



Revista Brasileira de Cartografia (2013) N^o 65/3: 441-453
Sociedade Brasileira de Cartografia, Geodésia, Fotogrametria e Sensoriamento Remoto
ISSN: 1808-0936

UM NOVO MÉTODO DE SEGMENTAÇÃO DE IMAGEM COM ABORDAGEM BASEADA EM BORDAS E REGIÕES

A New Image Segmentation Method Based on Edge and Region Detection

Rogério Galante Negri¹ & Marcus Fabiano Saldanha Silva^{1,2}

¹Instituto Nacional de Pesquisas Espaciais - INPE

Divisão de Processamento de Imagens - DPI

Av. dos Astronautas, 1.758 – 12227-010 – São José dos Campos – SP – Brasil
{rogerio, saldanha}@dpi.inpe.br

²Diretoria de Serviço Geográfico – DSG

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

Recebido em 03 de maio, 2012/ Aceito em 03 de julho, 2012

Received on May 03, 2012/ Accepted on July 03, 2012

RESUMO

Uma das principais fontes de informações de dados espaciais são as imagens obtidas por sensoriamento remoto. Os recentes avanços tecnológicos têm proporcionado o desenvolvimento de novos satélites, os quais são capazes de realizar medidas mais precisas e, juntamente com o aumento na quantidade de satélites em órbita a disponibilidade das imagens de sensoriamento remoto tem aumentado. Estes fatos, por sua vez, têm motivado o desenvolvimento de novos métodos para o processamento e extração de informações sobre tais imagens. Dentre esses métodos destaca-se a segmentação de imagem. Conceitualmente, a segmentação de imagem é fundamentada em características da fotointerpretação humana, que permitem a distinção entre diferentes alvos distribuídos ao longo de uma imagem. Neste contexto, este trabalho apresenta um novo método de segmentação de imagens que integra conceitos de segmentação baseados em detecção de bordas e regiões. Uma análise comparativa entre os métodos proposto e o método Crescimento de Regiões é conduzida sobre dois estudos de caso que envolvem dados reais e simulados. Os resultados obtidos mostram que o método proposto neste estudo apresenta melhores índices de ajuste quando é permitida a segmentação de alvos com pequenas dimensões.

Palavras chaves: Segmentação de Imagem, Detecção de Bordas, Detecção de Regiões, Simulação.

ABSTRACT

Today, the remote sensing images are one of the main sources of spatial data information. The recent technological advances had provided better sensors and the increase in the launch of new satellites increased the availability of remote sensing images. These facts has motivated the development of new methods to process and extract information from such images. One of these methods is known as image segmentation. Conceptually, the image segmentation is based on characteristics of human photointerpretation, which allow distinguishing the different targets distributed over the image. In this context, this paper presents a new method of image segmentation which integrates concepts of edge and regions detection. A comparative analysis of the proposed method and the Region Growth method is conducted on

two study cases involving real and simulated images. The results obtained show that the proposed method provides better fit when are allowed the segmentation of targets with small dimensions.

Keywords: Image Segmentation, Edge Detection, Region Detection, Simulation.

1. INTRODUÇÃO

Atualmente, diversos campos da atividade humana têm recorrido a imagens da superfície terrestre para obter informações a respeito desta. Com os recentes avanços tecnológicos em sensoriamento remoto, é cada vez maior a quantidade de fontes de informação sobre a Terra.

Este número crescente de fontes de informação associado à aquisição contínua de dados resulta na geração de volumosos aglomerados de dados, introduzindo conseqüentemente dificuldades em sua manipulação, interpretação e extração de informações úteis. Isso torna importante o desenvolvimento de métodos e ferramentas que visem organizar e analisar os dados de forma automática.

A simplificação da representação é uma das questões centrais relacionadas à extração de informações sobre as imagens de sensoriamento remoto. Um exemplo de simplificação consiste no particionamento da imagem em regiões homogêneas. Esta abordagem compreende, de modo geral, os métodos de *segmentação de imagem*. Estes métodos podem realizar o processo de identificação de regiões de diferentes maneiras, seja a partir da identificação das bordas que delimitam as regiões, pelo agrupamento de *pixels* semelhantes ou mesmo definindo limiares para separação de *pixels*. A utilização dos métodos de segmentação de imagens nas aplicações em geoprocessamento enfatiza a delimitação de regiões, por exemplo, florestas, estradas, rios, áreas agrícolas, etc.

Devido às diversas finalidades e tipos de imagens disponíveis, não existe um método global para segmentação de imagens. Este fato motiva o constante estudo e desenvolvimento de diferentes métodos de segmentação.

Neste enfoque, este trabalho apresenta um novo método automático de segmentação de imagem, o qual é fundamentado em conceitos de detecção de bordas e agrupamento entre *pixels*. A detecção das bordas é conduzida a partir de uma função de diferenciação. O resultado desta diferenciação fornece um arranjo espacial para

realização de um processo de agrupamento entre *pixels*. Tal processo de agrupamento consiste no principal diferencial do método proposto.

2. SEGMENTAÇÃO DE IMAGENS

2.1. Visão geral sobre segmentação de imagens

A segmentação de imagem é um importante método utilizado em problemas de análise de imagens. Suas aplicações variam desde o controle de qualidade industrial à medicina, navegação de robôs, aplicações militares, exploração geofísica, sensoriamento remoto, etc (CUFÍ *et al.*, 2002). Devido a sua importância, o desenvolvimento de algoritmos mais precisos e confiáveis torna-se uma necessidade.

O objetivo da segmentação é particionar a imagem em um conjunto de regiões visualmente distintas e uniformes com relação a alguma propriedade, como o nível de cinza, textura ou cor (ROSENFELD; KAK, 1982). Conforme estruturado por Gonzalez e Woods (2002), os métodos de segmentação de imagem baseiam-se em duas propriedades básicas dos *pixels* com relação a sua vizinhança local: *descontinuidade* e *similaridade*. Quando fundamentados nas propriedades de descontinuidade dos *pixels*, os métodos de segmentação são denominados “baseados em bordas”, já quando fundamentados nas características de similaridade, são denominados “baseados em regiões”.

A abordagem baseada em bordas usa o postulado que mudanças no nível de cinza dos *pixels* acontecem quando existe um limite entre duas regiões. A detecção de zonas de fronteira entre regiões é usualmente realizada por operações de diferenciação de primeira ordem, por exemplo, através dos filtros de gradiente Sobel (SOBEL, 1970) e Roberts (ROBERTS, 1965). A vantagem essencial da abordagem baseada em bordas refere-se a sua arquitetura e facilidade de implementação. Em contrapartida, uma das principais limitações desta abordagem procede da maneira como as bordas são identificadas, as quais geralmente não

correspondem aos limites verdadeiros dos objetos e é suscetível a identificação de bordas falsas (ACHARYA; RAY, 2005).

Por outro lado, a abordagem baseada em regiões tenta isolar áreas da imagem que são homogêneas segundo determinadas características. Para isso, os *pixels* são submetidos a um processo de agrupamento. Durante o processo de segmentação, as áreas candidatas podem aumentar de tamanho, serem comprimidas, divididas, criadas ou eliminadas. Dentre diferentes métodos de segmentação baseado em regiões, o Crescimento de Regiões (*Region Growing*), introduzido em Zucker (1976), é um dos mais populares (WAN; HIGGINS, 2003; ROSE *et al.*, 2010).

A segmentação por Crescimento de Regiões parte da seleção de *pixels* aleatórios, denominados *sementes*, de onde “crescem” as regiões a partir da união de *pixels* vizinhos que são similares de acordo com determinado critério. Este critério, também denominado por *Predicado*, geralmente é um valor limite adotado para determinar se um *pixel* deve pertencer a uma região ou para comparar a similaridade de duas regiões. Nestas comparações podem ser observados atributos como a intensidade média das regiões, sua variância, textura, tamanho, forma, *etc.* Uma discussão apurada sobre o método Crescimento de Regiões e diferentes tipos de *Predicados* é apresentada em Besl e Jain (1988).

Dentre diferentes qualidades, o método Crescimento de Regiões é capaz de proporcionar bons resultados de segmentação mesmo em imagens com ruído, permite o uso de diferentes critérios e é pouco sensível aos *pixels* semente utilizados. Por outro lado, este método é computacionalmente custoso, a variação de intensidade na imagem geralmente provoca supersegmentação, e as regiões segmentadas tendem a ser fragmentadas. Ainda, segundo Chang e Chen (2008), o método Crescimento de Regiões considera apenas a homogeneidade das regiões para o delineamento dos limites das mesmas durante o processo de segmentação. Esta característica pode ser observada como uma fragilidade ou desvantagem do método, uma vez que resultados inadequados podem ser produzidos.

Dessa forma, devido a diferentes comportamentos que as imagens podem apresentar, os métodos de segmentação tendem a falhar na

geração de resultados acurados. Uma solução a este problema é proposta com a integração de métodos baseados em bordas e regiões (TABB; AHUJA, 1997; PAVLIDIS; LIOW, 1990; SINGH *et al.* 2011).

2.2. Métricas para avaliação de segmentação

Para avaliação dos resultados de segmentação, as medidas quantitativas apresentadas em Delves *et al.* (1992) são uma opção. Estas medidas baseiam-se nas diferenças entre a imagem segmentada e seu respectivo resultado esperado, denominado por *imagem de referência*.

Segundo Delves *et al.* (1992), a primeira etapa da avaliação de uma segmentação consiste na comparação de regiões detectadas na imagem segmentada e na imagem de referência. O coeficiente de ajuste entre as regiões da segmentação de referência e suas respectivas regiões segmentadas pode ser calculado por critérios de posição, valor médio dos *pixels* da região, dimensão e forma. De modo formal, sejam *R* e *S* as imagens de referência e segmentada, compostas por *m* linhas e *n* colunas e particionadas respectivamente em *k* e *l* regiões. Denotando as regiões de *R* por $r_i, i = 1, \dots, k$, assim como as regiões de *S* por $s_j, j = 1, \dots, l$, são definidas as seguintes medidas entre regiões:

$$\alpha(r_i, s_j) = \frac{|\mu_x(r_i) - \mu_x(s_j)|}{m} \quad (1)$$

$$\beta(r_i, s_j) = \frac{|\mu_y(r_i) - \mu_y(s_j)|}{n} \quad (2)$$

$$\gamma(r_i, s_j) = \frac{|d(r_i) - d(s_j)|}{|d(r_i) + d(s_j)|} \quad (3)$$

$$\phi(r_i, s_j) = \frac{|\mu_v(r_i) - \mu_v(s_j)|}{|\mu_v(r_i) + \mu_v(s_j)|} \quad (4)$$

onde $d(t)$ é a quantidade de *pixels* de uma dada região *t*, enquanto $\mu_x(t)$, $\mu_y(t)$ e $\mu_v(t)$ são respectivamente os valores médios das abscissas, ordenadas e do nível de cinza dos *pixels* de *t*.

Sobre estas medidas, são definidas as matrizes:

$$G = (g_{i,j})_{k,l} : g_{i,j} = \frac{d(r_i \cap s_j)}{d(r_i \cup s_j)} \quad (5)$$

$$F = (f_{i,j})_{k,l} : f_{i,j} = \frac{\alpha(r_i, s_j) + \beta(r_i, s_j) + 0,5[\gamma(r_i, s_j) + \phi(r_i, s_j)]}{g_{i,j}} \quad (6)$$

A matriz G descreve os pares de regiões com *pixels* comuns, determinados entre as imagens segmentada e de referência, dá uma relação entre o número de *pixels* nas intersecções destes pares de regiões e provê o número total de *pixels* em cada um destes pares. Já a matriz F fornece a medida de ajuste entre regiões, considerando o tamanho, posição, forma e valor do nível de cinza das mesmas. Para cada região r_i da imagem de referência R , existe uma região s_j em S cujo valor $f_{i,j}$ é mínimo, denominada *região ajustada*.

Após identificadas as regiões ajustas da imagem segmentada, a qualidade da segmentação pode ser computada a partir das seguintes medidas de ajuste:

$$M_{pos}(r_i, s_j) = 1 - \frac{\alpha(r_i, s_j) + \beta(r_i, s_j)}{2} \quad (7)$$

$$M_{val}(r_i, s_j) = 1 - \phi(r_i, s_j) \quad (8)$$

$$M_{dim}(r_i, s_j) = 1 - \gamma(r_i, s_j) \quad (9)$$

$$M_{for}(r_i, s_j) = g_{i,j} \quad (10)$$

Estas medidas quantificam o ajuste individual de cada região. Para representar o ajuste das regiões de forma global, é computada a média aritmética dos ajustes individuais segundo cada uma das medidas. Assim, são obtidas as medidas M_{pos} , M_{val} , M_{dim} e M_{for} , que quantificam respectivamente os ajustes de posição, nível de cinza, dimensão e forma das regiões. Estas medidas estão contidas no intervalo $[0,1]$, sendo 0 o pior nível de ajuste e 1 o melhor. Ainda, é possível definir uma medida geral de ajuste das regiões, computando a média das medidas M_{pos} , M_{val} , M_{dim} e M_{for} , ou seja:

$$M_{geral} = \frac{M_{pos} + M_{val} + M_{dim} + M_{for}}{4} \quad (11)$$

3. O MÉTODO DE SEGMENTAÇÃO PROPOSTO

3.1. Concepção do método proposto

Como mencionado, uma solução para determinadas fragilidades encontradas nos métodos baseados em bordas e regiões deriva da integração de ambas as abordagens. Nesta subseção é introduzido um novo método de segmentação baseado em conceitos de detecção de bordas e regiões.

Essencialmente, este método consiste em detectar as bordas das regiões que compreendem a imagem a ser segmentada. Respeitando a delimitação imposta pelas bordas identificadas, ocorre a detecção das regiões.

A detecção das bordas é realizada por um processo de diferenciação, aplicado sobre cada *pixel* da imagem. O produto desta etapa é uma *imagem de gradientes*, cujos limites entre regiões possuem valores mais elevados com relação aos interiores das mesmas.

Sobre a imagem de gradientes é conduzida a identificação das regiões. Para isso, é efetuado um processo de agrupamento entre os *pixels* da imagem de gradientes que são adjacentes entre si e possuem valores abaixo de um dado limiar. O valor deste limiar é alterado de forma incremental ao longo do processo de segmentação, em função de um parâmetro definido pelo usuário. O incremento gradativo deste limiar implica no aumento do número de *pixels* para agrupamento, e conseqüentemente, proporciona o surgimento de novas regiões ou a expansão de regiões já existentes.

A discussão apresentadas introduz os principais conceitos do método automático de segmentação de imagens proposto. Verifica-se a partir desta discussão que a identificação das regiões é um processo adaptativo, guiado pelos valores da imagem de gradientes e um limiar que aumenta gradativamente durante a segmentação. Esta característica denomina o método por *Limiarização Adaptativa*. A subseção seguinte apresenta formalmente as etapas do método proposto.

3.2. Formalização do método

A primeira etapa realizada pelo método de segmentação proposto consiste na identificação das bordas das regiões da imagem a partir de um processo de diferenciação. Este processo é

realizado com a aplicação de uma função sobre os *pixels* da imagem. Para isso, é utilizada a informação de apenas uma única banda da imagem, selecionada *a priori* pelo usuário, caso a mesma possua mais que uma banda.

Formalmente, seja $\{B\}_{p=1,\dots,m;q=1,\dots,n}$, uma banda de uma dada imagem I , composta por m linhas e n colunas. O processo de diferenciação é realizado com a aplicação da seguinte função:

$$f(b_{p,q}) = \max_{u_1, u_2, v_1, v_2} \left| b_{p-u_1, q-v_1} - b_{p-u_2, q-v_2} \right| \quad (12)$$

onde $b_{p,q}$ é um dado *pixel* de B , com $u_k \in \{-U/2, \dots, U/2\}$ e $v_k \in \{-V/2, \dots, V/2\}$ para k igual a 1 ou 2, sendo U e V as dimensões da vizinhança. Como já mencionado, o resultado da aplicação desta função é denominada *imagem de gradientes*.

A Figura 1 exemplifica um produto gerado pela aplicação de (1) sobre uma imagem do satélite GeoEye adotando U e V iguais a 2 (i.e. janela de dimensão 3×3). Nesta imagem de gradientes a identificação das bordas que delimitam os diferentes alvos é mais visível com relação à imagem original.

O próximo procedimento consiste na identificação das regiões a partir da imagem de gradientes. Para isso, determina-se que as regiões devem ser expandidas a partir dos *pixels* da imagem de gradientes cujos valores estão abaixo de um dado limiar. Este limiar, denotado por L_α , corresponde ao valor da imagem de gradientes que separa os $\alpha\%$ menores valores dos demais, sendo α um parâmetro definido pelo usuário.

Após o cálculo de L_α , é selecionado aleatoriamente um dado *pixels* da imagem de gradiente cujo valor é inferior a este limiar. Tal *pixel* consiste em uma semente de uma região. Esta região, inicialmente composta por um único *pixel*, é expandida a partir do agrupamento com *pixels* vizinhos. O agrupamento consiste em unir em uma

mesma região os *pixels* da imagem de gradientes que são adjacentes (i.e. os elementos da vizinhança 8) a quaisquer *pixel* de uma dada região e cujo valor é inferior ou igual a L_α .

Formalmente, a expansão de uma dada região s_j a partir do processo de agrupamento é denotado por:

$$s_j = s_j \cup b_{p,q} : \left\{ \begin{array}{l} b_{p,q} \leq L_\alpha \\ \forall b_{u,v} \in s_j; \|(p,q) - (u,v)\| \leq \sqrt{2} \end{array} \right. \quad (13)$$

O processo de agrupamento acontece até que não seja mais possível agregar *pixels* a uma dada região. Neste caso, é selecionado um novo elemento da imagem de gradientes que seja inferior a L_α e que ainda não faça parte de nenhuma região, iniciando assim a expansão (agrupamento) de uma nova região. Este processo deve ocorrer até que todos os *pixels* da imagem de gradientes com valor inferior ou igual a L_α pertençam a uma dada região.

Em seguida torna-se necessária uma atualização do limiar. Para isso, é feito um incremento no valor de α , equivalente a seu valor inicial. Com o incremento de α , é definido um novo L_α , que por sua vez torna disponível para expansão, ou definição de novas regiões, um novo conjunto de *pixels* da imagem de gradientes. Os *pixels* deste conjunto são selecionados aleatoriamente e utilizados no processo de agrupamento.

Cabe ressaltar que, quando um *pixel* é selecionado aleatoriamente e o mesmo é vizinho de algum *pixel* que já pertença a uma região, o mesmo é automaticamente agregado a esta região. Ainda, quando o *pixel* selecionado é vizinho de *pixels* pertencentes a diferentes regiões, o mesmo deve ser associado à região cujo número de vizinhos é maior. Na ocorrência de empate, o *pixel* é associado aleatoriamente a uma das regiões.

Atualizações no valor de L_α são realizadas enquanto o valor de α for menor ou igual a 100. Nota-se que α é um parâmetro no método proposto que define o número de atualizações de L_α que compreende o processo de segmentação. Por conveniência, este parâmetro pode ser obtido pela razão $1/\beta$, sendo β o número de vezes que o limiar L_α é atualizado.

Ao fim do processo de segmentação é executada uma última etapa, a qual consiste em eliminar regiões cuja dimensão seja inferior a um valor definido de *Área Mínima*. Este valor é outro parâmetro para o processo de segmentação. A




Fig.1 - Imagem de gradientes. Resultado da operação para identificação dos limites das regiões.

ordem de eliminação das regiões acontece em função de suas dimensões, sendo eliminadas primeiramente as regiões menores. Para eliminação de uma região, são verificadas todas as regiões vizinhas (i.e. possuem fronteira). Em seguida são calculadas as distâncias euclidianas entre a região a ser eliminada e suas vizinhas. Esta distância é baseada no valor médio dos *pixels* das regiões com relação à imagem original. A eliminação de regiões pequenas é um procedimento usualmente realizado pelos métodos de segmentação. O método de segmentação por Crescimento de Regiões, por exemplo, utiliza este processo.

A Figura 2 ilustra de forma simplificada o processo de agrupamento sobre uma imagem de gradientes fictícia (Figura 2.a). Na Figura 2.b o limiar inicial equivale ao mais baixo nível da escala de diferenças absolutas, que por sua vez define quatro regiões diferentes, indexadas por 1, 2, 3 e 4. O “ponto” no canto superior esquerdo de alguma das células identifica o *pixel* semente que deu origem a região. Na Figura 2.c, com o incremento no valor do limiar, o mesmo passa a equivaler ao terceiro nível da escala de valores de diferenças absolutas. Este limiar, por sua vez, proporciona o surgimento das regiões 5 e 6. Nota-se que estas regiões são compostas por *pixels* de diferentes valores (cores), uma vez que para definição de uma nova região é




Fig.2 - Exemplicação do processo de agrupamento.

necessário que existam *pixels* que não pertençam a nenhuma região e cujo valor na imagem de gradientes seja menor ou igual que limiar definido. Por fim, na Figura 2.d, após um novo incremento no limiar, é alcançado o valor máximo da escala. A região 4 é expandida em função do *pixel* semente selecionado aleatoriamente para iniciar esta etapa. O mesmo acontece com a região 6. Neste caso, o *pixel* selecionado está na vizinhança de *pixels* das regiões 5 e 6, no entanto, o número de vizinhos da região 6 é maior.

Com objetivo de organizar os conceitos introduzidos ao longo desta seção, a Figura 3 apresenta um fluxograma com as etapas do método de segmentação proposto.

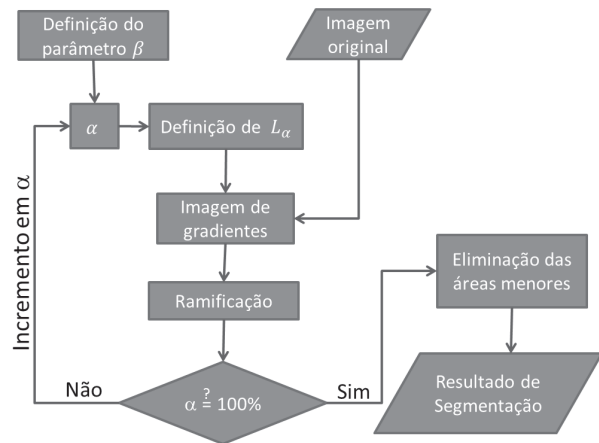


Fig.3 - Fluxograma de etapas do método proposto.

4. EXPERIMENTOS REALIZADOS

Nesta seção são realizadas análises comparativas entre o método proposto e o método de segmentação por Crescimento de Regiões (BESL; JAIN, 1988). Optou-se em utilizar o método Crescimento de Regiões como referencial devido sua popularidade em diferentes aplicações envolvendo segmentação de imagens.

Esta análise comparativa é baseada em dois estudos de caso. O primeiro estudo (Subseção 4.1) consiste na aplicação de tais métodos sobre um conjunto de dados simulados, enquanto o segundo estudo (Subseção 4.2) consiste na aplicação em uma imagem real de sensoriamento remoto. A comparação é baseada nas métricas de avaliação de segmentação apresentadas na Subseção 2.2.

4.1. Segmentação de imagens simuladas

Esta subseção apresenta um estudo comparativo entre os métodos Limiarização

Adaptativa e Crescimento de Regiões baseado em imagens simuladas. Para isso, as Subsubseções 4.1.1 e 4.1.2 apresentam uma metodologia desenvolvida para geração de imagens sintéticas. A Subsubseção 4.1.3 fundamenta-se na exposição e discussão do desempenho dos métodos analisados na segmentação das imagens sintéticas geradas.

4.1.1 Geração de segmentações simuladas


O uso de imagens simuladas permite a condução de experimentos controlados, isto é, experimentos cujo comportamento dos alvos é conhecido *a priori*, além de permitir a realização de avaliações sem a influência de uma imagem particular. Para construção do conjunto de imagens simuladas foram geradas inicialmente diferentes segmentações de imagens. As regiões das segmentações simuladas são então preenchidas com *pixels* que reproduzem o comportamento de alvos observados em imagens reais de sensoriamento remoto.

Neste estudo foi elaborado um procedimento automático para simulação de imagens específicas para segmentação. A primeira etapa deste procedimento requer a definição das dimensões das imagens simuladas. Para este estudo a dimensão definida foi de 150×150 *pixels*.

Em seguida, a área de 150×150 *pixels* é preenchida com valores aleatórios segundo uma distribuição de probabilidade uniforme, com valores entre 0 e 1. Após esta etapa, são selecionados aleatoriamente *pixels* desta “imagem de valores randômicos”. Cada *pixel* selecionado é interligado a um dos vizinhos (*pixels*) adjacentes cujo valor de probabilidade é maior. Por sua vez, o vizinho selecionado é interligado a seu respectivo vizinho de maior probabilidade, e assim sucessivamente.

Este procedimento é realizado repetidamente até que seja selecionado um *pixel* que já foi utilizado anteriormente, e então, uma nova posição é selecionada aleatoriamente. O processo descrito é finalizado quando o número de *pixels* selecionados totaliza 5% da área de 150×150 *pixels*. O conjunto dos *pixels* selecionados é responsável por definir apenas as bordas das regiões da segmentação simulada.

A Figura 4.a apresenta as bordas de uma segmentação simulada, enquanto as respectivas regiões são mostradas na Figura 4.b.



Definição das bordas Regiões geradas
Fig.4 - Simulação de imagens segmentadas. Em (a) são definidas as bordas das regiões, já em (b) é realizada a consolidação das regiões a partir das bordas definidas.

4.1.2 Geração de imagens simuladas

Após a simulação das segmentações, conforme apresentado na Subsubseção 4.1.1, torna-se necessário simular o comportamento de suas regiões. Reproduzir o comportamento de alvos reais é uma maneira de realizar tal simulação.

Sob esta consideração, foram selecionados diferentes tipos de cobertura da terra em uma imagem LANDSAT-5 TM adquirida em 26 de setembro de 2010, referente uma região localizada ao longo da rodovia BR-163, próxima à Floresta Nacional do Tapajós, no Estado do Pará. A seleção desta região é justificada pelo conhecimento de diferentes tipos de cobertura da terra existentes no local, devido a um levantamento de campo conduzido no mesmo período da aquisição da imagem. Para simulação do comportamento das regiões foram considerados 13 tipos diferentes de cobertura da terra, os quais são citados na Tabela 1 e identificados na Figura 5.

Para cada região das segmentações simuladas é associado aleatoriamente um tipo de cobertura da terra. Esta região é preenchida com valores gerados por uma distribuição Gaussiana cujos parâmetros média e variância são estimados a partir de amostras referentes ao tipo de cobertura de terra associada. Cabe ressaltar que os métodos avaliados neste estudo utilizam apenas uma banda espectral para segmentação da imagem. Dessa forma, foi utilizada apenas a banda 4 (infravermelho próximo), uma vez que esta proporciona a melhor distinção entre os tipos de cobertura da terra identificados na imagem adotada. A Figura 6.b ilustra uma imagem simulada obtida com o preenchimento das regiões da segmentação mostrada na Figura 6.a segundo o comportamento dos diferentes tipos de cobertura da terra identificados na Figura 5.

Tabela 1 - Tipos de cobertura da terra identificados na imagem LANDSAT-5 TM

Índice	Tipo de cobertura da terra
1	Floresta primária
2	Floresta Degradada
3	Regeneração nova
4	Pasto limpo
5	Pasto sujo
6	Pasto limpo com palmeira
7	Pasto sujo com palmeira
8	Solo exposto
9	Agricultura de soja – 1
10	Agricultura de soja – 2
11	Agricultura de soja – 3
12	Agricultura de feijão
13	Agricultura em pousio

De acordo com Bustos e Frery (1992), nos estudos envolvendo experimentos com dados simulados, é necessário realizar milhares de repetições, visando a obtenção de resultados com níveis de qualidade aceitáveis. No entanto, devido o custo computacional exigido pelos algoritmos de segmentação, esta exigência torna-se um fator limitante. Assim, para este estudo foi gerado um conjunto composto por 100 imagens simuladas, provenientes de diferentes segmentações simuladas.




Fig.5 - Imagem LANDSAT-5 TM, banda 4, e amostras de cobertura da terra. Os índices ilustrados relacionam as amostras com os tipos de cobertura da terra mencionados na Tabela 1.

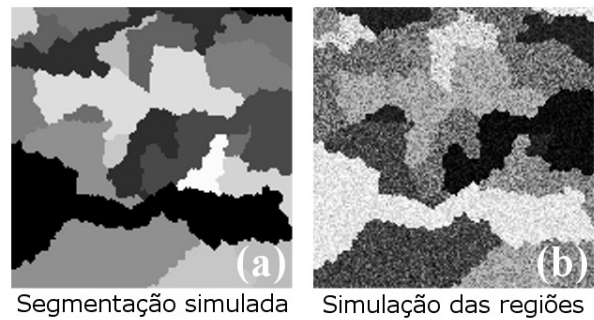


Fig.6 - Imagem simulada (b) obtida com o preenchimento das regiões da segmentação (a) segundo os diferentes tipos de cobertura da terra apresentados na Figura 5.

4.1.3. Análises comparativas

A primeira etapa executada para análise comparativa entre o método de segmentação por Crescimento de Regiões e o método proposto refere-se ao ajuste dos parâmetros. Para isso, foi realizada uma busca exaustiva em um intervalo fixo de valores de parâmetros dos diferentes métodos analisados. O parâmetro *Área Mínima*, exigido em ambos os métodos analisados, foi observado variando entre 10 e 300 em passos de tamanho 10. O efeito do parâmetro *Predicado*, usado no método Crescimento de Regiões, foi observado no intervalo de 5 a 200 em passos de tamanho 5. Já o parâmetro β , exigido pelo método Limiarização Adaptativa, foi observado no intervalo de 1 a 10 em passos de 0,5.

Para cada configuração de parâmetros, em ambos os métodos, foram segmentadas todas as 100 imagens do conjunto de imagens simuladas. Para cada segmentação realizada foi computada a medida geral de ajuste, expressa pela Equação (11). Após a execução das 100 segmentações, para uma dada configuração de parâmetros, foi computada a média aritmética da medida geral de ajuste.

Com isso, foi possível identificar os parâmetros que proporcionam o melhor desempenho sobre todo o conjunto de dados simulados. O gráfico apresentado na Figura 7 ilustra o desempenho do método de segmentação por Crescimento de Regiões diante diferentes combinações de valores para os parâmetros *Área Mínima* e *Predicado*. Neste caso, é possível verificar que quando o *Predicado* assume valores próximos a 10, a medida de ajuste geral atinge valores mais elevados, independente do parâmetro *Área Mínima*. Já o gráfico da Figura 8 ilustra o desempenho do método Limiarização Adaptativa

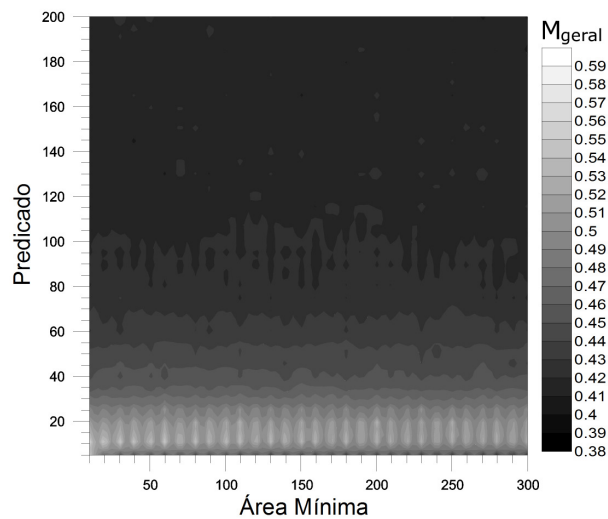


Fig.7 - Desempenho diante diferentes configurações de parâmetros do método Crescimento de Regiões.




Fig.8 - Desempenho diante diferentes configurações de parâmetros do método Limiarização Adaptativa.

segundo as combinações dos parâmetros *Área Mínima* e β . De modo geral, o valor de β que proporciona os maiores índices de ajuste encontra-se próximo de 4.

Sendo assim, fixando os valores de *Predicado* e *b* iguais a 10 e 4, respectivamente, é possível realizar uma avaliação mais precisa dos métodos analisados em função do parâmetro *Área Mínima*.

Nesta etapa da análise o conjunto de imagens simuladas foi segmentado considerando valores do parâmetro *Área Mínima* variando entre 100 e 3100 em intervalos de 25. Para cada resultado de segmentação foram computadas as medidas M_{pos} , M_{val} , M_{dim} e M_{for} . Os gráficos apresentados nas Figuras 9 a 16 exibem tais resultados. Para melhor comparação entre os diferentes métodos, foi adotada uma mesma escala de cor para cada medida de ajuste. Com esta padronização, torna-

se mais simples a verificação visual dos resultados.

As Figuras 9 e 10 exibem o desempenho dos métodos segundo o ajuste de posição das regiões. Com relação a esta primeira medida, o método Limiarização Adaptativa alcançou melhores valores de ajuste, principalmente para valores pequenos de *Área Mínima*. Com relação a esta medida, a partir de valores próximos a 1600, o método Crescimento de Regiões tende a apresentar resultados inferiores.

Nas Figuras 11 e 12 são verificados os desempenhos segundo o ajuste do nível de cinza das regiões. Neste caso, o método Limiarização Adaptativa sofre uma queda acentuada no desempenho com o aumento da *Área Mínima*, ao contrário do Crescimento de Regiões, que embora também apresente uma diminuição no desempenho com o aumento de valor deste parâmetro, esta diminuição é mais amena. Verifica-se novamente que os melhores níveis de desempenho do método Limiarização Adaptativa encontram-se para valores baixos de *Área Mínima*.

Os resultados sobre ajuste de dimensão são apresentados nas Figuras 13 e 14. Segundo esta medida, o método Limiarização Adaptativa torna-se superior para valores de *Área Mínima* aproximadamente entre 100 e 300. Porém, para valores maiores, seu desempenho é crítico. Mais uma vez o método Crescimento de Regiões mostrou-se menos sensível ao aumento da *Área Mínima*.

Um comportamento muito semelhante aos resultados sobre o ajuste de dimensão é apresentado para o ajuste de forma, como exposto nas Figuras 15 e 16.

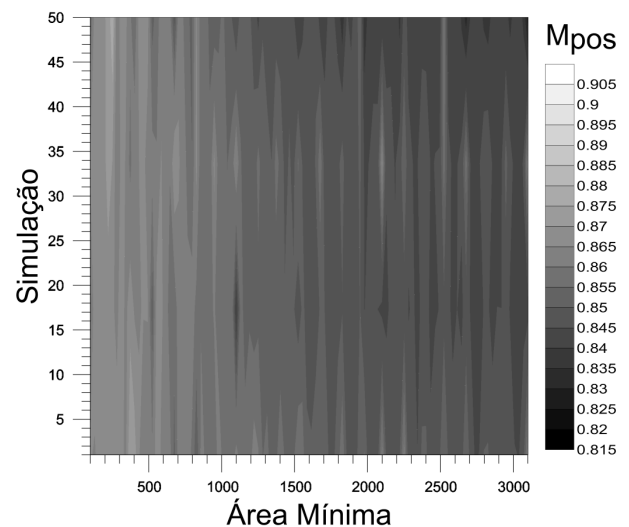


Fig.9 - Desempenho do método Crescimento de Regiões segundo a medida de ajuste de posição diante diferentes valores de *Área Mínima*.

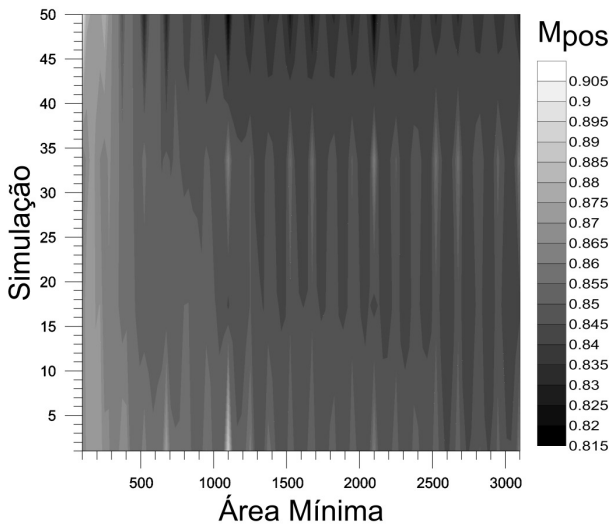


Fig.10 - Desempenho do método Limiarização Adaptativa segundo a medida de ajuste de posição diante diferentes valores de *Área Mínima*.




Fig.13 - Desempenho do método Crescimento de Regiões segundo a medida de ajuste de dimensão diante diferentes valores de *Área Mínima*.




Fig. 11 - Desempenho do Crescimento de Regiões segundo a medida de ajuste de nível de cinza diante diferentes valores de *Área Mínima*.




Fig.14 - Desempenho do método Limiarização Adaptativa segundo a medida de ajuste dimensão diante diferentes valores de *Área Mínima*.




Fig.12 - Desempenho do método Limiarização Adaptativa segundo a medida de ajuste de nível de cinza diante diferentes valores de *Área Mínima*.




Fig.15 - Desempenho do método Crescimento de Regiões segundo a medida de ajuste de forma diante diferentes valores de *Área Mínima*.




Fig.16 - Desempenho do método Limiarização Adaptativa segundo a medida de ajuste de forma diante diferentes valores de *Área Mínima*.

De acordo com os resultados apresentados, foi observado que o parâmetro *Área Mínima* influi na qualidade dos resultados em ambos os métodos, sendo o Crescimento de Regiões menos sensível. Por outro lado, para valores pequenos deste parâmetro, o método Limiarização Adaptativa fornece no geral resultados mais acurados.

Verifica-se ainda que as maiores diferenças entre os métodos analisados, considerando valores de *Área Mínima* abaixo de 1000, são identificadas pelas medidas de ajuste de dimensão (M_{dim}) e forma (M_{for}). Como já mencionado, o método Crescimento de Regiões realiza a delimitação das regiões com base na homogeneidade destas regiões, o que o torna suscetível a determinação de limites mal definidos. Ao contrário, a delimitação das regiões pelo método proposto está vinculada a imagem de gradientes, o que pode garantir melhor ajuste na forma e na dimensão das regiões segmentadas.

4.2. Segmentação de imagem desensoriamento remoto

Nesta subseção é apresentada uma comparação entre os métodos Limiarização Adaptativa e Crescimento de Regiões na segmentação de uma imagem real de sensoriamento remoto. Para isso foi utilizada uma subárea de uma imagem da área urbana de São José dos Campos – SP, adquirida pelo satélite IKONOS em 27 de junho de 2007. Apenas a banda pancromática foi utilizada. A escolha desta imagem é justificada principalmente em função de sua alta resolução espacial (1 metro),

que possibilita a identificação visual de diferentes alvos de forma precisa, permitindo assim a realização de uma segmentação manual adequada. A Figura 17 ilustra a imagem adotada e uma segmentação manual, definida como segmentação de referência, utilizada para comparação dos métodos segundo as métricas de avaliação de segmentação apresentadas na Subseção 2.2.

A partir desses dados, diferentes parâmetros de segmentação foram observados visando obter os melhores índices de ajuste. Os gráficos das Figuras 18 e 19 ilustram os resultados das diferentes configurações de parâmetros para os métodos proposto e Crescimento de Regiões.

De acordo com os resultados de ajustes de segmentação apresentados nas Figuras 18 e 19, verifica-se que o método Limiarização Adaptativa alcança melhores resultados quando os parâmetros β e *Área Mínima* equivalem a 5,5 e 30, respectivamente. Já o método Crescimento de




Fig.17 - Subárea de imagem IKONOS, visualizada segundo a banda pancromática, referente a cidade de São José dos Campos (a), e segmentação manual desta subárea (b).

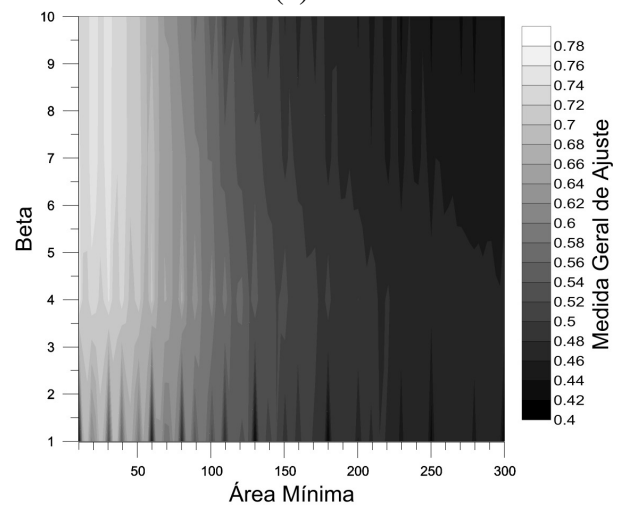


Fig.18 - Desempenho diante diferentes configurações de parâmetros do método Limiarização Adaptativa na segmentação da imagem IKONOS (Figura 17.a) segundo a medida geral de ajuste.

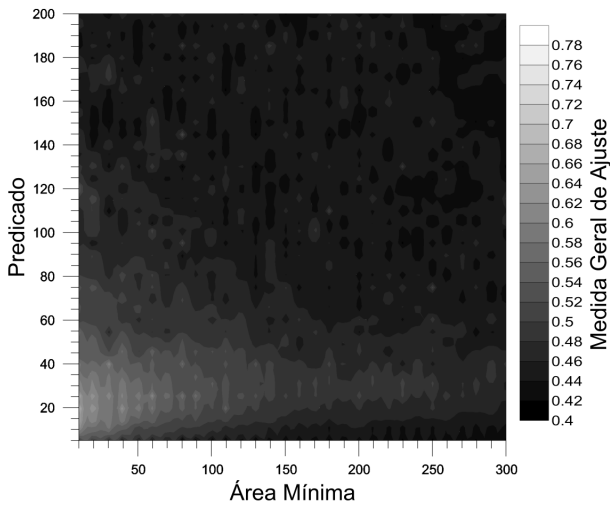


Fig.19 - Desempenho diante diferentes configurações de parâmetros do método Crescimento de Regiões na segmentação da imagem IKONOS (Figura 17.a) segundo a medida geral de ajuste.

regiões atinge melhores índices de ajuste quando ambos os parâmetros *Predicado* e *Área Mínima* são iguais a 20. Segundo tais configurações de parâmetros, a Tabela 2 apresenta os valores das medidas de ajuste (i.e. M_{pos} , M_{val} , M_{dim} , M_{for} e M_{geral}) obtidas por ambos os métodos.

De acordo com os coeficientes de ajuste apresentados na Tabela 2, verifica-se que o método Limiarização Adaptativa alcança melhores resultados, principalmente com relação as medidas de dimensão (M_{dim}) e forma (M_{for}) das regiões segmentadas, como já verificado nos experimentos da Subseção 4.1. Tais resultados de segmentação são apresentados na Figura 20.

A segmentação gerada pelo método Crescimento de Regiões identificou regiões estreitas, proporcionando um efeito de “borda dupla” em algumas áreas, o que não é verificado na segmentação obtida pelo método Limiarização Adaptativa. No entanto, é possível observa-se que os limites das regiões segmentadas pelo método Limiarização Adaptativa apresentam maior sinuosidade.

Ao comparar a segmentação de referência às segmentações geradas, é possível notar que o Tabela 2 - Medidas de ajuste obtidas na segmentação da imagem IKONOS pelos métodos analisados

Método	M_{pos}	M_{val}	M_{dim}	M_{for}	M_{geral}
L. Adaptativa	0,98	0,94	0,78	0,40	0,78
Cresc. Regiões	0,95	0,91	0,52	0,25	0,66

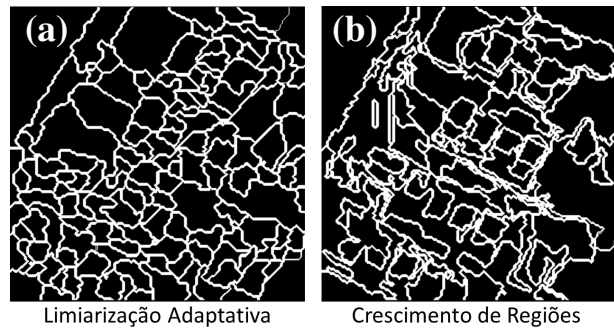


Fig. 20 - Segmentações da imagem IKONOS (Figura 17.a) segundo os métodos Limiarização Adaptativa (a) e Crescimento de Regiões (b), segundo as configurações.

método Crescimento de Regiões proporcionou regiões de sobresegmentação, como ocorre no canto inferior esquerdo da Figura 20.b. Embora o problema de sobresegmentação não seja verificado na Limiarização Adaptativa, os limites das regiões de menor área apresentam problemas de ajuste, o que é refletido principalmente pela medida M_{for} e pode ser verificado visualmente na Figura 20.a.

5. CONCLUSÕES E PERSPECTIVAS

Neste trabalho foi proposta um novo método de segmentação de imagem, denominada Limiarização Adaptativa. Para validação, foram realizados dois estudos comparativos com o método Crescimento de Regiões, o qual é amplamente divulgado e usualmente empregado em diferentes aplicações.

Os resultados apresentados mostraram que o método proposto alcança melhores índices de ajuste, comparado ao método Crescimento de Regiões, desde que seja permitida a supersegmentação das imagens. A produção de supersegmentações não deve ser entendida como uma deficiência, mas sim uma característica de determinados métodos de segmentação. Nas aplicações envolvendo segmentação, por exemplo, de áreas urbanas a partir de imagens de sensoriamento remoto de altíssima resolução, a utilização de métodos capazes de produzir supersegmentações mais precisas torna-se uma característica desejável.

Para estudos futuros, e o aprimoramento do método proposto, devem ser analisados novos meios mais precisos para detecção de borda dos alvos, estender o método tornando-o capaz de considerar múltiplas bandas para o processo de

segmentação e por fim, avaliar outras estratégias, seja ela estatística ou *ad-hoc*, usada no processo de eliminação de áreas que não atingem a dimensão mínima exigida, definida pelo parâmetro *Área Mínima*.

AGRADECIMENTOS

Os autores agradecem a CAPES pelo suporte financeiro.

REFERÊNCIAS BIBLIOGRÁFICAS

ACHARYA, T.; RAY, A. K. **Image processing, principles and applications**. New Jersey: John Wiley and Sons, 2005. 425p.

BESL, P. J.; JAIN, R. C. Segmentation through Variable-Order Surface Fitting. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, p.167-192, 1988.

BUSTOS, O.H.; FRERY, A.C. **Simulação estocástica: teoria e algoritmos**. Rio de Janeiro, IMPA, 1992. 148p.

CHANG, L. Y.; CHEN, C. F. A Multi-Scale Region Growing Segmentation for High Resolution Remotely Sensed Images. *Journal of Photogrammetry and Remote Sensing*. v.13, n.2, p.158-164, 2008.

CUFÍ, X.; MUÑOZ, X.; FREIXENET, J.; MARTÍ, J. A Review on Image Segmentation Techniques Integrating Region and Boundary Information. **Advances in Imaging and Electron Physics**. Eds. HAWKES, P. W., Academic Press, v.120, p.1-39, 2002.

DELVES, L.M.; WILKINSON, R.; OLIVER, C.J.; WHITE, R.G. Comparing the performance of SAR segmentation algorithms. **International Journal of Remote Sensing**, v.13, n.2, p.2121-2149, 1992.

GONZALES, R. C.; WOODS, R. E. **Digital image processing**. Addison-Wesley, New York, 2002. 190p.

PAVLIDIS, T.; LIOW, Y. T. Integrating region growing and edge detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, n.12, v.3, p.225-233, 1990.

ROBERTS, L. G. **Machine perception of three-dimensional solids**. In: TIPPETT, J. T.; CLAPP, L. C. (Eds.) **Optical and electro-optical information processing**, MIT Press, Cambridge, Massachusetts, pp. 159-197, 1965.

ROSE, J.; GREINER, T.; REVOL-MULLER, C.; ODET C. Unifying variational approach and region growing segmentation. **European Signal Processing Conference**, p.1781-1785, 2010.

ROSENFELD, A.; KAK, A. **Digital picture processing - vol. 2**, Academic Press, Orlando, Florida, 1982. 435p.

SINGH, R.; SINGH J.; SHARMA, P.; SHARMA, S. Edge Based Region Growing. **International Journal of Computer Technology and Applications**, n.4, v.2, p. 1122-11126, 2011.

SOBEL, I. E. **Camera Models and Machine Perception**, PhD thesis, Electrical Engineering Department, Stanford University, Stanford, California, 1970.

TABB, M.; AHUJA, N. Multiscale image segmentation by integrated edge and region detection. **IEEE transactions on image processing**, n.6, v.5, p.642-655, 1997.

WAN, S.; HIGGINS, W. Symmetric Region Growing. **IEEE Transactions on Image Processing**. v.12, n.9, p.1007-1015, 2003.

ZUCKER, S. W.; Region growing: Childhood and adolescence, **Computer Vision, Graphics and Image Processing**, v.5, p.382-399, 1976.