de segmentação podem basear-se em conhecimento *a priori*, na análise de histogramas ou processos de tentativa e erro (GULIATO, 1998). Arantes e Martins (2007) constataram a partir das idéias iniciais de Gonzalez e Woods (2000) que o ajuste de funções gaussianas ao histograma da imagem produzem resultados consideravelmente satisfatórios na escolha de limiares para a segmentação e também na utilização destas funções como funções de pertinência.

O algoritmo de crescimento de regiões pode ser interpretado da seguinte maneira: a partir da escolha de um “pixel semente” contido em uma região de interesse e da comparação deste com seus primeiros quatro vizinhos, conforme representado na Figura 2, estes serão agregados ou não à região, de acordo com a avaliação de similaridade utilizando a lógica booleana, ou seja, o resultado da avaliação das características de dois pixels resultará em 1 se houver similaridade, ou 0 caso não haja.

Este tipo de algoritmo deve: realizar a comparação entre o pixel semente e os seus vizinhos obedecendo ao critério de agregação, agregá-los, ou não, à região, prosseguir para

um próximo pixel e repetir o processo descrito. Implementa-se uma sistemática para a comparação do pixel semente com seus vizinhos e a escolha do próximo “pixel semente”, sendo quatro o número de pixels que podem ser escolhidos como o próximo “pixel semente”, contudo, ao se escolher um, deve-se manter o restante em espera e retornar a eles em algum momento posterior.

$a_{i-1,j-1}$	$a_{i-1,j}$	$a_{i,j-1}$
$a_{i,j-1}$	$a_{i,j}$	$a_{i,j+1}$
$a_{i+1,j-1}$	$a_{i+1,j}$	$a_{i+1,j+1}$

Figura 2. Dado o pixel semente $a_{i,j}$, os pixels $a_{i,j-1}$, $a_{i-1,j}$, $a_{i,j+1}$, $a_{i+1,j}$ são chamados de primeiros quatro vizinhos.

Estes critérios de agregação podem utilizar lógica clássica, onde se classifica um pixel como pertencente ou não a uma região, ou lógica *fuzzy*, quando se analisa a probabilidade de um pixel pertencer a uma região de interesse (GULIATO et al, 1999). Entre as características utilizadas nos critérios de agregação, estão: nível de cinza, cor, textura ou estatística da população de pixels.

Há duas maneiras de se implementar o algoritmo de crescimento de regiões: utilizando funções recursivas ou por pilhas, nesta última cria-se uma pilha e coloca-se o “pixel semente” como o seu primeiro elemento. A cada passo, avalia-se, em determinada ordem e de acordo com um critério de agregação, se os primeiros quatro vizinhos do elemento no topo da pilha fazem parte da região de interesse. Caso o critério seja satisfeito, o pixel é colocado na pilha. Os pixels são retirados do topo da pilha quando todos os seus vizinhos tiverem sido avaliados e já tenham sido retirados da pilha ou classificados como não pertencentes a região de interesse. A cada avaliação cria-se um rótulo identificando os pixels como já analisados para se evitar que o algoritmo entre em um laço infinito de operações em que um pixel testa outro e vice-versa. O processo é terminado quando a pilha estiver vazia.

2.3 Métodos de segmentação baseados em lógica *fuzzy*

Seja um conjunto domínio Ω , um conjunto imagem L e uma função Δ que mapeia os elementos de Ω em L . Na lógica clássica, o conjunto L possui somente valores binários, ou seja, dois valores que podem ser 0 ou 1, ao passo que na lógica *fuzzy*, o conjunto L , também chamado de conjunto de pertinência, não está limitado aos valores 0 ou 1, podendo admitir qualquer valor no intervalo $[0,1]$.

No processamento de imagens digitais, a classificação de um pixel como sendo pertencente a uma região pode ser obtida determinando-se uma função de pertinência apropriada que avalia o grau de similaridade entre o “pixel semente” e seus vizinhos dentro de uma região pré-determinada. Esta função de pertinência deve possuir as seguintes características:

- i) associar um valor de pertinência àqueles pixels que possuem propriedades idênticas a região pré-determinada, obedecendo a uma sistemática;
- ii) representar o grau de similaridade entre o pixel que ora está sendo analisado, e a região pré-determinada;
- iii) decrescer monotonicamente de 1 a 0.

Em meados de 1980, a lógica *fuzzy* foi utilizada pela primeira vez na detecção de bordas por Pal e King (1980). De acordo com seus métodos, uma imagem em tons de cinza pode ser analisada usando um critério de semelhança ao atribuir aos pixels um grau de similaridade, transformando a imagem num domínio *fuzzy*. A função de pertinência realiza a classificação a partir de uma média e uma matriz de covariância. Através de passos iterativos os pixels são

analisados, sendo, em seguida, a imagem convertida para o domínio espacial.

Em 1990, quando os métodos de análise de imagens de satélites ainda eram incapazes de extrair a maior parte das informações nelas contidas, Wang (1990) já escrevia em seus trabalhos sobre a utilização da lógica *fuzzy*, usando um processo de análise supervisionada destas imagens, apresentou resultados que reduziram a perda de informações e qualidade durante a análise.

Yi e Xue-quan (2004) afirmam que a lógica *fuzzy* é capaz de representar uma imensa gama de incertezas sobre uma determinada informação. Em se tratando de detecção de bordas, consegue-se claramente visualizar esta referida gama de incertezas, pois os dados estão dispostos de uma maneira muito heterogênea. Nas últimas décadas muitos algoritmos foram apresentados para a determinação de bordas, tais como operadores de gradiente, transformada de Hough, etc. (GONZALEZ e WOODS, 2000). Estes algoritmos, em sua maioria, estão baseados na quantificação da diferença entre os níveis de cinza dos pixels de uma imagem em uma vizinhança. Contudo, estes algoritmos não produzem um resultado satisfatório no processo de detecção de bordas de alguns objetos em imagens de sensoriamento remoto. Imagens de satélites têm suas próprias características como, quantidade de dados contidos, textura variada, dispersão pela atmosfera, a radiação e a reflexão da radiação pela superfície terrestre fazendo com que as imagens fiquem borradas. Por estes vários fatores, vem se tornando necessário o desenvolvimento de uma nova metodologia, não-supervisionada, capaz de processar, automaticamente, estes tipos de imagens.

Todos estes problemas relatados desde 1980 acumulam-se quando a questão é a detecção de bordas de áreas urbanas (as bordas de uma área urbana é uma importante informação para a construção do plano diretor e para o monitoramento urbano), cujas imagens são muito heterogêneas. Console e Mouchot (1996) mostra em seus trabalhos que a metodologia da lógica *fuzzy* é capaz de suprir estas dificuldades, pois um pixel pode ser classificado de acordo com uma grade de similaridade utilizando-se a função de pertinência para esta finalidade. Nas conclusões de seus trabalhos ela afirma que a lógica *fuzzy* é mais adequada que métodos convencionais para a classificação de áreas com alta heterogeneidade.

3. Resultados e Discussão

A metodologia de segmentação desenvolvida, baseada na técnica de crescimento de regiões utilizando a lógica clássica para se determinar uma região original de interesse e a lógica *fuzzy* para se fazer a segmentação das feições que se assemelham à região de interesse de acordo com um critério de semelhança pré-estabelecido por uma função de pertinência.

Alguns passos de tratamento da imagem se fazem necessários para o desenvolvimento do método, são eles:

- i) Aplicação de Filtro Mediano: considerando que nos próximos passos será utilizada a técnica de crescimento de regiões para segmentação da região original de interesse, logo se faz necessário a aplicação de um filtro mediano formato bloco 5x5 (cinco por cinco) para suavização das feições (CRANE, 1997);
- ii) Equalização do Histograma: verifica-se que a distribuição da intensidade dos pixels na imagem após aplicação de filtros medianos é concentrada ao longo do histograma, o que pode dificultar o processo de crescimento de regiões, assim é realizado a equalização do histograma para que se tenha uma imagem cujas intensidades dos pixels seja mais distribuída ao longo do histograma (CRANE, 1997);
- iii) Crescimento de Regiões: faz-se a escolha de um pixel semente que indica a Região Original de Interesse que se deseja segmentar, e escolhe-se também o limiar de agregação, os pixels são avaliados segundo a média da região formada pelos pixels agregados em relação a este limiar;
- iv) Detecção das Bordas: este passo delimita as bordas da região segmentada no passo

anterior;

v) Aplicação de Lógica *Fuzzy*/Operador MAX (LAÉCIO et al., 2006): são definidas duas médias, μ_1 e μ_2 , a primeira referente à média da Região Original de Interesse (segmentada por Crescimento de Regiões) e a outra referente à média dos pixels concentrados nas áreas externas à Região Original de Interesse.

A Equação 6 representa a Função de Pertinência utilizada para avaliação dos pixels.

$$f(p) = \frac{1}{1 + \beta \cdot |\mu - p|} \quad (6)$$

Nesta equação, p é a intensidade do pixel em questão; β um valor atribuído aleatoriamente que define o grau de abertura da função (grau de permissividade), os valores de β devem partir de processos de tentativa e erro ou experiências anteriores do usuário; e μ a média da região que está sendo considerada.

Aplica-se o operador MAX, Equação 7, que avalia $f(p)$ e agrega os pixels da imagem que tenham valor de $f(p)$ com média μ_1 maiores do que aqueles com média μ_2 . A cada pixel agregado, as médias devem ser atualizadas.

$$\frac{1}{1 + \beta \cdot |\mu_1 - p|} > \frac{1}{1 + \beta \cdot |\mu_2 - p|} \quad (7)$$

Quando satisfeita a condição da Equação 7, que representa o critério de agregação estabelecido pelo Operador MAX, o pixel p é agregado à Região Original de Interesse e μ_1 e μ_2 são atualizados. Este processo deve ser realizado para toda a imagem em análise ou para regiões pré-determinadas, por exemplo, bordas da região original de interesse.

4. Conclusões

A aplicação do algoritmo possibilitou a identificação de características determinantes no processo de segmentação. O que se mostrou mais impactantes nos teste realizados foi o grau de adensamento da região urbana. Para obtenção de um bom resultado com o crescimento de regiões é imprescindível que regiões semelhantes estejam conectadas.

Nos resultados das segmentações das áreas urbanas pode-se verificar que regiões consideradas como solos expostos são segmentadas juntamente como áreas urbanas. Esta diferenciação não é tão evidente considerando somente a tonalidade do pixel, apesar da textura da região de solo exposto ser de fácil diferenciação da textura da área urbana nestas mesmas imagens. Isto indica que a técnica de segmentação utilizada pode ser aperfeiçoada para considerar em sua avaliação outras características na imagem além da tonalidade dos pixels.

Verificou-se que o método de segmentação utilizado neste trabalho apresenta limitações referentes à incapacidade de distinção de solo exposto e área urbana em determinadas regiões desconectadas, entretanto o algoritmo produziu resultados satisfatórios que merecem comparação à outros métodos de segmentação já utilizados em *softwares* voltados para geoprocessamento e sensoriamento remoto, sendo que estas comparações poderão ser realizadas em trabalhos futuros.

Agradecimentos

Os autores gostariam de agradecer à FAPESP – Fundação de Amparo à Pesquisa do Estado de São Paulo pela bolsa concedida para realização destes estudos.

Referências Bibliográficas

ARANTES, D. M. e MARTINS, A. C. G. **Implementação do método de ajuste de funções gaussianas para análise de imagens.** In: Simpósio de Iniciação Científica e Tecnológica (SICT), 2007, São Paulo. Anais do 9º Simpósio de Iniciação Científica e Tecnológica (SICT), 2007.

ARANTES, D. M.; MARTINS, A. C. G. e LOURENÇO, R. W. Avaliação temporal do contorno urbano da cidade de Sorocaba através do crescimento de regiões e lógica fuzzy. In: V Simpósio Brasileiro de Engenharia Ambiental, 2006, Curitiba. Anais do V Simpósio Brasileiro de Engenharia Ambiental, 2006.

CONSOLE, E. e MOUCHOT, M. C. **Fuzzy classification techniques in the urban area recognition.** In: International Geoscience and Remote Sensing Symposium, maio de 1996, Lincoln, Nebraska. p. 1373-1375.

CRANE, R. **A simplified approach to image processing:** classical and modern techniques in C. Upper Saddle River, New Jersey: Prentice-Hall, 1997.

GONZALEZ, R.C. e WOODS, R.E. **Processamento de Imagens Digitais.** São Paulo: Edgard Blücher Ltda, 2000.

GULIATO, D. **Combinação de Algoritmos de Segmentação por Operadores de Agregação.** Tese de Doutorado apresentada ao Departamento de Engenharia Elétrica da Universidade de São Paulo. São Paulo em agosto de 1998.

JALBA, A. C., WILKINSON, M. H. F. e ROERDINK, J. B. T. M. **CPM: A Deformable Model for Shape Recovery and Segmentation Based on Charged Particles.** IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 26, no. 10, pp. 1320 – 1335, outubro de 2004.

KASS, M., WITKIN, A. e TERZOPOULOS, D. **Snakes: Active contour models.** International Journal of Computer Vision, vol. 1. pp. 321-331, 1987.

LAÉCIO, C. B. et al. **Introdução à Teoria dos Conjuntos Fuzzy com Aplicações.** In: Simpósio de Aplicações em Lógica Fuzzy. Sorocaba/SP. 2006.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicações.** 2. ed. Viçosa, MG: UFV, 2003.

PAL, S. R. e KING, R. A. **Image Enhancement Using Fuzzy Sets.** Electronics Letters, Vol.16(10), pp. 376-378, 1980.

SCHOWENGERDT, R. A. Remote Sensing: Models and methods for image processing. 2. ed. San Diego, California: Academic Press, 1997.

SIMÕES, A. S. e COSTA, A. H. R. **Classificação de laranjas baseada em padrões visuais.** Anais do 6º Simpósio Brasileiro de Automação Inteligente – SBAI 2003. Sociedade Brasileira de Automática - SBA. CDROM. Setembro 14-17, pp. 77-81. Bauru, 2003.

WANG, F. **Fuzzy supervised classification of remote sensing images.** In: IEEE Transactions on Geoscience and Remote Sensing, vol. 28, n. 2, março de 1990, p. 194-201.

YI, L. e XUE-QUAN, C. **An edge detection algorithm of remote sensing images based on fuzzy sets.** In: International Conference on Communications, Circuits and Systems, 2004, Chengdu, China, p. 984-988.