

Segmentação de imagens de terrenos baseada na associação de características de texturas com dependência espacial modelada por campo aleatório de Markov

William Robson Schwartz¹
Hélio Pedrini¹

¹ Departamento de Informática - Universidade Federal do Paraná (UFPR)
Centro Politécnico – 81531-990 - Curitiba-PR, Brasil
{william, helio}@inf.ufpr.br

Abstract. Demand for automatic image analysis methods has increased in the last years due to the large amount of information contained in high resolution images acquired by laser scanners and satellites. A crucial step is the image segmentation, responsible for obtaining high level information about regions in the image. This work presents a new terrain image segmentation method based on texture feature extraction and on spatial dependence modeled by a Markov random field. A set of images is used to show the results by applying the proposed method.

Palavras-chave: image segmentation, remote sensing, Markov random field, texture features, co-occurrence matrix, segmentação de imagens, sensoriamento remoto, campo aleatório de Markov, características de textura, matriz de co-ocorrência.

1. Introdução

Devido ao aumento significativo no volume e na resolução de imagens obtidas a partir de satélites e *laser scanners*, torna-se necessário o desenvolvimento de métodos automáticos para realizar a tarefa de análise de imagens. Além de redução da intervenção humana, pode-se obter maior acuracidade e rapidez na interpretação das imagens.

Como a análise de grande quantidade de dados contidos em imagens digitais é uma atividade complexa, um processo intermediário de *segmentação* é necessário para particionar o conjunto de entrada, formando regiões homogêneas, de modo a produzir estruturas de mais alto nível, correspondentes a objetos que possam ser relacionados para viabilizar o processo de interpretação. Desse modo, um processo de segmentação que identifique corretamente as formas, topologia e localização dos objetos é um requisito de fundamental importância para que as informações resultantes de um sistema de análise de imagens sejam confiáveis.

A segmentação de imagens, entretanto, ainda é um dos maiores desafios na área de análise de imagens. Processar uma imagem, de modo a encontrar um número de objetos, possivelmente em diferentes posições e com diferentes tamanhos e formas, é uma atividade complexa e extremamente dependente da correta extração de características dos objetos, especialmente em imagens apresentando ruído.

A etapa de segmentação consiste na partição de uma imagem em regiões disjuntas, tal que cada região apresente características homogêneas conforme um determinado conjunto de características. Diversas abordagens têm sido propostas para segmentação, tais como métodos de detecção de bordas de objetos, agrupamento de regiões com características semelhantes, abordagens semânticas e a utilização da dependência espacial entre os elementos (*pixels*) da imagem. No entanto, não existe um método genérico que apresente bom desempenho e acuracidade em diferentes domínios de aplicação.

Devido ao seu desempenho satisfatório em diversas áreas de aplicação (Dubes e Jain 1989, Tso e Mather 1999, Fjortoft et al. 2003, Tonazzini e Bedini 2003), abordagens que se baseiam em dependência espacial têm recebido crescente atenção da comunidade científica.

Além de considerar as características extraídas a partir das regiões da imagem, como utilizado normalmente pelas técnicas de segmentação, esses métodos incorporam informações sobre a vizinhança de uma dada região através do paradigma Bayesiano.

Este trabalho apresenta um novo método para segmentação de imagens de terrenos baseado na extração de características de texturas e na dependência espacial entre as regiões. A formulação utilizada baseia-se no trabalho de Jackson e Landgrebe (2002), entretanto, sem a necessidade de apresentar um conjunto de treinamento. Para isso, o método é composto de duas etapas. Na primeira, as G regiões que apresentam características homogêneas são agrupadas por meio do método *k-means* (Theodoridis 2003), permitindo a obtenção das informações necessárias para descrição das regiões da imagem.

Ao final da primeira etapa, a segmentação já está concluída em regiões que apresentam características homogêneas. Ao contrário dos métodos de Yamazaki e Gingras (1995) e Fwu e Djuric (1996), que utilizam o *modo condicional de iteração* (ICM, *iterated conditional modes*) em toda a imagem, este aplica o ICM apenas sobre os pixels localizados nas fronteiras entre regiões homogêneas, reduzindo, dessa maneira, a quantidade de computação requerida.

O restante deste trabalho é organizado como segue. A seção 2 apresenta os principais conceitos da segmentação baseada em dependência espacial. A seção 3 descreve, em detalhes, a metodologia proposta. Os resultados experimentais, obtidos a partir da aplicação do método de segmentação sobre um conjunto de imagens digitais de terrenos, são apresentados na seção 4. Finalmente, na seção 5 são descritas as conclusões obtidas com este trabalho.

2. Segmentação Baseada em Dependência Espacial

Os métodos que utilizam informações sobre dependência espacial, relacionam as características de uma região com uma dada vizinhança pela utilização do paradigma Bayesiano (Winkler 2003). Com objetivo de particionar uma imagem em regiões homogêneas, agrupando os pixels que apresentam características semelhantes, esses métodos consideram a existência de uma observação (imagem de entrada) e uma imagem segmentada corretamente, porém desconhecida.

Cada pixel da imagem deve ser considerado uma variável aleatória que assume valores em $L = \{0, 1, \dots, G-1\}$, onde G denota o número de regiões com características distintas contidas na imagem. $\mathbf{Y} = \{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_n\}$ denota o conjunto composto pelos vetores de características das variáveis observadas. As informações sobre a dependência espacial são modeladas por um campo aleatório de Markov (MRF, *Markov random field*), representado pelo conjunto de variáveis aleatórias $\mathbf{X} = \{X_1=x_1, \dots, X_n=x_n\}$, onde x_i pertence ao conjunto L .

O teorema de Bayes, mostrado na equação 1, é utilizado para estabelecer a relação entre as características \mathbf{Y} com a dependência espacial entre as variáveis em \mathbf{X} , onde $P(\mathbf{X})$ é denominada probabilidade *a priori*. Conforme essa modelagem, a segmentação correta para uma imagem é aquela que maximiza a probabilidade *a posteriori* $P(\mathbf{X}|\mathbf{Y})$.

$$P(\mathbf{X} | \mathbf{Y}) = \frac{P(\mathbf{X})P(\mathbf{Y} | \mathbf{X})}{P(\mathbf{Y})} \quad (1)$$

Contudo, o custo computacional para determinar a segmentação que maximiza $P(\mathbf{X}|\mathbf{Y})$ é alto, devido à necessidade de calcular G^n vezes a probabilidade condicional mostrada pela equação 1. Portanto, em tempo computacional aceitável, pode-se apenas obter segmentações que se aproximam da solução ótima. Tais aproximações são efetuadas por meio de métodos de relaxação, tais como *máximo a posteriori* (MAP, *maximum a posteriori*) (Geman e Geman 1984), ICM (Besag 1986) e *probabilidade condicional máxima* (MMP, *maximum marginal probability*) (Marroquin et al. 1987), que maximizam iterativamente a probabilidade $P(\mathbf{X}|\mathbf{Y})$.

2.2 Características de Texturas

Textura é uma propriedade importante na percepção de regiões e superfícies, contendo informações sobre a distribuição espacial das variações de tonalidade dos objetos. Não há uma definição geral para textura, tal dificuldade é refletida pelo grande número de métodos de análise de texturas encontrados na literatura (Reed e Dubuf 1993). Haralick et al. (1973), por exemplo, definiram textura a partir de medidas de uniformidade, densidade, aspereza, regularidade e intensidade, dentre outras características da imagem.

Dentre as técnicas utilizadas para análise de texturas, a *abordagem estatística* utiliza um conjunto de medidas estatísticas locais para representar uma imagem texturizada. Na *abordagem estrutural*, as regiões da textura são consideradas como padrões bidimensionais compostos por primitivas que se relacionam. Na *abordagem baseada em modelos*, a textura pode ser considerada como uma realização de um processo estocástico regido por determinados parâmetros, os quais são utilizados como características.

A extração de características de texturas a partir da matriz de co-ocorrência está entre os métodos mais utilizados da abordagem estatística para análise de texturas. Essa matriz contém uma tabulação da frequência relativa $P(i, j, d, \theta)$, considerando dois pixels vizinhos separados pela distância d na orientação θ , um pixel com tom de cinza i e o outro com tom de cinza j .

A partir da matriz de co-ocorrência, quatorze características estatísticas são extraídas (Haralick et al. 1973), incluindo variância, segundo momento angular, energia, contraste, correlação, homogeneidade, momento inverso da diferença, soma da média, soma da variância, soma da entropia, diferença da variância diferença da entropia, medida de informação da correlação e coeficiente de correlação máxima.

2.3 Campo Aleatório de Markov

Para que as interações entre os pixels sejam definidas, uma imagem deve ser modelada probabilisticamente, ou seja, $\mathbf{X} = (X_1 = x_1, X_2 = x_2, \dots, X_n = x_n)$, onde x_i pertence ao conjunto L definido no início da seção 2. Uma realização dessa imagem é o vetor $\mathbf{x} = (x_1, x_2, \dots, x_n)$, dessa maneira, o espaço amostral possui $\{0, 1, \dots, G-1\}^n$ realizações distintas.

Com a modelagem probabilística, a imagem torna-se um conjunto de variáveis aleatórias. Pode-se, então, determinar a distribuição conjunta dessas variáveis, denotada por $P(\mathbf{X})$, e calcular a probabilidade de uma realização \mathbf{x} , denotada por $P(\mathbf{x})$. Entretanto, devido à falta de informações sobre a dependência entre as variáveis aleatórias Abend et al. (1965) concluem que apenas devem ser consideradas interações locais entre os vizinhos, obtendo-se assim, soluções aproximadas, no entanto, computáveis.

Com a utilização da dependência local, diversos modelos estocásticos de imagens têm sido propostos, tais como *Markov Mesh* (Abend et al. 1965), *modelo de Pickard* (Pickard 1980) e o *campo aleatório de Markov* (Besag 1974). Todos esses modelos determinam a probabilidade $P(\mathbf{x})$ através da equação 2, diferindo apenas nos componentes do conjunto n_i , que denota a vizinhança da variável aleatória X_i .

$$P(\mathbf{x}) = \prod P(X_i = x_i | n_i) \quad (2)$$

Quando se utiliza o campo aleatório de Markov, a probabilidade $P(X_i = x_i | n_i)$ segue a distribuição de Gibbs, apresentada na equação 3, onde \mathbf{x}^x denota a realização em que a variável aleatória $X_i = x$, U_c representa a função de potencial dos elementos que compõem a vizinhança de X_i e C são as cliques que contêm X_i (Geman e Geman 1984).

$$P(X_i = x_i | n_i) = \frac{\exp\left(-\sum_{C:i \in C} U_c(\mathbf{x})\right)}{\sum_{x \in L} \exp\left(-\sum_{C:i \in C} U_c(\mathbf{x}^x)\right)} \quad (3)$$

3. Metodologia Proposta

O objetivo do método proposto é a segmentação de imagens de terrenos em G regiões que apresentem características semelhantes. O método é composto de duas etapas. A primeira, baseada em Schwartz e Pedrini (2003) e Schwartz e Pedrini (2004), segmenta as regiões homogêneas das imagens por meio do método k -means e um histograma bidimensional e, na segunda etapa, baseada na formulação apresentada por Jackson e Landgrebe (2002), utiliza-se o ICM para determinar a localização das fronteiras existentes entre as regiões homogêneas. O diagrama mostrado na figura 1 ilustra as etapas utilizadas para a segmentação.

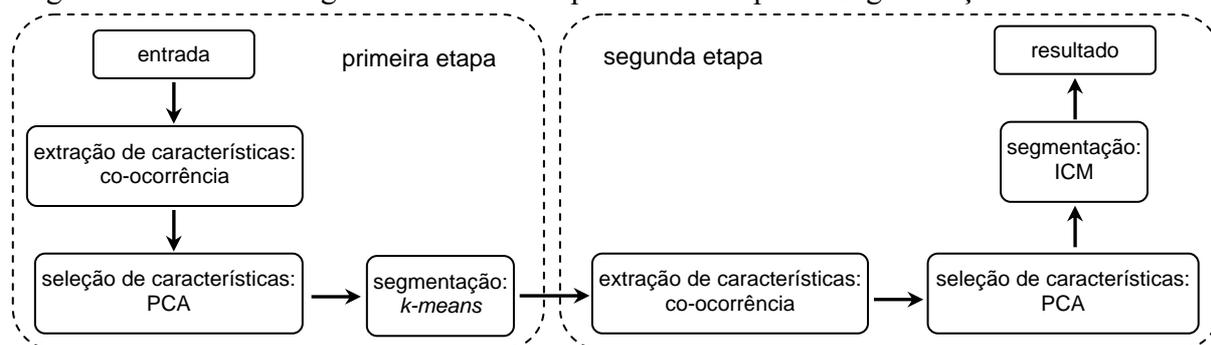


Figura 1: Diagrama apresentando as duas etapas do método para segmentação de imagens.

Durante a primeira etapa do algoritmo, a imagem é dividida em janelas retangulares, sendo permitida a sobreposição entre regiões distintas. Para cada janela, calcula-se a matriz de co-ocorrência, e um vetor de característica é criado a partir da extração de 14 medidas estatísticas dessa matriz. Portanto, cada região será descrita apenas por esse vetor e não mais pelos tons de cinza dos pixels que a compõe, obtendo-se, dessa maneira, uma redução no volume dos dados para representar a imagem.

Também é desejável reduzir a redundância entre os dados utilizados na descrição de cada janela pois, além de diminuir o custo computacional, evita-se a ocorrência de ambigüidades durante a segmentação. Com esse objetivo, o método de análise de componentes principais (PCA, *principal component analysis*), também conhecido como transformada de *Karhunen-Loève* (Theodoridis 2003), é aplicado sobre os dados contidos nos vetores de características.

Para que os resultados obtidos com a PCA não sejam afetados pela escala das medidas extraídas da matriz de co-ocorrência, os componentes dos vetores de características devem ser padronizados através da equação 4, onde x contém o valor da medida em questão, μ e σ denotam, respectivamente, a média e o desvio padrão dessa medida, sendo obtidos a partir das janelas amostradas. Após a sua determinação, z substituirá x no vetor de características.

$$z = \frac{x - \mu}{\sigma} \quad (4)$$

Tendo sido efetuada a PCA sobre os dados padronizados de cada vetor, passam a ser utilizados apenas os autovetores que melhor descrevem a variância, obtendo-se uma redução de dimensionalidade dos dados. Assim, o método k -means é utilizado para definir os centróides dos G agrupamentos que dividem a imagem em regiões homogêneas, rotulando cada uma das janelas com um valor em L .

Com o agrupamento inicial concluído, um histograma bidimensional é calculado. A entrada (x,y) contém a frequência de ocorrência de cada um dos G rótulos, e um pixel (x,y) será considerado como pertencente à região homogênea i apenas se a entrada (x,y) contiver valores distintos de nulo apenas em i ; caso contrário, a segmentação deste pixel será postergada para a segunda etapa do algoritmo. Dessa maneira, quanto maior for o número de janelas sobrepostas, mais preciso será o resultado da primeira etapa da segmentação.

Para que os pixels remanescentes da primeira etapa do algoritmo sejam segmentados, utiliza-se o método ICM, que efetua uma aproximação da maximização da probabilidade *a posteriori*, conforme equação 1. Dado que o ICM apenas maximiza a probabilidade local de uma variável aleatória, como pode ser observado pela equação 5, seu custo computacional é menor que o apresentado pelos métodos de maximização MAP e MMP.

$$x_i \leftarrow \operatorname{argmax}\{P(X_i = v | n_i)P(\mathbf{Y}_i = \mathbf{y}_i | X_i = v)\}, \quad \forall v \in L \quad (5)$$

Conforme a formulação apresentada por Jackson e Landgrebe (2002), os dois termos da equação 5 podem ser determinados pelas equações 6 e 7. A equação 6, uma aproximação da equação 3, modela a dependência espacial entre as variáveis aleatórias, enquanto a equação 7 considera que as características extraídas para cada pixel seguem a distribuição Gaussiana multivariada, onde $\delta(x) = 1$ se $x=0$, Z denota uma constante de normalização, μ_{x_i} e Σ_{x_i} denotam o vetor de médias e a matriz de covariância que representa a i -ésima região homogênea, p contém o número de componentes de \mathbf{y}_i e β um parâmetro determinado experimentalmente que representa a força da interação entre os vizinhos (Winkler 2003).

$$P(X_i = v | n_i) = \frac{1}{Z} \exp\left\{-\beta \sum_{t \in n_i} [1 - \delta(x_i - x_t)]\right\} \quad (6)$$

$$P(\mathbf{Y}_i = \mathbf{y}_i | X_i = x_i) = \frac{1}{(2\pi)^{p/2} |\Sigma_{x_i}|^{1/2}} \exp\left\{-\frac{1}{2} [(\mathbf{y}_i - \mu_{x_i})^T \Sigma_{x_i}^{-1} (\mathbf{y}_i - \mu_{x_i})]\right\} \quad (7)$$

A extração e seleção de características são efetuadas de maneira análoga à primeira etapa do método, no entanto, ao invés de particionar a imagem em sub-regiões, as medidas são extraídas a partir de janelas centradas nos pixels que ainda não tenham sido segmentados. Dessa maneira, o vetor \mathbf{y}_i é preenchido com os valores resultantes da PCA efetuada sobre as medidas da matriz de co-ocorrência extraída da janela centrada no i -ésimo pixel.

Após os vetores \mathbf{y}_i serem preenchidos e a ordem da vizinhança ser determinada, basta executar alguns ciclos do ICM para que, os pixels ainda não segmentados na primeira etapa, sejam atribuídos a uma dentre as G regiões homogêneas da imagem. Finalmente, após a união dos resultados obtidos pelas duas etapas, a imagem estará completamente segmentada.

4. Resultados Experimentais

O método proposto é aplicado sobre um conjunto composto por três imagens reais de terrenos. A figura 2 apresenta os resultados obtidos utilizando a imagem mostrada em 2(a), com dimensões de 512x512 pixels. Em 2(b) é mostrado o resultado da segmentação ao final da primeira etapa; as regiões mostradas na cor branca devem ser segmentadas durante a segunda etapa do método. A figura 2(c) apresenta o resultado obtido se fosse utilizado apenas o método *k-means*, enquanto 2(d) mostra o resultado final da segmentação utilizando o método proposto. Percebe-se que a utilização do ICM na segunda etapa do algoritmo proporciona uma segmentação acurada, adaptando-se adequadamente às fronteiras entre as classes.

Pode-se observar também que, após a primeira etapa do algoritmo, apenas as regiões localizadas nas divisões das classes não foram segmentadas, ou seja, todas as regiões homogêneas presentes na imagem foram segmentadas. Desse modo, o ICM deve ser executado apenas em uma área reduzida da imagem, ao contrário do que é efetuado pelos

métodos propostos por Yamazaki e Gingras (1995) e Fwu e Djuric (1996), que segmentam toda a imagem utilizando o ICM.

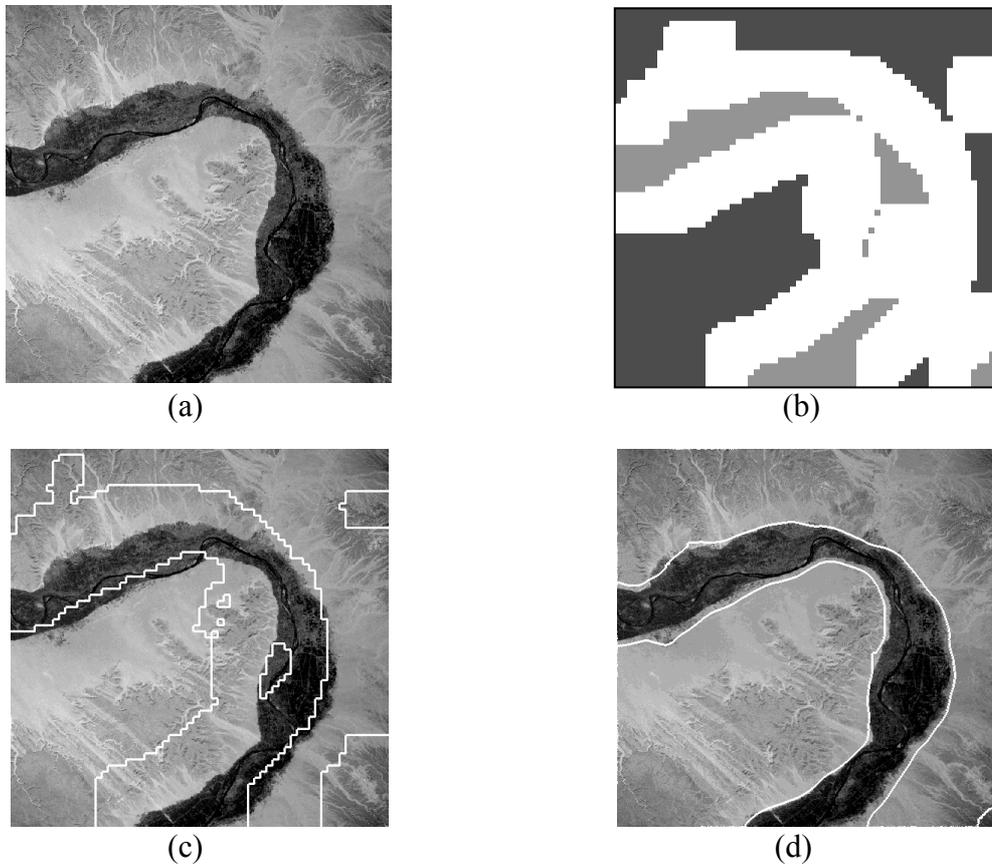


Figura 2: Resultado da segmentação obtida em uma imagem de terreno com 512x512 pixels. (a) imagem original; (b) resultado ao final da primeira etapa do método proposto; (c) segmentação obtida com o método *k-means*; (d) segmentação obtida após a execução de 50 ciclos do ICM.

A figura 3 apresenta a segmentação obtida para outra imagem de terreno, composta por 512x512 pixels. Em (a) é mostrado o resultado obtido apenas com a utilização do método *k-means*. A figura 3(b) apresenta a segmentação obtida após a execução de apenas 5 ciclos do ICM. A segmentação final é mostrada em (c), obtida após 100 ciclos do ICM.

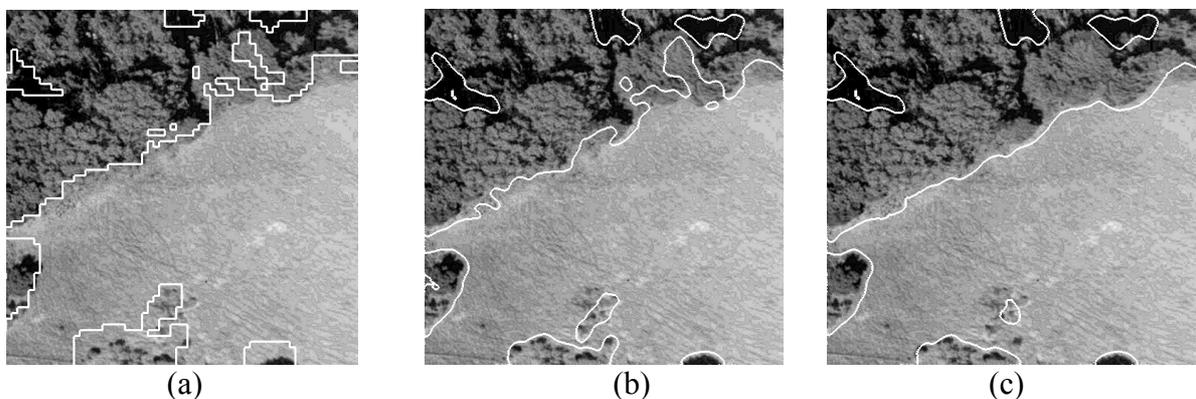


Figura 3: Imagem aérea com 512x512 pixels. (a) resultado obtido com a aplicação do método *k-means*; (b) resultado obtido após 5 ciclos do ICM; (c) resultado final obtido após a execução de 100 ciclos do ICM.

Finalmente, a figura 4 apresenta o resultado da segmentação obtida para uma imagem composta por 2048x1024 pixels. Apesar da dimensão da imagem ser maior, o resultado se manteve mais acurado daquele obtido apenas com a utilização do método *k-means*.

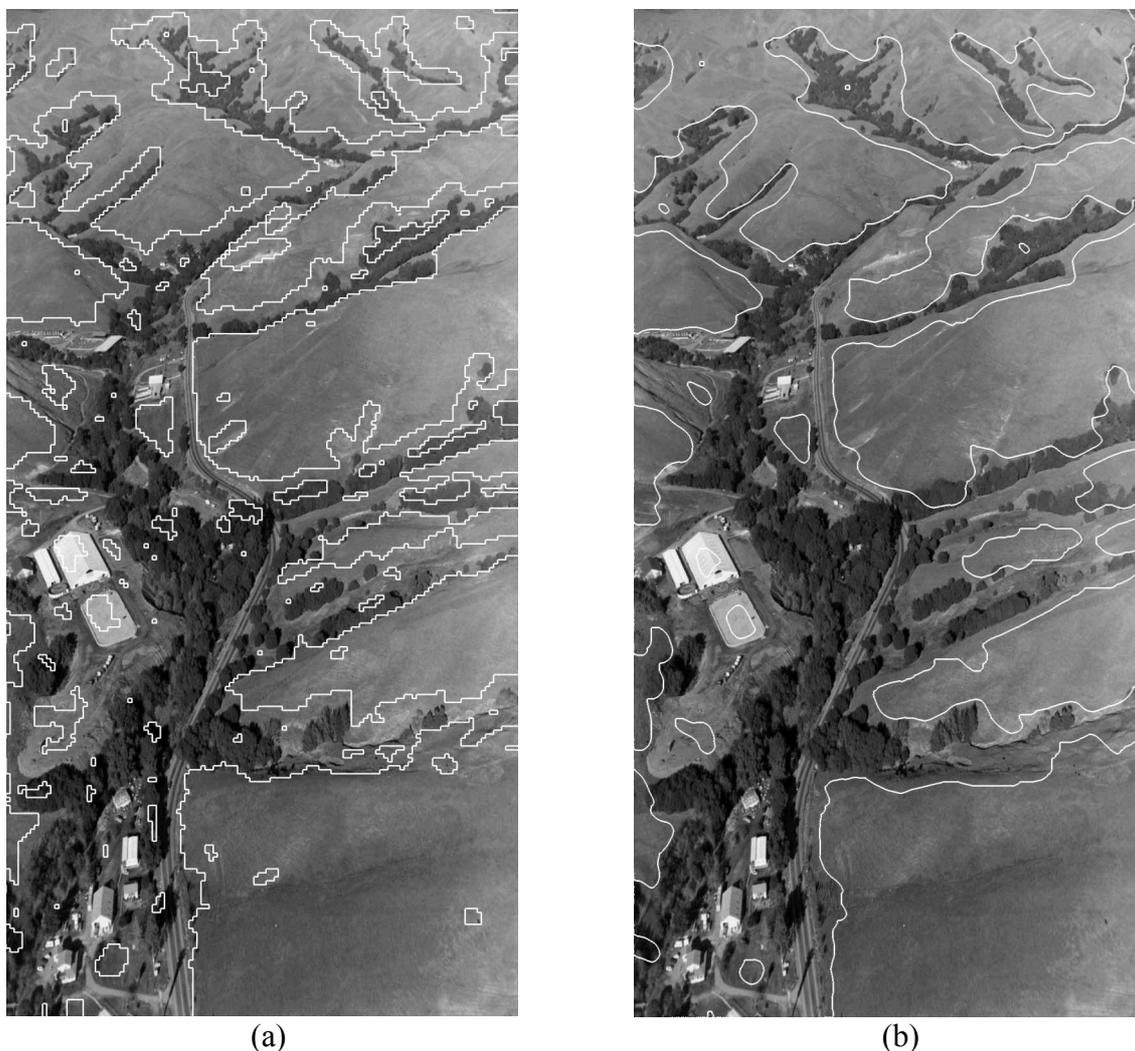


Figura 4: Resultado da segmentação obtida a partir de uma imagem com 2048x1024 pixels. (a) resultado obtido com a aplicação do método *k-means*; (b) resultado obtido ao final da segunda etapa do método proposto, após 50 ciclos do ICM.

O número de pixels e o percentual da imagem segmentada durante a primeira e a segunda etapas do método são mostrados na tabela 1. Pode-se perceber que, em geral, o ICM é aplicado em menos da metade da imagem, permitindo, assim, que a quantidade de computação requerida para a segmentação seja reduzida.

<i>imagem</i>	<i>No. de pixels da imagem</i>	<i>No. de pixels segmentados durante a primeira etapa</i>	<i>No. de pixels segmentados durante a segunda etapa</i>
Figura 2	262.144	118.400 (45,16%)	143.744 (54,84%)
Figura 3	262.144	197.248 (75,24%)	64.896 (24,76%)
Figura 4	2.097.152	1.371.776 (65,41%)	725.376 (34,59%)

Tabela 1: Número de pixels segmentados em cada uma das etapas do método proposto.

5. Conclusões e Trabalhos Futuros

Uma etapa crítica presente no processo de análise de imagens é a segmentação, responsável por obter informações de alto nível sobre os objetos ou regiões contidos na imagem, de modo a facilitar sua interpretação. Este trabalho apresentou um novo método de segmentação de imagens de terrenos baseado na extração de características de texturas e na dependência espacial entre as regiões.

A utilização da dependência espacial, ao invés de apenas as características de texturas, proporciona resultados mais acurados, pois possibilita que a segmentação seja adaptável às características específicas de cada região. A divisão do método em duas etapas eliminou a necessidade de um conjunto de treinamento previamente definido, além de evitar a aplicação do método ICM para todos os pixels da imagem.

Como trabalhos futuros, os autores pretendem investigar novas características de texturas que, assim como as medidas estatísticas extraídas da matriz de co-ocorrência, possam descrever eficientemente as regiões da imagem.

Referências

- Abend, K.; Harley, T.J.; Kanal, L.N. Classification of binary random patterns. **IEEE Transactions on Information Theory**, v. IT-11, n. 4, p. 538-544, 1965.
- Besag, J.E. Spatial interaction and statistical analysis of lattice systems. **Journal of the Royal Statistical Society: Series B (Statistical Methodology)**, v. 36, n. 2, p. 192-236, 1974.
- Besag, J.E. On the statistical analysis of dirty pictures. **Journal of the Royal Statistical Society: Series B (Statistical Methodology)**, v. 48, n. 3, p. 259-302, 1986.
- Dubes, R.C.; Jain A.K. Random field models in image analysis. **Journal of Applied Statistics**, v. 16, n. 2, p. 131-164, 1989.
- Fjortoft, R.; Delignon, Y.; Pieczynski, W.; Sigelle M.; Tupin, F. Unsupervised classification of radar images using hidden Markov chains and hidden Markov random fields. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 3, p. 675-686, 2003.
- Geman, S.; Geman, D. Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 6, n. 6, p. 721-751, 1984.
- Fwu, J.K.; Djuric, P.M. Unsupervised vector image segmentation by a tree structure-ICM algorithm. **IEEE Transaction on Medical Imaging**, v. 15, n. 6, p. 871-880, 1996.
- Haralick, R.M.; Shanmugam, K.K.; Dinstein, I. Textural features for image classification, **IEEE Transactions on Systems, Man, and Cybernetics**, v. 3, n. 6, p. 610-611, 1973.
- Jackson, Q.; Landgrebe, D.A. Adaptive Bayesian contextual classification based on Markov random fields. **IEEE Transactions on Geoscience and Remote Sensing**, v. 40, n. 11, p. 2454-2463, 2002.
- Marroquin, J.; Mitter, S.; Poggio, T. Probabilistic solution of ill-posed problems in computational vision. **Journal of the American Statistical Association**, v. 82, n. 397, p. 76-89, 1987.
- Pickard, D.K. Unilateral Markov random fields. **Advanced Applied Probability**, v. 12, p. 655-671, 1980.
- Reed, T.E.; Dubuf, J.M.H. A review of recent texture segmentation and feature extraction techniques. **CVGIP: Image Understanding**, v. 57, n. 3, p. 359-372, 1993.
- Schwartz, W.R.; Pedrini, H. Método para classificação de imagens baseada em matrizes de co-ocorrência utilizando características de textura. In: Colóquio Brasileiro de Ciências Geodésicas, 3, 2003, Curitiba-PR, **Anais...** p. 1-11.
- Schwartz, W.R.; Pedrini, H. Texture Classification Based on Spatial Dependence Features Using Co-Occurrence Matrices and Markov Random Fields. In: IEEE International Conference on Image Processing, 2004, Cingapura, **Proceedings...**
- Theodoridis, S.; Koutroumbas, K. **Pattern recognition**. Elsevier Academic Press, 2003. 689 p.
- Tonazzini, A.; Bedini, L. Monte Carlo Markov chain techniques for unsupervised MRF-based image denoising, **Pattern Recognition Letters**, v. 24, n. 1, p. 55-64, 2003.
- Tso, B.C.; Mather, P.M. Classification of multisource remote sensing imagery using a genetic algorithm and Markov random fields. **IEEE Transactions on Geoscience and Remote Sensing**, v. 37, p. 1255-1260, 1999.
- Winkler, G. **Image analysis, random fields and Markov chain Monte Carlo methods, a mathematical introduction**. Applications of Mathematics, Stochastic Modeling and Applied Probability. Berlin: Springer-Verlag, 2003. 387 p.
- Yamazaki, T.; Gringas, D. Image classification using spectral and spatial information based on MRF models. **IEEE Transactions on Image Processing**, v. 4, n. 9, p. 1333-1339, 1995.