



MINISTÉRIO DA CIÊNCIA E TECNOLOGIA

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

AJUSTE DE PARÂMETROS EM ALGORITMOS DE SEGMENTAÇÃO DE
IMAGENS POR CRESCIMENTO DE REGIÕES

Giovana Mira De Espindola

Dissertação de Mestrado do Curso de Pós-Graduação em Sensoriamento Remoto,
orientada pelo Dr. Gilberto Câmara E Antônio Miguel Vieira Monteiro.

INPE
São José dos Campos
2006

MINISTÉRIO DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

INPE-

SELEÇÃO DE PARÂMETROS EM ALGORITMOS DE SEGMENTAÇÃO DE
IMAGENS POR CRESCIMENTO DE REGIÕES

Giovana Mira De Espindola

Dissertação de Mestrado do Curso de Pós-Graduação em Sensoriamento Remoto,
orientada pelo Dr. Gilberto Câmara E Antônio Miguel Vieira Monteiro.

INPE
São José dos Campos
2006

AGRADECIMENTOS

Agradeço às pessoas e instituições que contribuíram, de forma direta ou indireta, para a realização deste trabalho, em especial:

Ao Instituto Nacional de Pesquisas Espaciais – INPE, pelo Curso de Pós-Graduação em Sensoriamento Remoto, e a Fundação de Aperfeiçoamento de Pessoal de Nível Superior - CAPES, pelo auxílio financeiro.

Aos meus orientadores, Dr. Gilberto Câmara e Dr. Antônio Miguel Vieira Monteiro, pela confiança depositada, pelo constante apoio e pela orientação.

Ao pesquisador Leonardo Sant’Anna Bins e à amiga Ilka Afonso Reis, pelas inúmeras contribuições e pela disposição. Ao amigo Nicolas Despres, pelas implementações indispensáveis para a elaboração deste trabalho.

Aos amigos do INPE, Camila Souza dos Anjos, Denis de Moura Soares, Michelle Cristina Araújo Picoli e Natalia de Almeida Crusco, pelos momentos de alegria e descontração.

À empresa Intersat Soluções em Imagens de Satélite, pela cessão da imagem do satélite QuickBird. Aos amigos Carolina Moutinho Duque de Pinho e Marcos Leandro Kazmiercza, pela revisão do texto.

Ao grande amigo Ricardo Wallach, pelo constante entusiasmo. À minha querida mãe, Dilza Mari de Mira, por toda uma vida de incentivos.

RESUMO

Os algoritmos de segmentação têm sido amplamente usados na extração de informações de imagens de sensoriamento remoto. Estes algoritmos têm por objetivo dividir uma imagem em regiões espacialmente contínuas, disjuntas e homogêneas. O processo de segmentação possui algumas vantagens quando comparado ao processo de classificação por pixels, pois obtém resultados visualmente consistentes e de fácil conversão em sistemas de informação geográfica. Dentre os algoritmos de segmentação de imagens, os de crescimento de regiões são preferíveis nas aplicações de sensoriamento remoto, pois consideram a característica espacial dos dados e garantem a formação de segmentos fechados. Grande parte dos algoritmos de segmentação por crescimento de regiões requer de seus usuários a escolha de parâmetros que definam os limiares da segmentação. Para os usuários destes algoritmos, um dos desafios consiste em selecionar os parâmetros que resultem nos melhores resultados da segmentação. Esta dissertação aborda essa questão, propondo uma função objetivo que busca selecionar os limiares da segmentação com base na qualidade de seus resultados. Tal função considera que bons resultados dependem, prioritariamente, da obtenção de regiões internamente homogêneas e regiões adjacentes significativamente distintas em relação à característica na qual elas são homogêneas. Assim, a função proposta combina um indicador de variância que expressa a homogeneidade interna dos segmentos, com um indicador de autocorrelação espacial que expressa a separabilidade entre segmentos vizinhos. A vantagem do método proposto consiste na incorporação da dimensão espacial da imagem às medidas de qualidade da segmentação, resultando em medidas mais eficientes que eliminam a necessidade de imagens de referência. A função objetivo proposta foi aplicada nos algoritmos de segmentação dos softwares SPRING e e-Cognition®, permitindo a avaliação dos resultados obtidos com imagens reais e sintéticas.

PARAMETER SELECTION FOR REGION-GROWING IMAGE SEGMENTATION ALGORITHMS

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. Usually, the resulting maps have much more visual consistency and are more easily converted into a geographical information system. 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 an objective function to select the best parameter settings of segmentation results. By applying the proposed function to the segmentation results, the user has guidance for selection of parameter values. The proposed objective function considers that segmentation results have two desirable properties: each of the resulting segments should be internally homogeneous and should be distinguishable from its neighborhood. The function combines a variance indicator, which expresses the overall homogeneity of the regions, with a spatial autocorrelation index, which detects separability between regions. The main advantage of the proposed method is its robustness, since it uses established statistical methods (variance and spatial autocorrelation) and it is not based on the use of reference segmentation. To assess the validity of the proposed measure, some experiments were conducted using the region-growing segmentation algorithms which are available in the SPRING and e-Cognition® softwares. The experimental results of both synthesized and real images were very encouraging. Therefore, they were used to evaluate the performance of the proposed method.

SUMÁRIO

	Pág.
INTRODUÇÃO.....	13
1.1 Objetivos.....	15
1.2 Contribuições para o Avanço do Conhecimento Científico.....	16
1.3 Organização da Dissertação.....	16
ÍNDICES DE QUALIDADE PARA OS RESULTADOS DA SEGMENTAÇÃO..	18
2.1 Algoritmos de Segmentação de Imagens por Crescimento de Regiões.....	18
2.1.1 Algoritmo de Segmentação de Imagens do Software SPRING.....	20
2.2 Índice de Homogeneidade Interna dos Segmentos.....	21
2.3 Índice de Separabilidade entre Segmentos Vizinhos.....	23
2.4 Função Objetivo - Software SPRING.....	26
2.5 Considerações Adicionais.....	29
EXTENSÕES DA SELEÇÃO DE PARÂMETROS EM ALGORITMOS DE SEGMENTAÇÃO DE IMAGENS	30
3.1 Seleção de Parâmetros no Algoritmo de Segmentação de Imagens do Software e- Cognition®.....	30
3.1.1 Algoritmo de Segmentação de Imagens do Software e-Cognition®.....	31
3.1.2 Função Objetivo - Software e-Cognition®.....	33
3.2 Seleção de Parâmetros na Segmentação Multibandas - Software SPRING.....	37
3.3 Considerações Adicionais.....	40
VALIDAÇÃO DO MÉTODO DE SELEÇÃO DE PARÂMETROS	42
4.1 Validação com Imagens Sintéticas.....	42
4.2 Validação com Imagens Reais.....	46
CONCLUSÕES.....	50
REFERÊNCIAS BIBLIOGRÁFICAS	52

CAPÍTULO 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 através da partição da mesma 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.

Em sensoriamento remoto, o processo de segmentação está inserido no plano das técnicas de processamento digital de imagens, sendo uma etapa de pré-processamento para a classificação por regiões. Para Soh e Tsatsoulis (1999), a obtenção de resultados satisfatórios na etapa de classificação é diretamente dependente da existência de algoritmos eficientes na etapa de segmentação.

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 está vinculada à extração automática de todos os 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; 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 recente comparação entre os principais algoritmos de segmentação aplicados às imagens de sensoriamento remoto. 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® (Baatiz; 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.

Neste contexto, surge a seguinte questão: *o que é uma boa segmentação de imagem?* Segundo Haralick e Shapiro (1985), as regiões de uma segmentação devem ser uniformes e homogêneas com respeito a alguma característica (níveis de cinza, por exemplo). Regiões adjacentes precisam ter valores significativamente distintos em relação à característica nas quais elas são homogêneas. Por fim, as bordas das regiões precisam ser simples, ou seja, únicas e contínuas.

Baseado nas condições sugeridas por Haralick e Shapiro (1985), definem-se algumas medidas de qualidade que 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 da literatura apresentar inúmeras técnicas de segmentação, poucos são os métodos de avaliação desenvolvidos para julgar a qualidade da segmentação. Novos métodos têm sido propostos para avaliar e comparar o desempenho de algoritmos de segmentação, entre os quais podem-se destacar os

apresentados por Oliveira *et al.* (2003), Kartikeyan *et al.* (1998), Lucca (1998) e Beauchemin e Thomson (1997).

Apesar da crescente ênfase destinada à questão da avaliação dos resultados da segmentação, os trabalhos existentes baseiam-se unicamente na definição de medidas estatísticas não-espaciais. Todos os métodos apresentados até o momento não consideram o arranjo espacial dos segmentos na definição de seus índices de qualidade. Além disto, os métodos de avaliação propostos por Oliveira *et al.* (2003), Lucca (1998), Beauchemin e Thomson (1997) e Zhang (1996), apesar de serem objetivos e eficientes, apresentam o inconveniente de necessitarem de uma imagem de referência.

Considerando as questões levantadas, essa dissertação parte da **hipótese** de que a incorporação da dimensão espacial da imagem às medidas de qualidade de sua segmentação leva a medidas mais eficientes e elimina a necessidade de imagens de referência. Neste sentido, esta dissertação propõe incorporar a dimensão espacial nas medidas de qualidade da segmentação através dos métodos de Análise Exploratória de Dados Espaciais (Anselin, 1999). De uma maneira geral, tais métodos permitem avaliar a **autocorrelação espacial** dos dados, isto é, como os dados estão correlacionados no espaço.

Este trabalho parte dos seguintes pré-supostos: (a) bons resultados da segmentação dependem, prioritariamente, da obtenção de regiões internamente homogêneas e regiões adjacentes significativamente distintas em relação à característica nas quais elas são homogêneas; (b) uma segmentação de boa qualidade possui segmentos adjacentes pouco correlacionados entre si ou até mesmo correlacionados negativamente, indicando a separabilidade entre estes segmentos.

1.1 Objetivos

Esta dissertação tem como objetivo geral propor um método de seleção de parâmetros para algoritmos de segmentação de imagens por crescimento de regiões. Tal método é baseado na definição de uma função objetivo que agrega dois índices de qualidade para os resultados da segmentação.

Os índices de qualidade são compostos por um Índice de Homogeneidade Interna que tem como atributo a variância dos níveis de cinza dos segmentos, e um Índice de Separabilidade entre Segmentos Vizinhos que tem como atributo a média dos níveis de cinza dos segmentos.

Para atender este objetivo geral, os seguintes objetivos específicos foram propostos:

- (a) Construir um índice de qualidade que, aplicado aos resultados da segmentação, traduza de forma eficiente a homogeneidade interna dos segmentos;
- (b) Definir um índice de qualidade baseado em medidas de autocorrelação espacial que, aplicado aos resultados da segmentação, traduza de forma eficiente a separabilidade entre segmentos vizinhos;
- (c) Construir uma função objetivo que agregue de forma eficiente os dois índices de qualidade propostos em (a) e (b);
- (d) Aplicar a função objetivo proposta em (c) na seleção de parâmetros de algoritmos de segmentação de imagens por crescimento de regiões e avaliar os resultados obtidos em imagens reais e sintéticas.

1.2 Contribuições para o Avanço do Conhecimento Científico

Do ponto de vista prático, a contribuição desta dissertação está baseada no desenvolvimento de um método objetivo de seleção de parâmetros para algoritmos de segmentação de imagens por crescimento de regiões que elimina a necessidade de imagens de referência. Do ponto de vista metodológico, esta dissertação contribui através da incorporação da dimensão espacial da imagem na avaliação da qualidade dos resultados da segmentação.

1.3 Organização da Dissertação

Esta dissertação está organizada em cinco capítulos. No Capítulo 2 são apresentados os conceitos relativos aos algoritmos de segmentação por crescimento de regiões, com ênfase no algoritmo implementado no software SPRING; os Índices de Homogeneidade

Interna e de Separabilidade entre Segmentos Vizinhos; e a definição da Função Objetivo usada na seleção de parâmetros no algoritmo de segmentação do software SPRING.

O Capítulo 3 é destinado à apresentação das extensões do método proposto. São apresentados modelos para a seleção de parâmetros no algoritmo de segmentação do software e-Cognition® e em segmentações multibandas.

O Capítulo 4 apresenta a validação do método proposto através da aplicação do mesmo em diferentes tipos de imagens reais e sintéticas.

O Capítulo 5 traz uma discussão geral a respeito do trabalho, com ênfase na contribuição e resultados da dissertação.

CAPÍTULO 2

ÍNDICES DE QUALIDADE PARA OS RESULTADOS DA SEGMENTAÇÃO

A realização de análises qualitativas nos resultados da segmentação requer a construção de índices de qualidade capazes de mensurar as condições que devem ser satisfeitas na obtenção de bons resultados da segmentação. Em geral, essas condições são derivadas das definições dadas ao processo de segmentação, sendo levadas em consideração nas implementações dos algoritmos segmentadores.

Dadas estas questões, a primeira seção deste capítulo apresenta as definições dadas aos algoritmos de segmentação por crescimento de regiões, com ênfase no algoritmo do software SPRING. Nas seções seguintes, são apresentados os índices de qualidade para avaliação dos resultados, bem como a função objetivo usada na seleção de parâmetros do algoritmo de segmentação do software SPRING.

A imagem utilizada neste capítulo 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 através do aumento do contraste, pela expansão do histograma da imagem através da aplicação da função de contraste linear.

2.1 Algoritmos de Segmentação de Imagens por Crescimento de Regiões

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. Dos algoritmos destinados a esse fim, os que implementam o método de crescimento de regiões são os mais eficientes, segundo Tilton e Lawrence (2000).

Zucker (1976) descreve o método de segmentação por **crescimento de regiões** 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 tais condições:

(a) As regiões $X_1, X_2, \dots, X_N$ devem ser compostas por uma sequência de pontos contíguos;

(b) $\bigcup_{i=1}^N X_i = X$, ou seja, a segmentação deve ser completa;

(c) $X_i \cap X_j = \emptyset$ para todo $i \neq j$, ou seja, todas as regiões devem ser distintas e separadas;

(d) $P(X_i) = \text{verdade}$ para $i = 1, 2, \dots, N$, ou seja, o atributo de homogeneidade deve ser satisfeito para cada região;

(e) $P(X_i \cup X_j) = \text{falsa}$ para $i \neq j$, onde X_i e X_j são adjacentes, ou seja, regiões vizinhas possuem atributos diferentes.

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 sequência 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 2.1 ilustra o processo de segmentação de imagens por crescimento de regiões. Inicialmente, cada pixel da imagem corresponde a uma célula (Figura 2.1a), da qual são escolhidas as células sementes (Figura 2.1b). 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 2.1c e 2.1d). 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 2.1e e 2.1f) (Bins et al., 1996).




FIGURA 2.1 - Processo de segmentação de imagens por crescimento de regiões com limiar de similaridade igual a 2 níveis de cinza.

2.1.1 Algoritmo de Segmentação de Imagens do Software SPRING

O algoritmo de segmentação de imagens do software SPRING se baseia 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.

Seja T o limiar de similaridade; M_i o vetor de média da região R_i ; $dist(R_i, R_j) = \|M_i - M_j\|$ a distância Euclidiana entre as regiões R_i e R_j ; e $N(R_i)$ o

conjunto de regiões vizinhas da região R_i . Duas regiões vizinhas R_i e R_j serão agrupadas se satisfizerem as seguintes condições:

- (1) Condição de Similaridade: $dist(R_i, R_j) \leq T$
- (2) Condição de Vizinhaça 1: $R_j \in N(R_i)$ and $dist(R_j, R_i) \leq dist(R_k, R_i), R_k \in N(R_i)$
- (3) Condição de Vizinhaça 2: $R_i \in N(R_j)$ and $dist(R_i, R_j) \leq dist(R_k, R_j), R_k \in N(R_j)$

Ou seja, segundo a condição (1), a distância Euclidiana entre as regiões R_i e R_j deverá ser menor que o limiar de similaridade T . As condições (2) e (3) garantem que, dado os conjuntos $N(R_i)$ e $N(R_j)$ de regiões vizinhas, as regiões R_i e R_j são mutuamente as mais similares destes conjuntos. Regiões menores que o limiar de área são agrupadas na região vizinha mais similar.

Os resultados deste processo de segmentação são sensíveis à escolha dos limiares de área e de similaridade. Baixos limiares tendem a produzir resultados com grande número de regiões fragmentadas, gerando *supersegmentações*. Em contra partida, altos valores forçam a união de regiões distintas, gerando resultados de *subsegmentações*.

2.2 Índice de Homogeneidade Interna dos Segmentos

Esta seção descreve a construção de um índice de qualidade que, aplicado aos resultados da segmentação, traduz de forma eficiente a homogeneidade interna dos segmentos. Para tanto, foi estendido o índice de qualidade U_α proposto por Levine e Nazif (1985) e revisado por Jiang e Toriwaki (1993). O índice U_α mede a uniformidade das regiões resultantes da segmentação considerando a variância ponderada dos níveis de cinza dos pixels de cada região.

Usando esses mesmos pressupostos, o Índice de Homogeneidade Interna (IHI) proposto nesta dissertação é calculado segundo a Equação 2.1, onde v_i é a variância dos níveis de cinza dos pixels da região R_i e a_i é a área da região R_i . Desta forma, v quantifica de forma ponderada a variância média das regiões, onde os pesos de ponderação são dados pelas áreas de cada região. Assim, pesos maiores são dados às maiores áreas, visando evitar as instabilidades causadas por regiões muito pequenas.

$$v = \frac{\sum_{i=1}^n a_i \cdot v_i}{\sum_{i=1}^n a_i} \quad (2.1)$$

O IHI retorna um valor de variância média para cada resultado da segmentação, sendo que resultados que apresentam alta homogeneidade interna de seus segmentos são traduzidos por baixos valores de variância média, que consequentemente retornam baixos valores deste índice.

Dado o conjunto de 2500 resultados da segmentação, o gráfico da Figura 2.2 mostra a variação do IHI para os resultados da segmentação da imagem Landsat-7/ETM+, considerando limiar de área e similaridade variando no intervalo $[1,2,3,...,50]$. De maneira geral, a variação do IHI é diretamente proporcional à variação destes limiares, ou seja, baixos valores de área e similaridade geram resultados que apresentam segmentos internamente homogêneos, com baixos valores de variância média, que são traduzidos por baixos valores de IHI.




FIGURA 2.2 - Gráfico do IHI para a imagem Landsat-7/ETM+.

Dado um valor constante para o limiar de área igual a 22, o gráfico da Figura 2.3 mostra a variação do IHI, considerando limiar de similaridade variando no intervalo $[1,2,3,...,50]$. Tal gráfico mostra uma variação notável entre os limiares de similaridade 33 e 34. O resultado obtido com limiar de área e similaridade igual a 22 e 33,

respectivamente, apresenta um total de 43 segmentos, com valor de IHI igual a 412,14. O resultado seguinte, obtido com limiar de área e similaridade igual a 22 e 34, respectivamente, apresenta um total de 37 segmentos, com valor de IHI igual a 586,23. Nota-se através da inspeção visual que a variação no resultado do IHI reflete as diferenças de homogeneidade interna obtidas nos resultados da segmentação.




FIGURA 2.3 - Resultados do IHI para limiar de área igual a 22.

2.3 Índice de Separabilidade entre Segmentos Vizinhos

Esta seção apresenta um índice de que incorpora a dimensão espacial da imagem na avaliação da qualidade dos resultados da segmentação. Quando aplicado aos resultados da segmentação, este índice traduz de forma eficiente a separabilidade entre segmentos vizinhos. Em trabalhos anteriores, Jiang e Toriwaki (1993) e Levine e Nazif (1985) propõem um índice C_α que mede o contraste entre regiões adjacentes, considerando a média dos níveis de cinza dos pixels de cada região nos resultados da segmentação. O índice C_α compara a média entre pares de segmentos vizinhos, sem considerar a

maneira como as regiões estão dispostas no espaço. O índice proposto vai além de trabalhos anteriores, por incorporar a dimensão espacial.

O Índice de Separabilidade entre Segmentos Vizinhos (ISSV) proposto nesta dissertação permite avaliar a **autocorrelação espacial** das regiões através dos métodos de Análise Exploratória de Dados Espaciais (Anselin, 1999). Tais métodos têm por objetivo identificar padrões espaciais através da descrição das distribuições e dos regimes de autocorrelação espacial (Anselin, 1999). A autocorrelação espacial é uma das propriedades dos dados espaciais, tal propriedade é traduzida pela Primeira Lei da Geografia de Tobler (1979) cujo enunciado é: “*Everything is related to everything else, but near things are more related than distant things*”. Ou seja, quando as relações espaciais são mensuradas, espera-se que as regiões próximas sejam mais parecidas que as regiões distantes. Para o estudo de dados espaciais univariados, alguns índices são usados para medir a autocorrelação espacial, sendo o Índice Global de Moran o mais usual deles.

Desta forma, o ISSV proposto é equivalente ao Índice Global de Moran (Fotheringham *et al.*, 2000), tendo como atributo a média dos níveis de cinza dos pixels das regiões. Na Equação 2.2, n é o número de áreas; z_i é o valor do atributo considerado na área i ; $\bar{z}$ é o valor médio do atributo na região de estudo; w_{ij} são os elementos da matriz de proximidade espacial normalizada.

$$I = \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} (z_i - \bar{z}) \cdot (z_j - \bar{z})}{\sum_{i=1}^n (z_i - \bar{z})^2} \quad (2.2)$$

Para estimar a variabilidade espacial dos dados de área, usa-se a Matriz de Proximidade Espacial, que é definida pelos elementos w_{ij} e leva em consideração as medidas de proximidade espacial em cada um de seus elementos. Dado um conjunto de n áreas $\{A_1, A_2, \dots, A_n\}$, $w_{ij} = 1$, se A_i compartilha um lado comum com A_j . Caso contrário, $w_{ij} = 0$ (Bailey; Gatrell, 1995; Druck *et al.*, 2004).

O Índice Global de Moran varia no intervalo $[-1, \dots, 1]$. Valores positivos indicam uma correlação direta e valores negativos, uma correlação inversa. Quando aplicado aos resultados da segmentação, o ISSV mostra como os valores médios dos níveis de cinza das regiões diferem dos valores médios de seus vizinhos. Baixos valores para o índice indicam regiões pouco correlacionadas. Neste caso, os vizinhos são, em média, significativamente distintos entre si. Mínimos locais são traduzidos por resultados que indicam separabilidade entre segmentos vizinhos.

Dado o conjunto de 2500 resultados da segmentação, o gráfico da Figura 2.4 mostra a variação do ISSV para os resultados da segmentação da imagem Landsat-7/ETM+, considerando limiar de área e similaridade variando no intervalo $[1, 2, 3, \dots, 50]$. De maneira geral, a variação do ISSV é inversamente proporcional à variação destes limiares, ou seja, altos valores de área e similaridade geram resultados que apresentam segmentos adjacentes distintos, pouco correlacionados, que são traduzidos por baixos valores de ISSV.




FIGURA 2.4 - Gráfico do ISSV para a imagem Landsat-7/ETM+.

Dado um valor constante para o limiar de área igual a 22, o gráfico da Figura 2.5 mostra a variação do ISSV, considerando limiar de similaridade variando no intervalo $[1, 2, 3, \dots, 50]$. Tal gráfico mostra a existência de mínimos locais. O resultado obtido com limiar de área e similaridade igual a 22 e 29, respectivamente, apresenta um total de 45

segmentos, com valor de ISSV igual a 0,046 e bom resultado visual da segmentação. Nota-se através da inspeção visual que a variação no resultado do ISSV reflete as diferenças de separabilidade entre segmentos vizinhos obtidas nos resultados da segmentação.




FIGURA 2.5 - Resultados do ISSV para limiar de área igual a 22.

2.4 Função Objetivo - Software SPRING

A seleção de parâmetros nos algoritmos de segmentação de imagens por crescimento de regiões deve levar em consideração as condições necessárias à obtenção de bons resultados da segmentação. Tais condições devem combinar a obtenção de regiões internamente homogêneas e regiões adjacentes significativamente distintas em relação à característica nas quais elas são homogêneas.

Considerando estes pressupostos, esta seção apresenta a Função Objetivo (FO) usada na seleção de parâmetros do algoritmo de segmentação de imagens do software SPRING. A FO proposta nesta dissertação combina os índices de qualidade apresentados nas

seções anteriores, conforme descrito na Equação 2.3, onde v e I representam os índices IHI e ISSV, respectivamente:

$$F(v, I) = F(v) + F(I) \quad (2.3)$$

Conforme Equação 2.4, os índices IHI e ISSV são normalizados nas funções $F(v)$ e $F(I)$ visando a maximização dos resultados de interesse. Assim, quando o valor de v for mínimo, $F(v)$ será máximo, valendo o mesmo para os valores de I .

$$F(x) = \frac{X_{\max} - X}{X_{\max} - X_{\min}} \quad (2.4)$$

Bons resultados da segmentação são traduzidos por alta homogeneidade interna de seus segmentos e alta separabilidade entre segmentos vizinhos. Resultados que apresentam alta homogeneidade interna de seus segmentos são traduzidos por baixos valores de IHI. Resultados que apresentam alta separabilidade entre segmentos vizinhos são traduzidos por baixos valores de ISSV. Baixos valores de v e I retornam, respectivamente, altos valores de $F(v)$ e $F(I)$. Assim, bons resultados da segmentação são traduzidos pelos máximos valores de $F(v, I)$.

Dado o conjunto de 2500 resultados da segmentação, o gráfico da Figura 2.6 mostra a variação da FO para os resultados da segmentação da imagem Landsat-7/ETM+, considerando limiar de área e similaridade variando no intervalo $[1, 2, 3, \dots, 50]$. De maneira geral, a variação da FO é independente da variação destes limiares, no entanto, nota-se a existência de máximos e mínimos locais que indicam as variações nos resultados da segmentação.

Dado um valor constante para o limiar de área igual a 22, o gráfico da Figura 2.7 mostra a variação da FO, considerando limiar de similaridade variando no intervalo $[1, 2, 3, \dots, 50]$. Tal gráfico mostra a existência de máximos locais. O resultado obtido com limiar de área e similaridade igual a 22 e 25, respectivamente, apresenta um total de 53 segmentos, com valor da FO igual a 1,383 e bom resultado visual da segmentação.

Nota-se através da inspeção visual que os máximos valores da FO refletem bons resultados da segmentação.




FIGURA 2.6 - Gráfico da FO para a imagem Landsat-7/ETM+.




FIGURA 2.7 - Resultados da FO para limiar de área igual a 22.

2.5 Considerações Adicionais

Este capítulo teve como principal propósito apresentar os índices de qualidade e a função objetivo definidos nesta dissertação. Para tanto, foram apresentadas as condições necessárias à obtenção de bons resultados da segmentação, ou seja, a obtenção de regiões internamente homogêneas e regiões adjacentes significativamente distintas em relação à característica na qual elas são homogêneas. Foram propostos índices de qualidade, o IHI e o ISSV, que traduzem respectivamente tais condições, e uma função objetivo que agrega estes dois índices.

A abordagem adotada na definição da função objetivo, baseada na maximização dos resultados de interesse de IHI e ISSV, permite a seleção dos limiares que resultam em bons resultados da segmentação. Os máximos valores da função objetivo retornam os melhores resultados da segmentação.

A fim de buscar a obtenção de uma segmentação precisa de todos os alvos presentes em uma dada imagem, o método proposto apresenta uma alternativa objetiva na seleção dos limiares da segmentação. O pressuposto básico é de que há um conjunto ótimo de parâmetros da segmentação que determinam a obtenção de bons resultados, de acordo com as características espectrais e radiométricas da imagem.

CAPÍTULO 3

EXTENSÕES DA SELEÇÃO DE PARÂMETROS EM ALGORITMOS DE SEGMENTAÇÃO DE IMAGENS

Este capítulo apresenta duas extensões para o método de seleção de parâmetros apresentado no Capítulo 2. Inicialmente, a Seção 3.1 descreve a extensão do método para a seleção de parâmetros no algoritmo de segmentação do software e-Cognition®. Nesta seção, são apresentados os conceitos da segmentação orientada a objetos e a abordagem destes conceitos no algoritmo deste software. Em seguida, a Seção 3.2 descreve a extensão do método para a seleção de parâmetros em segmentações multibandas do software SPRING.

3.1 Seleção de Parâmetros no Algoritmo de Segmentação de Imagens do Software e-Cognition®

O e-Cognition® (Baatz et al., 2004) é um software comercial que implementa um sistema de interpretação de imagens baseado em segmentação e redes hierárquicas. O objetivo é usar o conhecimento do usuário para rotular redes hierárquicas obtidas por uma segmentação multinível. Numa descrição simplificada, este tipo de sistema é apresentado como “sistema baseado em conhecimento”. Segundo Bock e Lessing (2002), sistemas baseados em conhecimento são aqueles que modelam o conhecimento do intérprete em um ambiente computacional, emulando sua capacidade de análise dos dados de diferentes fontes e formatos na análise de imagens de sensores remotos (Feitosa *et al.*, 2005). Outros exemplos são os softwares SPAM (McKeown *et al.*, 1985), SIGMA (Matsuyama; Hwang, 1990), MESSIE (Clement *et al.*, 1993), ERNEST (Niemann *et al.*, 1990), AIDA (Tonjes; Liedtke, 1998) e a extensão deste último, o geoAIDA (Buckner *et al.*, 2001).

Uma das premissas dos sistemas baseados em conhecimento é a abordagem da análise de imagens orientada a objetos. Nesta abordagem, objetos são conceitos, abstrações definidas em um determinado domínio de uma aplicação (Rumbaugh *et al.*, 1991). Tais

objetos agrupam atributos e métodos que os definem (Yourdon, 1994), sendo que cada objeto é caracterizado por suas especificações de tamanho, forma, cor e tipo.

Em um sistema de análise orientada a objetos, os objetos com características comuns são agrupados em classes e estas são organizadas em forma de uma rede hierárquica, onde as classes de um nível inferior herdam as características da classe do nível superior. Parte-se do princípio de que a informação semântica necessária à interpretação de uma imagem não se restringe às informações espectrais e radiométricas dos pixels, sendo composta pelas informações dos objetos da imagem, bem como pelas suas relações de vizinhanças (Baatz et al., 2004).

Outras premissas são consideradas neste tipo de análise. Primeiramente, a caracterização dos objetos da imagem não pode se limitar apenas a atributos espectrais e radiométricos, sendo necessária a utilização de outros atributos como forma, tamanho, textura, padrão e contexto. Em segundo lugar, os objetos de interesse a serem extraídos de uma determinada cena podem estar associados a diferentes níveis de abstração. E, finalmente, a descrição do espaço de atributos de uma determinada classe pode ser imprecisa, o que introduz incertezas na associação de um objeto a determinada classe. A materialização destas premissas é dada pelo processo de segmentação e posterior estruturação das classes de objetos em uma rede de classes hierárquica (Baatz *et al.*, 2004).

3.1.1 Algoritmo de Segmentação de Imagens do Software e-Cognition®

O algoritmo de segmentação do software e-Cognition® aplica a abordagem de crescimento de regiões, onde o critério de similaridade é construído a partir do conceito de heterogeneidade interna das regiões. A heterogeneidade resulta da diferença entre o atributo de uma região e a soma dos valores deste mesmo atributo para as duas sub-regiões que serão agrupadas caso o critério seja satisfeito. Assim, são calculados os coeficientes de heterogeneidade para os atributos de cor e forma. A soma ponderada destes dois coeficientes forma o critério de similaridade f expresso pela Equação 3.1, onde w_{cor} é o peso do atributo cor, h_{cor} é o coeficiente de heterogeneidade do atributo

cor e h_{forma} é o coeficiente de heterogeneidade do atributo forma (Baatz *et al.*, 2004; Baatz *et al.*, 2000).

$$f = w_{cor} \cdot h_{cor} + (1 - w_{cor}) \cdot h_{forma} \quad (3.1)$$

O atributo cor constitui-se de uma soma ponderada dos desvios-padrão de cada banda espectral. O coeficiente de heterogeneidade deste atributo é dado pela Equação 3.2. Nela, w_c é o peso de cada banda espectral, $n_{união}$ e $\sigma_c^{união}$ são, respectivamente, o número de pixels e o desvio-padrão do objeto, e $n_{obj1,2}$ e $\sigma_c^{obj1,2}$ são, respectivamente, o número de pixels e o desvio-padrão de cada um dos subobjetos que serão agrupados caso o critério de similaridade seja satisfeito.

$$h_{cor} = \sum_c w_c (n_{união} \cdot \sigma_c^{união} - (n_{obj1} \cdot \sigma_c^{obj1} + n_{obj2} \cdot \sigma_c^{obj2})) \quad (3.2)$$

O atributo forma é composto por dois outros atributos: compacidade e suavidade. O primeiro é a razão entre o perímetro l de um objeto pela raiz quadrada do número n de pixels, sendo expresso pela Equação 3.3. A compacidade é um atributo que representa o quão agrupado estão os pixels de um determinado objeto. A suavidade é a razão entre o perímetro l do objeto e o perímetro b do retângulo envolvente paralelo às bordas da imagem com menor comprimento possível, sendo expresso pela Equação 3.4. A suavidade representa o grau de irregularidade do contorno de um objeto, ou seja, quanto mais compacto um objeto e mais suave a sua borda, menores serão os valores de cp e sv .

$$cp = \frac{l}{\sqrt{n}} \quad (3.3)$$

$$sv = \frac{l}{b} \quad (3.4)$$

Desta forma, o coeficiente de heterogeneidade do atributo forma é igual a soma ponderada das heterogeneidades dos atributos compacidade e suavidade, conforme Equação 3.5, onde w_{cp} é o peso do atributo compacidade, e h_{cp} e h_{sv} são,

respectivamente, os coeficientes de heterogeneidade dos atributos compacidade e suavidade.

$$h_{forma} = w_{cp} \cdot h_{cp} + (1 - w_{cp}) \cdot h_{sv} \quad (3.5)$$

As Equações 3.6 e 3.7 mostram as relações de h_{cp} e h_{sv} . Nelas, $cp_{união}$ é a compacidade do objeto, $cp_{obj1,2}$ é a compacidade de cada um dos subobjetos que serão agrupados caso o critério de similaridade seja satisfeito, $sv_{união}$ é a suavidade do objeto, e $sv_{obj1,2}$ é a suavidade de cada um dos subobjetos que serão agrupados caso o critério de similaridade seja satisfeito.

$$h_{cp} = n_{união} \cdot cp_{união} - (n_{obj1} \cdot cp_{obj1} + n_{obj2} \cdot cp_{obj2}) \quad (3.6)$$

$$h_{sv} = n_{união} \cdot sv_{união} - (n_{obj1} \cdot sv_{obj1} + n_{obj2} \cdot sv_{obj2}) \quad (3.7)$$

Após o cálculo de f , o valor de similaridade é comparado com o valor de escala fornecido pelo usuário. Se o valor de escala for menor que o quadrado do limiar de similaridade, os dois subobjetos analisados serão agrupados. Assim, no processo de segmentação do software e-Cognition®, o usuário precisa definir quatro parâmetros: fator de escala, peso para cada uma das bandas espectrais, peso para cor e peso para compacidade (Baatz *et al.*, 2004; Baatz *et al.*, 2000).

3.1.2 Função Objetivo - Software e-Cognition®

Conforme apresentado no Capítulo 2, a seleção de parâmetros nos algoritmos de segmentação de imagens por crescimento de regiões deve levar em consideração a obtenção de regiões internamente homogêneas e regiões adjacentes significativamente distintas em relação à característica nas quais elas são homogêneas. Estas mesmas condições são válidas para os resultados do algoritmo de segmentação de imagens do software e-Cognition®.

A imagem utilizada nesta seção é a mesma do Capítulo 2. 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.

Nesta seção, são analisados os resultados obtidos na segmentação desta imagem, considerando variações nos limiares de forma no intervalo $[0, 0.10, 0.20, \dots, 0.90]$ e de escala no intervalo $[4, 8, 12, \dots, 40]$. Para efeito destas análises, o peso para compacidade permaneceu constante, com valor igual a 0.50. Devido ao extenso âmbito de variação dos limiares de forma e escala, possibilitando uma infinidade de possíveis combinações, e devido a limitações na automatização do processo de segmentação, este experimento analisa 100 resultados amostrais da segmentação, desconsiderando para efeito das análises os possíveis resultados intermediários.

As Figuras 3.1 e 3.2 mostram, respectivamente, a variação do Índice de Homogeneidade Interna e do Índice de Separabilidade entre Segmentos Vizinhos. Nota-se que os gráficos apresentam, respectivamente, os mesmos padrões presentes nos gráficos das Figuras 2.2 e 2.4 (Capítulo 2). De maneira geral, a variação do IHI é diretamente proporcional à variação dos limiares de forma e escala, ou seja, baixos valores destes limiares geram resultados que apresentam segmentos internamente homogêneos, com baixos valores de variância média, que são traduzidos por baixos valores de IHI. A variação do ISSV é inversamente proporcional à variação dos limiares de forma e escala, ou seja, altos valores destes limiares geram resultados que apresentam segmentos adjacentes distintos, pouco correlacionados, que são traduzidos por baixos valores de ISSV.

O gráfico da Figura 3.3 mostra que a variação da FO é independente da variação dos limiares de forma e escala. No entanto, nota-se a existência de máximos e mínimos locais que indicam as variações nos resultados da segmentação. Dado um valor constante para o limiar de forma igual a 0,50, o gráfico da Figura 3.4 mostra a variação da FO, considerando limiar de escala variando no intervalo $[4, 8, 12, \dots, 40]$. Tal gráfico mostra a existência de máximos locais. O resultado obtido com limiar de forma e escala igual a 0,50 e 36, respectivamente, apresenta um total de 37 segmentos, com valor da

FO igual a 1,482 e bom resultado visual da segmentação. Nota-se através da inspeção visual que os máximos valores da FO refletem bons resultados da segmentação.




FIGURA 3.1 - Gráfico do IHI para a imagem Landsat-7/ETM+.




FIGURA 3.2 - Gráfico do ISSV para a imagem Landsat-7/ETM+.




FIGURA 3.3 - Gráfico da FO para a imagem Landsat-7/ETM+.




FIGURA 3.4 - Resultados da FO para limiar de forma igual a 0,50.

3.2 Seleção de Parâmetros na Segmentação Multibandas - Software SPRING

Grande parte dos algoritmos de segmentação por crescimento de regiões apresenta opções para segmentação multibandas. O algoritmo do software SPRING, por exemplo, permite a seleção das bandas espectrais a serem utilizadas no processo de segmentação, sendo que o número de bandas é definido pelo usuário. O algoritmo segmenta uma ou mais bandas, desde que todas as bandas tenham a mesma resolução espacial. Esta seção descreve a extensão do método para a seleção de parâmetros na segmentação multibandas do software SPRING.

Devido a uma limitação decorrente do cálculo da Matriz de Proximidade Espacial, definida para dados univariados e usada na obtenção do Índice de Separabilidade entre Segmentos Vizinho, o método de seleção de parâmetros proposto no Capítulo 2 não pode ser diretamente aplicado aos resultados da segmentação multibandas. Para efeito destas análises, considera-se que o resultado final de uma segmentação multibandas é decorrente da combinação dos resultados da segmentação de cada uma das bandas selecionadas. Em outras palavras, os melhores parâmetros para uma segmentação multibandas são obtidos após comparação e análise dos resultados da segmentação de cada uma das bandas selecionadas.

A imagem utilizada nesta seção corresponde a um recorte de 164x152 pixels de uma cena do sensor Landsat-7/ETM+, bandas espectrais 3 ($0.63\mu\text{m} - 0.69\mu\text{m}$), 4 ($0.78\mu\text{m} - 0.90\mu\text{m}$) e 5 ($1.55\mu\text{m} - 1.75\mu\text{m}$), 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 através do aumento do contraste, pela expansão do histograma da imagem através da aplicação da função de contraste linear.

Dado o conjunto de 2500 resultados da segmentação, o gráfico da Figura 3.5a mostra a variação da FO para os resultados da segmentação da banda 3 da imagem Landsat-7/ETM+, considerando limiar de área e similaridade variando no intervalo $[1, 2, 3, \dots, 50]$. A Figura 3.5b mostra, para a banda 3, o resultado obtido com o máximo valor da FO: limiar de área e similaridade igual a 30 e 38, respectivamente, e ISSV igual a -0,156. A

Figura 3.5c mostra, para a segmentação das bandas 3, 4 e 5, o resultado obtido com os limiares selecionados na Figura 3.5b.




FIGURA 3.5 - Resultados da FO para a banda 3 da imagem Landsat-7/ETM+ .

De forma análoga, o gráfico da Figura 3.6a mostra a variação da FO para os resultados da segmentação da banda 4 da imagem Landsat-7/ETM+, considerando limiar de área e similaridade variando no intervalo [1,2,3,...,50]. A Figura 3.6b mostra, para a banda 4, o resultado obtido com o máximo valor da FO: limiar de área e similaridade igual a 17 e 47, respectivamente, e ISSV igual a -0,395. A Figura 3.6c mostra, para a segmentação das bandas 3, 4 e 5, o resultado obtido com os limiares selecionados na Figura 3.6b.




FIGURA 3.6 - Resultados da FO para a banda 4 da imagem Landsat-7/ETM+ .

Por sua vez, o gráfico da Figura 3.7a mostra a variação da FO para os resultados da segmentação da banda 5 da imagem Landsat-7/ETM+, considerando limiar de área e similaridade variando no intervalo $[1,2,3,...,50]$. A Figura 3.7b mostra, para a banda 5, o resultado obtido com o máximo valor da FO: limiar de área e similaridade igual a 25 e 24, respectivamente, e ISSV igual a -0,254. A Figura 3.7c mostra, para a segmentação das bandas 3, 4 e 5, o resultado obtido com os limiares selecionados na Figura 3.7b.




FIGURA 3.7 - Resultados da FO para a banda 5 da imagem Landsat-7/ETM+ .

A análise visual das Figuras 3.5c, 3.6c e 3.7c permite constatar que o melhor resultado da segmentação multibandas é obtido a partir dos limiares da segmentação que geram, para cada uma das bandas selecionadas, o menor valor de ISSV. Para este experimento, tais limiares correspondem aos valores obtidos na segmentação da banda 4: limiar de área e similaridade igual a 17 e 47, respectivamente, e ISSV igual a -0,395.

3.3 Considerações Adicionais

Este capítulo teve como principal propósito apresentar duas extensões para o método de seleção de parâmetros proposto nesta dissertação. Os resultados obtidos no software e-Cognition® sugerem que o método de seleção de parâmetros pode ser estendido aos demais algoritmos de segmentação de imagens por crescimento de regiões. Contudo, como os experimentos foram realizados a partir de dados amostrais que não consideram todas as possíveis combinações entre os limiares de forma e escala, ressalta-se que variações nos intervalos considerados podem retornar resultados distintos.

Por sua vez, a abordagem da segmentação multibandas para o software SPRING baseou-se na análise dos testes empíricos realizados para dado conjunto de imagens. Tal abordagem não foi elaborada em um plano teórico, mas sim constatada através da análise dos resultados obtidos. Esta constatação reafirma a importância da realização de testes empíricos para o estudo e análise da dinâmica dos resultados.

CAPÍTULO 4

VALIDAÇÃO DO MÉTODO DE SELEÇÃO DE PARÂMETROS

Este capítulo apresenta resultados de validação do método de seleção de parâmetros utilizado neste trabalho. A Seção 4.1 apresenta a aplicação do método propostos em três conjuntos de imagens sintéticas geradas como realizações de campos aleatórios. A Seção 4.2 apresenta os resultados obtidos para um conjunto de imagens reais dos satélites Landsat-5 e QuickBird.

4.1 Validação com Imagens Sintéticas

Liu e Yang (1994) sugerem a utilização de imagens sintéticas na validação de resultados de segmentações. Para efeito desta validação, três conjuntos de imagens sintéticas foram analisados. Tais imagens foram geradas como realizações de campos aleatórios Gaussianos (Diggle; Ribeiro, 2002) sobre grades de tamanho 12×12 , 30×30 e 100×100 (Figura 4.1). Os valores da média e da variância foram escolhidos de modo que o número de níveis de cinza não fosse muito grande, obtendo coeficientes de variação iguais a 5% em todas as simulações. Os padrões presentes nas imagens foram controlados por um parâmetro de escala mantido igual a um terço do tamanho de cada grade de simulação. Para a função de covariância, foi adotado o modelo Gaussiano, no qual o valor da covariância entre os dados de duas localizações geográficas é inversamente proporcional ao quadrado da distância entre elas.




FIGURA 4.1 - Conjunto de Imagens Sintéticas.

As imagens sintéticas foram segmentadas no software SPRING, considerando limiar de área e similaridade variando no intervalo $[1, 2, 3, \dots, 50]$, totalizando 2500 resultados para cada segmentação. As respectivas Funções Objetivo foram calculadas, sendo que a Figura 4.2 mostra os resultados selecionados através de seus máximos valores. Os resultados obtidos para as imagens sintéticas de tamanho 12 x 12 (Figuras 4.2a, 4.2b, 4.2c), 30 x 30 (Figuras 4.2d, 4.2e, 4.2f) e 100x100 (Figuras 4.2g, 4.2i), apresentam bons resultados visuais da segmentação.




FIGURA 4.2 - Resultados da FO para as imagens sintéticas.

Contudo, o resultado obtido para a imagem sintética (h) de tamanho 100x100 não apresenta um bom resultado da segmentação. Dado o conjunto de 2500 resultados da segmentação, o gráfico da Figura 4.3a mostra a variação da FO para os resultados da segmentação desta imagem sintética, considerando limiar de área e similaridade variando no intervalo $[1, 2, 3, \dots, 50]$. A Figura 4.3b mostra o resultado selecionado através do maior valor da FO: limiar de área e similaridade igual a 29 e 6, respectivamente, e ISSV igual a 0,971. A Figura 4.3c mostra o resultado selecionado através do segundo maior valor da FO: limiar de área e similaridade igual a 01 e 45, respectivamente, e ISSV igual a -0,001. Tais resultados são justificados pela grande variação nos valores da

variância média e índice de Moran de cada resultado da segmentação. Nessas condições, as funções normalizadas $F(v)$ e $F(I)$ apresentam grande discrepância de valores, resultando em resultados não coerentes.

Este resultado indica que a técnica proposta para seleção de parâmetros de segmentação tem limitações, pois podem existir casos (como a Figura 4.3), nos quais o comportamento da imagem não satisfaz as hipóteses do método. O método proposto é aplicável quando existem bordas bem definidas na imagem, que geram descontinuidades na variação espacial dos dados. Esta situação ocorre com muita frequência para alvos naturais. O caso da Figura 4.3 é mais típico de uma variável única no espaço, o que não é caso da maioria das imagens que se quer segmentar na prática.




FIGURA 4.3 – Resultados da FO para a imagem sintética (h).

4.2 Validação com Imagens Reais

Para efeitos de comparação, são analisados a seguir alguns experimentos obtidos através da segmentação de imagens reais. As imagens utilizadas nesta seção correspondem: (a) a um recorte de 246x218 pixels de uma cena do sensor Landsat-5/TM, banda espectral 3 ($0.63\mu m - 0.69\mu m$), resolução espacial de 30 metros, órbita 222/70, de 09 de abril de 2005; e (b) um recorte de 703x611 pixels de uma cena do satélite QuickBird, banda pancromática ($0.45\mu m - 0.90\mu m$), resolução espacial de 0,60 metros, de 08 de janeiro de 2006.

Dado o conjunto de 2500 segmentações geradas no software SPRING, o gráfico da Figura 4.4a mostra a variação da FO para os resultados da segmentação da imagem Landsat-5/TM, considerando limiar de área e similaridade variando no intervalo $[1, 2, 3, \dots, 50]$. A Figura 4.4b mostra o resultado selecionado através do maior valor da FO: limiar de área e similaridade igual a 13 e 14, respectivamente, e ISSV igual a 0,331. A Figura 4.4c mostra o resultado selecionado através do menor valor da FO: limiar de área e similaridade igual a 01 e 45, respectivamente, e ISSV igual a 0,290.




FIGURA 4.4 - Resultados da FO para imagem Landsat-5/TM, software SPRING.

Dado o conjunto de 100 segmentações geradas no software SPRING, o gráfico da Figura 4.5a mostra a variação da FO para os resultados da segmentação da imagem QuickBird, considerando limiar de área e similaridade variando no intervalo [5,10,15,...,50]. A Figura 4.5b mostra o resultado selecionado através do maior valor da FO: limiar de área e similaridade igual a 45 e 15, respectivamente, e ISSV igual a 0,230. A Figura 4.5c mostra o resultado selecionado através do menor valor da FO: limiar de área e similaridade igual a 50 e 50, respectivamente, e ISSV igual a 0,180.




FIGURA 4.5 - Resultados da FO para imagem QuickBird, software SPRING.

Dado o conjunto de 100 segmentações geradas no software e-Cognition®, o gráfico da Figura 4.6a mostra a variação da FO para os resultados da segmentação da imagem QuickBird, considerando variações nos limiares de forma no intervalo $[0,0.10,0.20,...,0.90]$ e de escala no intervalo $[4,8,12,...,40]$. A Figura 4.6b mostra o resultado selecionado através do maior valor da FO: limiar de forma e escala igual a 0,1 e 40, respectivamente, e ISSV igual a 0,192. A Figura 4.6c mostra o resultado selecionado através do menor valor da FO: limiar de forma e escala igual a 0,9 e 40, respectivamente, e ISSV igual a 0,226.




FIGURA 4.6 - Resultados da FO para imagem QuickBird, software e-Cognition®.

A comparação visual dos resultados obtidos em imagens reais e sintéticas sugere que o método de seleção de parâmetros proposto nesta dissertação é independente do tipo de imagem e do algoritmo segmentador. Esta flexibilidade está diretamente relacionada com as definições do método, que são válidas para todas as imagens de sensoriamento remoto segmentadas em algoritmos de crescimento de regiões.

A utilização do método de seleção de parâmetros mostrou-se eficiente na delimitação dos alvos presentes nos recortes de imagens utilizadas nesta validação. Apesar de o método ter sido aplicado apenas em recorte de imagens, os índices IHI e ISSV podem ser obtidos para cenas completas, salvo esforço computacional necessário ao processamento destas segmentações.

CAPÍTULO 5

CONCLUSÕES

O principal propósito desta dissertação foi o de elaborar um método de seleção de parâmetros para algoritmos de segmentação de imagens por crescimento de regiões baseado em índices de qualidade que incorporam a dimensão espacial dos resultados da segmentação. Entre as principais contribuições desta dissertação, destacam-se:

- (a) *Construção de Índices de Qualidade*: os índices propostos, além de serem simples e de fácil manipulação, incluem em suas formulações parâmetros estatísticos que mensuram as condições necessárias à obtenção de bons resultados da segmentação;
- (b) *Incorporação da Dimensão Espacial*: de forma inédita, o método de seleção de parâmetros da segmentação proposto nesta dissertação incorpora a dimensão espacial da imagem quando considera a autocorrelação espacial existente entre os segmentos vizinhos.
- (c) *Definição de Critérios para a Seleção de Parâmetros*: esta dissertação desenvolveu um método objetivo de seleção de parâmetros para algoritmos de segmentação de imagens por crescimento de regiões que pode ser usado pelos diversos usuários destes algoritmos na definição dos parâmetros que resultem nos melhores resultados da segmentação.

Além da proposição de medidas de qualidade, este trabalho tinha como objetivo implícito demonstrar a eficiência do método de seleção de parâmetros proposto. Tal método mostrou-se bastante eficiente na obtenção de bons resultados da segmentação dado que os índices IHI e ISSV buscam medir as condições derivadas das definições dadas ao processo de segmentação.

As definições destes índices são consistentes com a lógica dos algoritmos de segmentação por crescimento de regiões. Os parâmetros de uma dada segmentação estão relacionados com o comportamento radiométrico dos alvos de interesse. Assim,

dado um detector óptico, uma condição de iluminação e um alvo de interesse e sua resposta espectral, a hipótese implícita nos algoritmos de crescimento de regiões é que as fronteiras entre os objetos da superfície terrestre correspondem as diferenças radiométricas presentes da imagem, sendo que tais diferenças são traduzidas pelos limiares de similaridade.

Além disto, a escolha dos parâmetros da segmentação é um compromisso global dependente das características da imagem. Os índices IHI e ISSV permitem medir tal escolha, indicando a obtenção de resultados com segmentos internamente homogêneos e segmentos adjacentes significativamente distintas em relação à característica nas quais eles são homogêneos.

Embora a proposição de índices de qualidade da segmentação não seja uma exclusividade desta dissertação, ainda são escassos os trabalhos que buscam implementar índices de qualidade nas rotinas dos algoritmos segmentadores. É necessário, portanto, um número maior de trabalhos que se dediquem a essa questão, focando nos aspectos práticos dessas implementações.

(trabalhos futuros?)

- selecionar algumas áreas representativas da imagens e tentar ponderar a escolha do índice com base nestes resultados.
- Propor algoritmos de segmentação por crescimento de regiões que já avaliem a separabilidade dos objetos resultantes.

REFERÊNCIAS BIBLIOGRÁFICAS

- Anselin, L. Interactive techniques and Exploratory Spatial Data Analysis. In: Longley, P.; Goodchild, M.; Maguire, D.; Rhind, D. (Ed.). **Geographical Information Systems: principles, techniques, management and applications**. Cambridge: Geoinformation International, 1999.
- Baatz, M.; Benz, U.; Dehghani, S.; Heynen, M.; Höltje, A.; Hofmann, P.; Lingenfelder, I.; Mimler, M.; Sohlbach, M.; Weber, M.; Willhauck, G. **e-Cognition Professional User Guide 4**. München, Germany: Definiens Imaging GmbH, 2004. 486 p.
- Baatz, M.; Schape, A. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. In: XII Angewandte Geographische Informationsverarbeitung, 2000, Wichmann-Verlag, Heidelberg.
- Bailey, T.; Gatrell, A. **An Interactive Spatial Data Analysis**. London: Longman Scientific and Technical, 1995.
- 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.
- Bins, L.; Fonseca, L.; Erthal, G. Satellite Imagery Segmentation: a region growing approach. In: VIII Brazilian Symposium on Remote Sensing, 1996, São José dos Campos, BR. INPE, p. 677-680.
- Bock, M.; Lessing, R. Remote sensing, formation of objects and determination of quality. In: 16th International Conference "Informatics for Environmental Protection", 2002, Vienna, Austria. September 25-27, 2002. p. 581-594.
- Borsotti, M.; Campadelli, P.; Schettini, R. Quantitative evaluation of color image segmentation results. **Pattern Recognition Letters**, v. 19, n. 8, p. 741-747, 1998.
- Buckner, J.; Pahl, M.; Stahlhut, O.; Liedtke, C. E. GEOAIDA - A knowledge based automatic image data analyser for remote sensing data. In: Congress on Computational Intelligence Methods and Applications, 2001, Bangor, Wales, UK. June, 2001.
- 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.
- Clement, V.; Giraudon, G.; Houzelle, S.; Sadakly, F. Interpretation of Remotely Sensed Images in a Context of Multisensor Fusion Using a Multispecialist Architecture. **IEEE Transactions on Geoscience and Remote Sensing**, v. 31, n. 4, p. 779-791, July, 1993.
- Diggle, P. J.; Ribeiro, P. J. Bayesian inference in Gaussian model-based Geostatistics. **Geographical and Environmental Modelling**, v. 6, n. 2, p. 129-146, 2002.
- Druck, S.; Carvalho, M. S.; Câmara, G.; Monteiro, A. M. V. **Análise Espacial de Dados Geográficos**. Brasília: EMBRAPA (ISBN 85-7383-260-6), 2004.

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 - 2005 Annual Conference of the International Association for Mathematical Geology, 2005, Toronto, Canada.

____. Parameter Selection for Region-Growing Image Segmentation Algorithms using Spatial Autocorrelation. **International Journal of Remote Sensing**, v. no prelo, 2006.

Feitosa, R. Q.; Mattos, C.; Santos, R. V.; Rego, L. F. G.; Pereira, A. A. C. Impacto de técnicas baseadas em conhecimento na análise de imagens de média resolução para mapeamento do desflorestamento na Amazônia. In: Simpósio Brasileiro de Sensoriamento Remoto, 2005, Goiânia - GO. INPE, 2005. p. 4065 - 4072.

Fotheringham, A. S.; Brunsdon, C.; Charlton, M. **Quantitative Geography: Perspectives on Spatial Analysis**. London: Sage, 2000.

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. i. 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.

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.

Liu, J.; Yang, Y.-H. Multiresolution color image segmentation. **IEEE Trans. on Pattern Analysis and Machine Intelligence**, v. 16, n. 7, p. 689, July, 1994.

Lucca, E. V. D. **Avaliação e comparação de algoritmos de segmentação de imagens de radar abertura sintética**. 207 p. Dissertação de Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1998.

Matsuyama, T.; Hwang, V. S. **A Knowledge-based Aerial Image Understanding System**. New York, NY: Plenum Press, 1990.

McKeown, D. M.; Harvey, W. A.; McDermott, J. Rule Based Interpretation of Aerial Imagery. **IEEE Transactions on Patterns Analysis and Machine Intelligence**, v. PAMI(7), n. 5, p. 570-585

Meinel, G.; Neubert, M. A comparison of segmentation programs for high resolution remote sensing data. **International Archives of Photogrammetry and Remote Sensing**, v. XXXV, n. Part B, p. 1097-1105, 2004.

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, 1995.

- Niemann, H.; Sagerer, G.; Schroder, S.; Kummert, F. ERNEST: A Semantic Network System for Pattern Understanding. **IEEE Transactions on Patterns Analysis and Machine Intelligence**, v. 12, n. 9, p. 883-905
- 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.
- R_Development_Core_Team. R: A language and environment for statistical computing. Vienna, Austria: R Foundation for Statistical Computing, 2005.
- Rumbaugh, J.; Blaha, M.; Premerlani, W.; Eddy, F.; Lorensen, W. **Object-Oriented Modeling and Design**. Englewood Cliffs, NJ: Prentice-Hall, 1991.
- Schlather, M. Simulation of stationary and isotropic random fields. **R News**, p. 18-22, 2001.
- _____. **RandomFields: Simulation and Analysis of Random Fields**, 2006. Disponível em: <http://www.unibw-hamburg.de/WWEB/math/schlath/schlather.html>.
- 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, 1991, Espoo, Finland. 2: IEEE, 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. IEEE Press,
- Tobler, W. Cellular geography. In: Gale, S.; G., O. (Ed.). **Philosophy in Geography**. Dordrecht: Reidel, 1979, p. 379-386.
- Tonjes, R.; Liedtke, C.-E. Knowledge-based Interpretation of Aerial Images Using Multiple Sensors. In: EUSIPCO-98 IX European Signal Processing Conference, 1998, Island of Rhodes, Greece.
- 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.
- Yourdon, E. **Object-oriented systems design: an integrated approach**. New Jersey: Prentice-Hall, 1994.

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