

SEGMENTAÇÃO DE DADOS DE PERFILAMENTO A LASER EM ÁREAS URBANAS UTILIZANDO UMA ABORDAGEM BAYESIANA

Laser Scanning Data Segmentation in Urban Areas by a Bayesian Framework

EDINÉIA APARECIDA DOS SANTOS GALVANIN¹

ALUIR PORFÍRIO DAL POZ²

Aparecida Doniseti Pires de Souza³

Universidade Estadual Paulista - Faculdade de Ciências e Tecnologia

¹ Programa de Pós-Graduação em Ciências Cartográficas

² Departamento de Cartografia

³ Departamento de Matemática, Estatística e Computação

Rua Roberto Simonsen, 305 - Campus de Presidente Prudente – SP

edineia@pos.prudente.unesp.br

{aluir, adps}@fct.unesp.br

RESUMO

Neste artigo é apresentada uma metodologia para a segmentação de um Modelo Digital de Elevação obtido a partir de um sistema de varredura a laser. A metodologia de segmentação baseia-se na utilização das técnicas de divisão recursiva usando a estrutura *quadtree* e de fusão de regiões usando o modelo *Markov Random Field*. Inicialmente a técnica de divisão recursiva é usada para particionar o Modelo Digital de Elevação em regiões homogêneas. No entanto, devido a ligeiras diferenças de altura no Modelo Digital de Elevação, nesta etapa a fragmentação das regiões pode ser relativamente alta. Para minimizar essa fragmentação, uma técnica de fusão de regiões baseada no modelo *Markov Random Field* é aplicada nos dados segmentados. As regiões resultantes são estruturadas usando um grafo de regiões adjacentes (*Region Adjacency Graph*). Cada nó do *Region Adjacency Graph* corresponde a uma região do Modelo Digital de Elevação segmentado e dois nós tem conectividade entre eles se as duas regiões correspondentes compartilham de uma mesma fronteira. Em seguida, assume-se que o comportamento da variável aleatória em relação a cada nó dá-se de acordo com um *Markov Random Field*. Esta hipótese permite a obtenção da chamada distribuição de probabilidade a posteriori, cuja solução é obtida via estimativa

Maximum a Posteriori. Regiões que apresentam alta probabilidade de fusão são fundidas. Os experimentos realizados com os dados de perfilamento a laser mostraram que a metodologia proposta permitiu separar os objetos no Modelo Digital de Elevação com um baixo nível de fragmentação.

Palavras chaves: *Markov Random Field*, Modelo Digital de Elevação, Segmentação por região, QuadTree.

ABSTRACT

In this paper is presented a region-based methodology for Digital Elevation Model segmentation obtained from laser scanning data. The methodology is based on two sequential techniques, i.e., a recursive splitting technique using the quad tree structure followed by a region merging technique using the Markov Random Field model. The recursive splitting technique starts splitting the Digital Elevation Model into homogeneous regions. However, due to slight height differences in the Digital Elevation Model, region fragmentation can be relatively high. In order to minimize the fragmentation, a region merging technique based on the Markov Random Field model is applied to the previously segmented data. The resulting regions are firstly structured by using the so-called Region Adjacency Graph. Each node of the Region Adjacency Graph represents a region of the Digital Elevation Model segmented and two nodes have connectivity between them if corresponding regions share a common boundary. Next it is assumed that the random variable related to each node, follows the Markov Random Field model. This hypothesis allows the derivation of the *posteriori* probability distribution function whose solution is obtained by the *Maximum a Posteriori* estimation. Regions presenting high probability of similarity are merged. Experiments carried out with laser scanning data showed that the methodology allows to separate the objects in the Digital Elevation Model with a low amount of fragmentation.

KEY WORDS: Markov Random Field, Digital Elevation Model, Region Segmentation, Quad Tree.

1. INTRODUÇÃO

A segmentação de imagens em visão computacional e análise de imagens é o termo usado para denotar o processo de agrupamento de partes de uma imagem genérica em unidades que são homogêneas com respeito a uma ou várias características (ou atributos), resultando em uma imagem segmentada (Ballard e Brown, 1982).

No âmbito da Cartografia, a motivação para a segmentação de feições surge principalmente da importância e necessidade da aquisição e da atualização de dados para Sistemas de Informação Geográfica (SIG). Para se detectar e extrair

informações dos objetos, várias técnicas de análise de imagem são utilizadas para separar os objetos de interesse, dentre elas a segmentação por regiões. A segmentação por regiões, dependendo do fim a que se destina, pode ser tida como um pré-processamento para passos subsequentes de análise de imagem. De qualquer forma, para que sejam obtidos os resultados desejados é necessário que a estratégia de detecção de objetos seja eficiente e confiável.

Com o objetivo de segmentar uma imagem ou um conjunto de dados para obter informações de alto nível sobre as regiões ou objetos contidos na imagem, de modo a facilitar a interpretação desses objetos, vários trabalhos vêm sendo desenvolvidos no intuito de superar essa etapa crítica presente em alguns processos de análise de imagem. Alguns trabalhos têm explorado a segmentação usando textura (Tuceryan e Jain, 1998) e outros usando cor (Cheng et al. 2001). No entanto, a combinação entre essas duas propriedades é capaz de fornecer informações mais acuradas para auxiliar na descrição de regiões (Palm 2004).

Em se tratando do uso da tecnologia de perfilamento a laser, pode-se destacar o trabalho de Lohmann (2002) e Voegtle e Steinle (2003) que realizam a segmentação na nuvem de pontos e não sobre uma malha regularizada. Tóvári e Pfeifer (2005) descrevem uma técnica que combina duas abordagens. A primeira trabalha diretamente na nuvem de pontos usando critérios geométricos para decidir se um ponto está sobre o terreno ou sobre um objeto. Na segunda abordagem, primeiramente os dados são segmentados e, após, as regiões resultantes são classificadas. Schenk e Csatho (2002) propõem uma combinação de dados laser e imagens aéreas para a reconstrução de edifícios. As superfícies planas representando telhados são obtidas a partir da segmentação por crescimento de regiões dos dados laser. As linhas de junção dos telhados são obtidas através da intersecção destes planos. Estas mesmas intersecções são extraídas na imagem aérea usando o detector de Canny. As informações de intersecção de telhados obtidas por ambas as metodologias são combinadas para eliminar falsos positivos. MCIntosh e Krupnik (2002) propõem detectar (com um operador *zero-crossing*) e correlacionar bordas em imagens aéreas para refinar o modelo digital de elevação (MDE) produzido através dos dados laser. Bretar e Roux (2005) apresentam uma metodologia de segmentação combinando dados laser e imagens aéreas. Inicialmente, os dados laser são processados para extrair primitivas dos edifícios e, em seguida essas primitivas são introduzidas no processo de segmentação baseado em fusão de regiões.

Nos últimos anos o uso da abordagem Bayesiana tem atraído muita atenção dos pesquisadores da área de processamento de imagens. Aplicações envolvendo Campos Aleatórios de Markov (*Markov Random Field - MRF*) para o processamento de imagem de baixo nível, tais como segmentação e restauração de imagem (Geman e Geman, 1984; Szirányi et al., 2000; Li, 2003) têm sido amplamente discutidas. No entanto, recentemente essa abordagem vem sendo utilizada em tarefas de análise de imagem de alto nível (Kim e Yang, 1995;

Modestino e Zhang, 1992; Kopparapu e Desai, 2001; Andersen et al., 2002) como, por exemplo, a interpretação de imagens. Recentemente, a *Commission III da ISPRS (International Society for Photogrammetry and Remote Sensing)* elegeu os modelos MRF como um dos seus termos de referência, cujo principal objetivo é investigar aplicações em análise de imagem para Fotogrametria.

Dentre as principais vantagens de se utilizar a segmentação baseada em MRF estão a integração ao processo das relações espaciais entre regiões vizinhas presentes na imagem (Dubes e Jain 1989). A tarefa de segmentação de objetos em ambientes urbanos, diante da complexidade da cena, requer o desenvolvimento de métodos específicos que integre a informação de vizinhança e o conhecimento a priori de características dos objetos de interesse. Diante dessa problemática, este trabalho propõe uma metodologia para segmentação de dados laser em duas etapas. Na primeira etapa, a conhecida técnica de divisão recursiva baseada na estrutura *quadtree* é utilizada para realizar uma segmentação inicial do MDE. Na seqüência uma técnica de fusão de regiões usando um modelo MRF é utilizada para melhorar a qualidade da segmentação inicial.

Este artigo está organizado em 4 seções principais. A seção 2 apresenta a metodologia proposta, ou seja, a divisão recursiva com fusão de regiões utilizando a abordagem Bayesiana. Os resultados e análise são descritos na seção 3 e a seção 4 traz as principais conclusões sobre o trabalho.

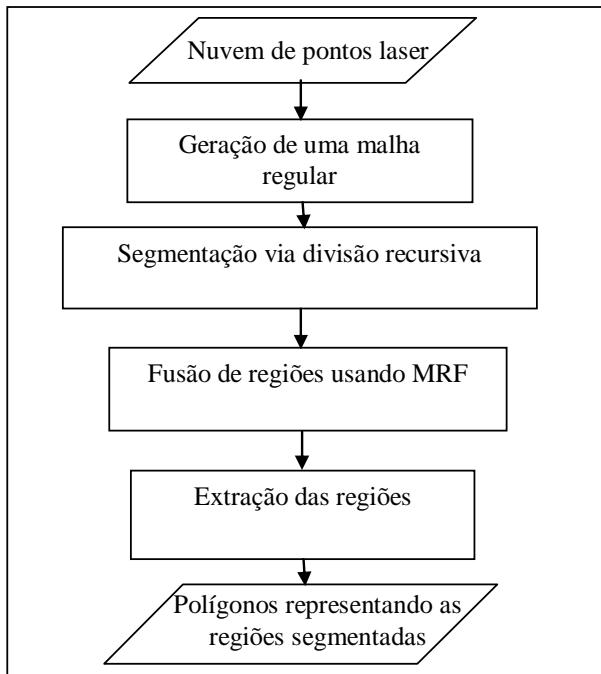
2. SEGMENTAÇÃO DE MODELO DIGITAL DE ELEVAÇÃO USANDO DIVISÃO RECURSIVA E FUSÃO BAYESIANA

A metodologia proposta para a segmentação de dados laser é baseada em um conjunto de dados regulares, isto é, um MDE. A utilização conjunta das técnicas de divisão recursiva e fusão Bayesiana de regiões é realizada para a obtenção de um MDE segmentado com um menor nível de fragmentação possível. Em outras palavras, procura-se obter regiões com alto grau de compatibilidade com os objetos físicos presentes na cena. O reconhecimento de cada objeto não é alvo desta proposta metodológica.

2.1 Princípio Do Método

O fluxograma apresentado na figura 1 mostra as etapas que envolvem a metodologia proposta.

Figura 1 – Fluxograma da metodologia proposta.



Inicialmente os dados de perfilamento a laser são interpolados para gerar uma malha regular (MDE). A partir dessa etapa, é realizada a divisão recursiva usando a estrutura *quadtree*. A divisão recursiva consiste em partitionar o MDE em quatro sub-regiões de tamanhos idênticos. Cada sub-região é analisada em relação a sua homogeneidade usando um limiar pré-estabelecido com base em conhecimentos a priori sobre a altura dos objetos presentes na cena. Este procedimento é realizado recursivamente até que nenhuma região possa ser subdividida. No final, a técnica de divisão recursiva gera um MDE organizado de acordo com a estrutura *quadtree*, onde todas as regiões homogêneas são explicitamente representadas.

Após a etapa de divisão recursiva é aplicada a técnica de fusão Bayesiana de regiões para reduzir a fragmentação da segmentação inicial. Após esta etapa, as regiões podem ser extraídas. Para a extração das regiões foi utilizada uma técnica de perseguição de contorno seguida por outra técnica de poligonização.

As técnicas necessárias para a extração de contornos poligonizados de regiões são bem documentadas na literatura, podendo-se citar Jain et al. (1995) como uma das referências relevantes. Alguns detalhes adicionais, sobre os processos de divisão recursiva e fusão de regiões são apresentados nas subseções seguintes.

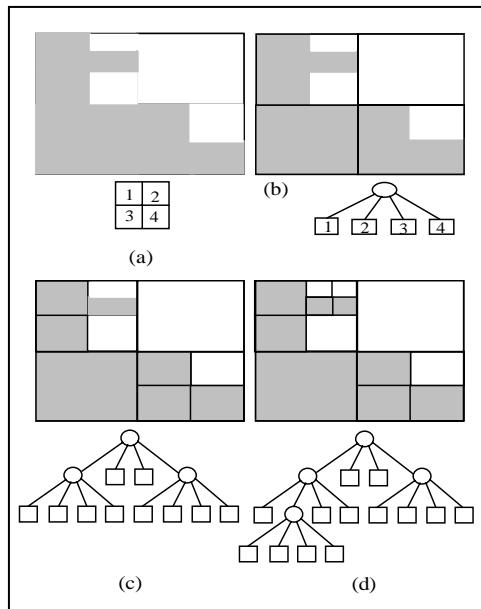
2.2 Divisão Recursiva Usando A Estrutura *Quad Tree*

Os dados laser consistem inicialmente de uma perfilagem irregular onde não se tem o exato espaçamento de pontos no perfil ou entre perfis. Neste caso fez-se necessário a interpolação dos dados para gerar uma malha regular (Morgan e Tempfli, 2000). Na literatura relacionada existe uma variedade de métodos de interpolação que podem ser utilizados para a densificação do MDE. Entre eles se destacam as *splines*, elementos finitos, mínimos quadrados, krigagem e vizinho mais próximo etc. Yang et al. (2004) realizaram um estudo com doze métodos de interpolação utilizando o software Surfer 8.0. Nesse trabalho os métodos de interpolação foram comparados e a acurácia dos resultados foi analisada. O vizinho mais próximo foi um dos métodos analisados e os resultados obtidos ficaram dentro dos padrões aceitáveis. Para cada método, os autores analisaram a aplicabilidade, o algoritmo, a eficiência e as vantagens dos métodos. Eles concluíram que não existe o melhor método, mas a melhor escolha diante de determinadas circunstâncias. Logo, para a escolha correta do método de interpolação é necessário conhecer as características de cada método bem como os dados que serão utilizados. Neste sentido, o método utilizado foi o de interpolação pelo vizinho mais próximo, visto que possibilita a preservação dos valores originais presentes no MDE, além de ser computacionalmente atrativo.

Uma região em um MDE é um agrupamento de pontos conexos com propriedades similares. Ao subdividir o MDE em regiões, várias decisões devem ser tomadas. No entanto, o problema está em decidir qual propriedade utilizar na subdivisão. Essa questão geralmente requer um conhecimento sobre as características dos objetos presentes na cena. Nessa aplicação, a variância dos valores de altura é usada como medida de dispersão desses valores em uma determinada região. Uma técnica utilizada para subdividir regiões é a divisão recursiva de regiões, utilizando a estrutura *quadtree*.

Na divisão recursiva usando a estrutura *quadtree* uma dada região é subdividida em outras quatro sub-regiões de tamanhos idênticos se a variação dos valores de altura desta região em análise for maior que o limiar especificado. Cada sub-região é analisada em relação a sua homogeneidade usando um limiar pré-estabelecido com base em conhecimentos a priori dos objetos presentes na cena. O processo de divisão segue recursivamente até que nenhuma região possa ser subdividida. O resultado é um MDE organizado de acordo com a estrutura *quadtree*, onde todas as regiões homogêneas são explicitamente representadas. A figura 2 apresenta um exemplo ilustrativo desta técnica, sendo que mais detalhes podem ser encontrados em Jain et al. (1995).

Figura 2 – Divisão recursiva usando a estrutura *quadtree*. (a) Imagem original. (b) Imagem dividida em quatro sub-regiões e o *quadtree* correspondente. (c) Subdivisão das regiões 1 e 4 em quatro sub-regiões respectivamente e o *quadtree* correspondente. (d) Subdivisão da sub-região 2 em quatro sub-regiões e o *quadtree* correspondente.



Fonte: Adaptado de Jain et al., 1995.

Na aplicação em questão, considera-se R o MDE, R_i cada quadrante do MDE e P uma propriedade (por exemplo, a variância das alturas dos pontos). Esta divisão é baseada em um teste de hipóteses do tipo $H_0 : P(R_i) \leq \sigma_0^2 = \lambda$ (onde λ é um valor pré-estabelecido de acordo com os valores de altura dos objetos presentes na cena) contra a hipótese $H_1 : P(R_i) > \sigma_0^2$. Se $H_1 : P(R_i) > \sigma_0^2$, rejeita-se H_0 em favor de H_1 . A segmentação de R é realizada a partir de sucessivas subdivisões. Assim, se a hipótese H_1 for verificada, então o MDE é subdividido em quadrantes cada vez menores. Essa técnica gera uma estrutura de dados denominada *quadtree*, isto é, uma árvore em que cada nó possui exatamente quatro descendentes.

Essa abordagem pode ser sumariada nas seguintes etapas:

- 1) Divide-se o MDE em quatro quadrantes distintos;
- 2) Para cada quadrante calcula-se a variância dos valores de altura;
- 3) Se $P(R_i) > \sigma_0^2$, subdivide-se o referido quadrante em quatro outros quadrantes.

A segunda e a terceira etapa devem ser aplicadas recursivamente a todos os quadrantes do MDE, enquanto a hipótese H_1 for verificada. O processo é finalizado quando a hipótese H_0 for verificada para todas as regiões. Isso significa que a estratégia descrita deve ser aplicada recursivamente até que não haja mais quadrantes para serem subdivididos. Assim, o algoritmo é finalizado e uma estrutura é gerada. Essa estrutura corresponde a um MDE segmentado, onde cada R_i é rotulado com o nível médio de altura da região correspondente.

2.3 Fusão De Regiões Usando Uma Abordagem Bayesiana

Seja X um MDE segmentado ($m \times n$) definido na grade regular $D = \{(i, j) : 1 \leq i \leq m \text{ e } 1 \leq j \leq n\}$, onde cada região $X_{i,j}$ toma valores em um conjunto finito de alturas médias. Assume-se que cada $X_{i,j}$ é uma realização de uma variável aleatória normal, cuja média é modelada em função de um fator comum a todos os pontos em estudo (μ) e de um efeito aleatório não observável ($\varepsilon_{i,j}$), representando características específicas.

$$X_{i,j} \sim Normal(\mu_{i,j}, \sigma^2) \quad (1)$$

$$\mu_{i,j} = \mu + \varepsilon_{i,j}, \quad (2)$$

Seja $\eta = \{\eta_{i,j}, (i, j) \in D\}$ um sistema de vizinhança, onde $\eta_{i,j} \subseteq D$ denota os vizinhos de (i, j) . Segundo Geman e Geman (1984) X é um MRF definido em (D, η) , se e somente se,

$$\begin{aligned} P[X_{i,j} = x_{i,j} | X_{k,l} = x_{k,l}, \forall (k,l) \neq (i,j)] \\ = P[X_{i,j} = x_{i,j} | X_{k,l} = x_{k,l}, \text{ para } (k,l) \in \eta_{i,j}] \end{aligned} \quad (3)$$

Pelo teorema de *Hammersley-Clifford*, X é um MRF com relação a vizinhança η se e somente se X tem distribuição de *Gibbs* (Kopparapu and Desai, 2001).

A inclusão da dependência espacial entre as observações é feita assumindo-se para o efeito aleatório $\varepsilon_{i,j}$ uma distribuição a priori Auto-Regressiva Condicional. Segundo Schmidt, Nobre e Ferreira (2003) esta distribuição é especificada por

$$(\varepsilon_i | \varepsilon_j, j \neq i) \sim N(m_i, v_i), \quad (4)$$

$$m_i = \frac{\sum_{j \in \delta_i} W_{ij} \varepsilon_j}{\sum_{j \in \delta_i} W_{ij}} \quad \text{e} \quad v_i = \frac{v^*}{\sum_{j \in \delta_i} W_{ij}}, \quad (5)$$

onde δ_i representa o conjunto de áreas adjacentes a i e v^* a variância. Essa especificação resulta na seguinte distribuição a priori conjunta para o vetor de erros aleatórios ε ,

$$(\varepsilon | v^*) \propto \frac{1}{v^{*n}} \exp \left\{ -\frac{1}{2v^{*n}} \sum_{i=1}^n \sum_{j \in \delta_i} W_{ij} (\varepsilon_i - \varepsilon_j)^2 \right\}. \quad (6)$$

A especificação se completa ao determinar a matriz de vizinhança W_{ij} e a distribuição a priori para a variância v^* . Neste caso, assume-se que $W_{ij} = 1$ se i é adjacente a j e $W_{ij} = 0$ caso contrário, resultando em

$$m_i = \frac{\sum_{j \in \delta_i} W_{ij} \varepsilon_j}{n_i} \quad \text{e} \quad v_i = \frac{v^*}{n_i}, \quad (7)$$

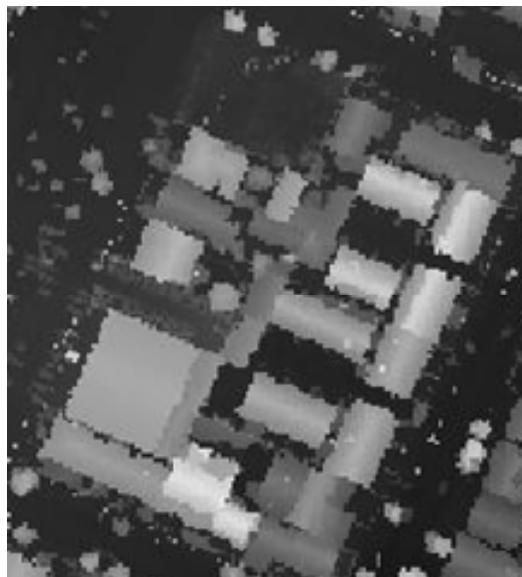
com n_i representando o número de vizinhos da i -ésima região e para v^* assume-se uma distribuição a priori gama invertida (Schmidt, Nobre e Ferreira, 2003). A análise Bayesiana se completa a partir da obtenção da estimativa *Maximum a Posteriori* (MAP) ou máximo a posteriori, o que pode ser obtida, por exemplo, através do *Simulated Annealing* ou Amostrador de Gibbs (Geman and Geman, 1984).

3. RESULTADOS E ANÁLISE

Nesta seção são apresentados os resultados obtidos pela aplicação da metodologia proposta a um MDE obtido de dados laser (figura 3). O limiar utilizado

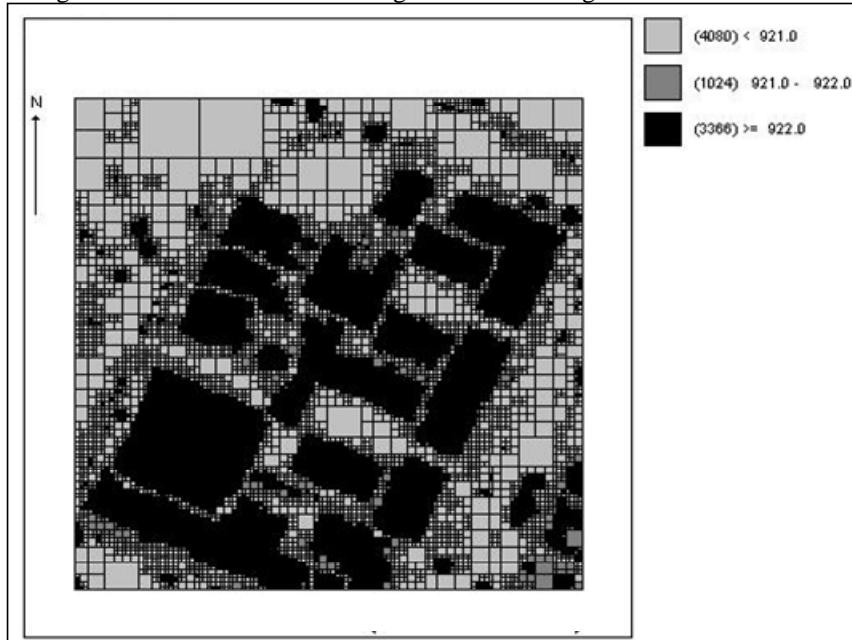
no processo de divisão recursiva foi adotado com base em conhecimentos a priori sobre a variabilidade de altura dos objetos presentes na cena. Na etapa de fusão de regiões, para a obtenção das distribuições a posteriori, utilizou-se o amostrador de Gibbs implementado no software WinBUGS (*Bayesian Analysis Using Gibbs Sampler*).

Figura 3 – Visualização do MDE obtido por perfilamento a laser.



A metodologia de fusão de regiões é aplicada nos resultados gerados pela técnica de divisão recursiva. A figura 4 apresenta os resultados obtidos com o algoritmo amostrador de Gibbs. Nessa figura é possível visualizar a discriminação dos objetos existentes na quadra urbana (figura 3), como por exemplo, telhados, árvores etc. As regiões com tonalidade preta representam os objetos mais altos na cena e as de tonalidade mais claras estão associadas às regiões baixas.

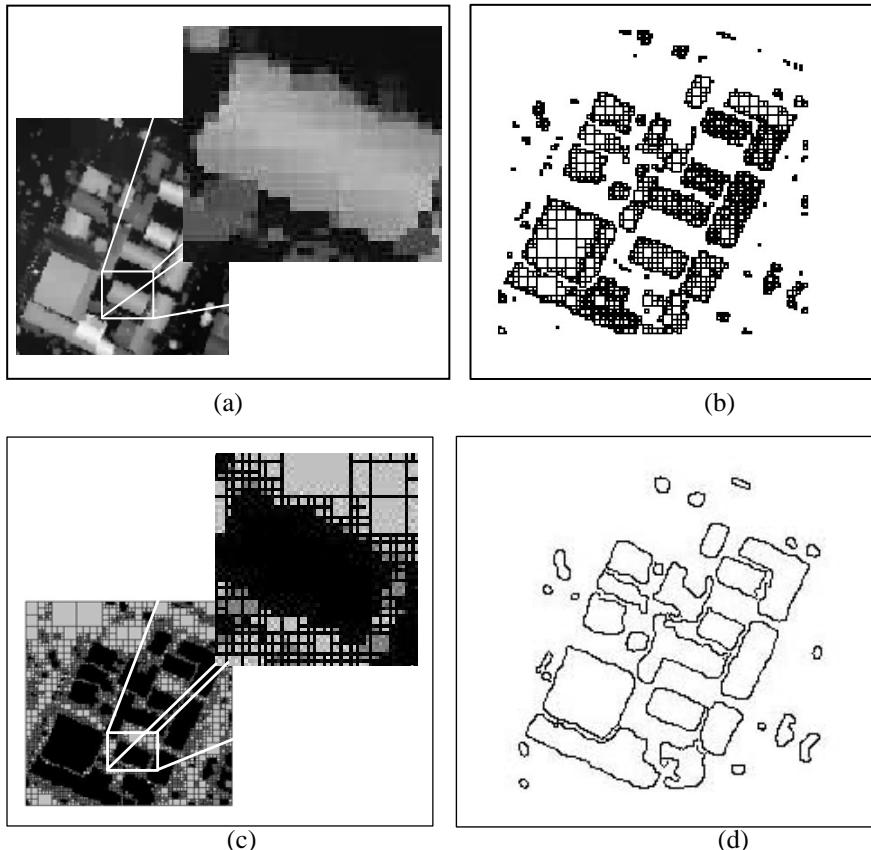
Figura 4 - Resultado da metodologia de fusão de regiões via modelo MRF.



A figura 5 mostra detalhes obtidos tanto com o processo de divisão recursiva quanto com o processo de fusão de regiões. A figura 5(a) mostra o resultado obtido pela divisão recursiva para toda quadra e, em destaque, para um único edifício. Neste caso pode-se observar claramente o efeito da fragmentação resultante do processo de divisão recursiva. Visualmente as diferenças entre as tonalidades das regiões parecem pequenas mas, no entanto, várias são as regiões para um mesmo objeto que, no caso, é um telhado. A figura 5(b) mostra o resultado da plotagem dos contornos dos objetos obtidos (figura 5(a)) via algoritmo de divisão recursiva. Embora as figuras 5(a) e 5(b) mostrem uma acentuada fragmentação dos objetos, fica também evidente uma clara distinção entre conjuntos de sub-regiões que compõem os respectivos objetos físicos (por exemplo, edifícios, árvores etc.) e as regiões de fundo. O processo de fusão bayesiana visa encontrar similaridades probabilísticas entre sub-regiões pré-detectadas, resultando em regiões com alta compatibilidade com os objetos físicos. A figura 5(c) mostra, principalmente na janela onde está destacado o mesmo objeto selecionado na figura 5(a), uma melhoria significativa no nível de segmentação. Pode-se notar visualmente que agora os quadrantes correspondentes ao objeto possuem característica similar, isto é, mesma altura. A figura 5(d) mostra o resultado final, obtido pela plotagem dos contornos vetorizados dos objetos presentes no MDE segmentado pela metodologia

proposta. É possível verificar que os contornos dos objetos foram geralmente extraídos com boa qualidade. Vale finalmente ressaltar que esse resultado mostra os objetos extraídos a partir do resultado final da segmentação, onde ainda não se tem a atribuição do significado de cada objeto.

Figura 5 – Resultado da extração dos objetos segmentados a partir da metodologia proposta. (a) Resultado da divisão recursiva. (b) Imagem vetorizada após a divisão recursiva. (c) Resultado da fusão de regiões (d) Cadeias de pontos representando os objetos na cena obtidas após a etapa de fusão de regiões.



4. CONCLUSÕES E PERSPECTIVAS FUTURAS

Neste trabalho foram apresentados os fundamentos teóricos e a análise experimental referente ao processo de segmentação de regiões via divisão recursiva e fusão de regiões através de um modelo MRF. Foram descritos os passos

integrantes do processo, bem como foi apresentado um experimento efetuado com os dados de altura fornecidos pelo perfilamento a laser referentes a uma quadra urbana.

A modelagem Bayesiana permitiu incluir no estudo a estrutura de dependência espacial dos dados, através do efeito aleatório incluído no modelo. Considerando que este efeito, representando características específicas dos objetos em questão, permite que se incorpore à análise a relação de vizinhança entre as áreas, tem-se um modelo que representa de forma mais realista o comportamento do fenômeno em estudo.

Os resultados obtidos mostraram que a estratégia proposta permitiu a geração de regiões bastante próximas dos objetos físicos, que incluem desde o objeto altamente desejável (telhados) até objetos geralmente indesejáveis, como árvores e veículos. Dentre os objetos detectados podem estar também os espúrios, resultantes de irregularidades no MDE. Entre os trabalhos futuros, destaca-se o desenvolvimento de estratégias, baseadas também no modelo MRF, para o reconhecimento das regiões relacionadas com edificações.

REFERÊNCIAS BIBLIOGRÁFICAS

- ANDERSEN, H.; REUTEBUCH, S.; SCHREUDER, G. *Bayesian object recognition for the analysis of complex forest scenes*. In: Airbone Laser Scanner Data. ISPRS, Symposium Photogrammetric Computer Vision, Austria, 2002.
- BALLARD, D. H.; BROWN, C. M. *Computer vision*. Englewood Cliffs, Prentice-Hall, 1982.
- BRETAR, F.; ROUX, M. *Hybrid Image Segmentation Using Lidar 3D Planar Primitives*. In: Workshop “Laser scanning 2005” of ISPRS, WG III/3, III/4, v. XXXVI, Part 3/W193, Netherlands, p. 12-14. 2005.
- CHENG, H. D. et al. *Color Image Segmentation: Advances and Prospects*. Pattern Recognition, v. 34, n. 12, p. 2259–2281. 2001.
- DUBES, R. C.; JAIN, A. K. *Random Field Models in Image Analysis*. Journal of Applied Statistics, v. 16, n. 2, p. 131–164. 1989.
- GEMAN, S.; GEMAN, D. *Stochastic relaxation, Gibbs distribution, and Bayesian restoration of images*. In: IEEE Transactions on Pattern Analysis and Machine Intelligence, v.6, 1984. p.721-741.
- JAIN, R.; KASTURI, R.; SCHUNCK, B. G. *Machine Vision*, MIT Press and McGraw-Hill, Inc New York, 549p, 1995.
- KIM, I. Y.; YANG, H. S. *An integrated approach for scene understanding based on Markov Random Field*. Pattern Recognition. p.1887-1897, 1995.
- Bol. Ciênc. Geod., sec. Artigos, Curitiba, v. 13, nº 1, p.76-90, jan-jun, 2007.

- KOPPARAPU, S. K.; DESAI, U. B. *Bayesian approach to image interpretation.* 127p., 2001.
- LI, C.-T. Multiresolution image segmentation integrating Gibbs sampler and region merging algorithm. *Signal Processing*, v. 83, p. 67 – 78, 2003.
- LOHMANN, P. *Segmentation and Filtering of Laser Scanner Digital Surface Models.* In: IAPRS, v. 34, part 2, Xi'an, p.311-315, 2002.
- MCINTOSH, K.; KRUPNIK, A. *Integration of laser-derived DSMs and matched image edges for generating an accurate surface model.* ISPRS Journal of Photogrammetry and Remote Sensing (56), p. 167-176, 2002.
- MODESTINO, J. A; ZHANG, J. *A Markov Random Field model based approach to image interpretation.* IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 6, p.606-615, 1992.
- MORGAN, M.; TEMPFLI, K. *Automatic Building Extraction from Airborne Laser Scanning Data.* In: IAPRS – International Archives of Photogrammetry and Remote Sensing, v. XXXIII, Part B3, Amsterdam, 2000.
- PALM, C. *Color Texture Classification by Integrative Co-Occurrence Matrices.* *Pattern Recognition*, v. 37, n. 5, p. 965–976, 2004.
- SCHENK, T.; CSATHO, B. *Fusion of lidar data and aerial imagery for a more complete surface description.* In: International Archives of Photogrammetry and Remote Sensing, v. XXXIV-3A/W3, Graz, p. 310-317, 2002.
- SCHMIDT, A. M.; NOBRE, A. A.; FERREIRA, G. S. *Alguns Aspectos de Modelagem de Dados Espacialmente Referenciados.* Rio de Janeiro, 2003.
- SPIEGELHATER, D. J. et al. *WinBUGS (Bayesian Inference Using Gibbs Sampling).* Version 1.4, MRC Biostatistics Unit, Cambridge, UK, 2002.
- SZIRÁNYI, S. et al. *Image segmentation using Markov Random Field model in fully parallel cellular network architectures.* *Real-Time Imaging.* v.6, p.195-211, 2000
- TÓVÁRI, D.; PHEIFER, N. *Segmentation Based Robust Interpolation – A new Approach to Laser Data Filtering.* In: Workshop “Laser scanning 2005 of ISPRS WG III/3, III/4, v. XXXVI, Part 3/W19, Netherlands, p. 12-14. 2005.
- TUCERYAN, M.; JAIN, A. K. *Texture Analysis,* in C. H. Chen, L. F. Pau e P. Wang (eds), *The Handbook of Pattern Recognition and Computer Vision,* World Scientific Publishing Co., pp. 207–248. 1998.
- VOEGTLE, T.; STEINLE, E. *On the quality of object classification and automated building modelling based on laserscanning data.* In: IAPRS, v. XXXIV 3/W13, Dresden, Germany, p. 149-155. 2003.

YANG, C.; KAO, S.; LEE, F.; HUNG, P. *Twelve different interpolation methods: a case study of surfer 8.0.* In: XX ISPRS Congress, Istanbul, Turkey, 2004.

AGRADECIMENTOS

Os autores agradecem a CAPES, pelo suporte, sob a forma de bolsa de Demanda Social, concedida à doutoranda Edinéia Aparecida dos Santos Galvanin. Este trabalho é resultado de um projeto financiado pela FAPESP, na categoria de Auxílio à Pesquisa, coordenado pelo segundo autor. Este artigo conta também com apoio do CNPQ, através de bolsa de produtividade em Pesquisa (PQ) do segundo autor. Os autores agradecem o instituto LACTEC pelo fornecimento dos dados de perfilamento a laser.

(Recebido em setembro/2006. Aceito em março/2007)