

# EXTRAÇÃO AUTOMÁTICA DE CONTORNOS DE TELHADOS USANDO DADOS DE VARREDURA A LASER E CAMPOS RANDÔMICOS DE MARKOV

*Automatic extraction of building roof contours by laser scanning data and markov  
random field*

EDINÉIA APARECIDA DOS SANTOS GALVANIN<sup>1</sup>  
ALUIR PORFÍRIO DAL POZ<sup>2</sup>  
APARECIDA DONISETI PIRES DE SOUZA<sup>2</sup>

<sup>1</sup>Universidade do Estado de Mato Grosso – UNEMAT  
Departamento de Matemática  
Rua A, s/n  
78390-000 Barra do Bugres, MT

<sup>2</sup>Universidade Estadual Paulista – UNESP  
Faculdade de Ciências e Tecnologia  
<sup>1</sup>Programa de Pós-Graduação em Ciências Cartográficas  
Rua Roberto Simonsen, 305  
19060 – 900 Presidente Prudente, SP  
galvanin@gmail.com; {aluir, adps}@fct.unesp.br

## RESUMO

Este artigo propõe uma metodologia para a extração automática de contornos de telhados de edifícios a partir de um MDE (Modelo Digital de Elevação), gerado a partir da regularização de uma malha irregular de dados laser preexistentes. A metodologia baseia-se em duas etapas. Primeiramente, a fim de detectar objetos altos (edifícios altos, árvores etc.), o MDE é segmentado através de uma técnica de divisão recursiva e de uma técnica de fusão bayesiana. A técnica de divisão recursiva usa a estrutura *quadtree* para subdividir o MDE em regiões homogêneas. A fim de minimizar a fragmentação que frequentemente é observada nos resultados da segmentação por divisão recursiva, uma técnica de fusão baseada em Inferência Bayesiana é aplicada aos dados previamente segmentados. Os contornos dos objetos

altos são obtidos através de técnicas de vetorização e poligonização. Na segunda etapa, os contornos de telhados de edifícios são identificados entre todos os objetos altos extraídos previamente. Levando em conta algumas propriedades de telhado e alguns atributos (por exemplo, área, retangularidade e ângulos entre os eixos principais dos telhados), uma função de energia foi desenvolvida com base no modelo *Markov Random Field* (MRF). A solução desta função é um conjunto de polígonos representando contornos de telhados de edifícios e é encontrada através de técnicas de minimização, como o algoritmo *Simulated Annealing* (SA). Vários experimentos foram realizados com base em DEM's obtidos a partir de dados de varredura a laser, os quais demonstraram que a metodologia proposta funciona adequadamente, visto que foram extraídos contornos de telhados com aproximadamente 90% de completude de área e nenhum falso positivo foi verificado.

**Palavras Chave:** Extração Automática; Contornos de Telhados de Edifícios; Modelo Digital de Elevação; Dados de Varredura a Laser; Campos Randômicos de Markov.

### ABSTRACT

This paper proposes a methodology for automatic extraction of building roof contours from a Digital Elevation Model (DEM), which is generated through the regularization of an available laser point cloud. The methodology is based on two steps. First, in order to detect high objects (buildings, trees etc.), the DEM is segmented through a recursive splitting technique and a Bayesian merging technique. The recursive splitting technique uses the quadtree structure for subdividing the DEM into homogeneous regions. In order to minimize the fragmentation, which is commonly observed in the results of the recursive splitting segmentation, a region merging technique based on the Bayesian framework is applied to the previously segmented data. The high object polygons are extracted by using vectorization and polygonization techniques. Second, the building roof contours are identified among all high objects extracted previously. Taking into account some roof properties and some feature measurements (e. g., area, rectangularity, and angles between principal axes of the roofs), an energy function was developed based on the Markov Random Field (MRF) model. The solution of this function is a polygon set corresponding to building roof contours and is found by using a minimization technique, like the Simulated Annealing (SA) algorithm. Experiments carried out with laser scanning DEM's showed that the methodology works properly, as it delivered roof contours with approximately 90% shape accuracy and no false positive was verified.

**Key Words:** Automatic Extraction; Building Roof Contours; Digital Elevation Model; Laser Scanning Data; Markov Random Field.

## 1. INTRODUÇÃO

O problema de extração de objetos cartográficos tem recebido, nos últimos anos, considerável atenção. O problema específico de extração automática de contornos de telhados é reconhecidamente difícil, fato decorrente da heterogeneidade dos objetos presentes em cenas urbanas. A interação de edifícios com os outros objetos (árvores, carros, caixas d'água etc.) leva ao que se denomina de contexto, que é difícil de modelar e é fundamental para a compreensão da cena. O assunto de extração de edifícios já possui um histórico de quase 30 anos de pesquisa (Vosselman, 2002). Até meados da década de 1990 as imagens aéreas eram as fontes usuais de dados utilizadas para a extração. No final dessa mesma década outras fontes de dados (por exemplo, as imagens de satélites de alta-resolução e os dados de varredura a laser) passaram a ser utilizadas.

O uso de dados laser em problemas de extração de objetos cartográficos se tornou comum nos últimos anos, fato decorrente principalmente do amadurecimento do sistema que integra o sensor laser com o *Global Positioning System* (GPS) e a *Inertial Measurement Unit* (IMU). As metodologias que utilizam os dados de varredura a laser vêm sendo empregadas nas mais variadas áreas, mas no mapeamento em especial, são bastante atrativas as aplicações que envolvem a reconstrução de superfície e a extração de objetos. Isso implica na solução de problemas específicos envolvendo, por exemplo, segmentação e filtragem de objetos (edifícios, vegetação etc.) (Haala e Brenner, 1999), geração de Modelo Digital do Terreno (MDT) e Modelo Digital de Superfície (MDS) (Matikainen, Hyypä e Hyypä, 2005).

O problema de extração de edifícios usando dados laser, isolados ou conjuntamente com dados de imagem, vem sendo bastante investigado nos últimos 10 anos. Alguns dos trabalhos mais recentes são brevemente descritos a seguir a título de exemplificação. O trabalho de Sohn e Dowman (2003) descreve um método automático para extração de edifícios a partir da combinação entre dados multiespectrais do satélite Ikonos e dados regulares de varredura a laser. Nesta abordagem, os edifícios individuais são localizados como polígonos retangulares através de uma segmentação aplicada aos dados laser e à imagem Ikonos. Ambos os conjuntos de dados são combinados para obter contornos de edifícios com um mínimo de ambigüidade. Matikainen, Hyypä e Hyypä (2005) utilizam a informação altimétrica do sistema laser para a geração de modelos digitais da superfície e posteriormente integram esta informação com a imagem aérea, auxiliando na eliminação de feições irrelevantes (árvores, sombras etc.) no processo de detecção. Arefi e Hahn (2005) utilizam operações morfológicas para extrair contornos de edifícios e vegetação. Para esse propósito é realizada uma segmentação hierárquica utilizando operações morfológicas. Tarsha-Kurdi et al. (2006) desenvolveram um método automático de segmentação a partir da nuvem de pontos (malha irregular de pontos) obtida por varredura a laser usando somente a informação do primeiro pulso laser. O resultado da metodologia é a discriminação

automática de contornos de edifícios e terrenos, excluindo áreas de vegetação.

Tóvári e Pfeifer (2005) descrevem uma técnica que combina duas abordagens. A primeira trabalha diretamente na nuvem de pontos usando critérios geométricos (baseado em alturas, inclinações e diferença de curvatura) para decidir se um ponto está sobre o terreno ou sobre um objeto. Na segunda abordagem, inicialmente os dados são segmentados utilizando o algoritmo de crescimento de regiões e em seguida é realizada uma filtragem dos dados baseada em critérios de similaridade e distância entre pontos. 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. Essas primitivas são então introduzidas no processo de segmentação baseado em fusão de regiões.

As metodologias para extração de telhados de edifícios empregam, a exemplo de algumas metodologias brevemente apresentadas acima, várias estratégias para alcançar o objetivo desejado. A teoria dos campos randômicos de Markov (MRF – *Markov Random Field*) vem ganhando espaço no problema de extração de objetos cartográficos. A principal vantagem de se utilizar a segmentação baseada em MRF é a possibilidade de integração ao processo de extração das relações espaciais entre regiões vizinhas presentes na cena analisada (Dubes e Jain, 1989).

A tarefa de segmentação de objetos em ambientes urbanos, diante da complexidade da cena, requer o desenvolvimento de métodos específicos para a integração de informação de vizinhança e o conhecimento a priori de características dos objetos de interesse. Diante dessa problemática, é proposta neste trabalho uma metodologia para extração de contornos de telhados de edifícios, onde a principal meta é o aproveitamento do potencial do modelo MRF para a modelagem de relações espaciais. Esta metodologia possui duas etapas básicas. Na primeira etapa os objetos altos são extraídos no referencial do MDE. Na segunda etapa os contornos de telhados são separados entre os contornos extraídos na primeira etapa. As duas etapas são desenvolvidas utilizando métodos que envolvem a Inferência Bayesiana e modelos MRF.

Este artigo está organizado em 5 seções principais. A Seção 2 apresenta a fundamentação teórica básica relacionada com os modelos Auto-Regressivos Condicionais e com os modelos MRF aplicados ao problema de análise de imagens por regiões. A metodologia proposta é descrita na Seção 3. Na Seção 4 são apresentados e analisados os resultados experimentais obtidos. A Seção 5 traz as principais conclusões.

## 2. FUNDAMENTAÇÃO TEÓRICA

### 2.1 Modelo CAR

No contexto Bayesiano geralmente o modelo CAR (*Conditional Autoregressive*) é usado como informação a priori de um parâmetro do modelo para o processo de interesse. O modelo genérico descrito a seguir, com enfoque

direcionado às áreas em estudo, é usado para exemplificar a modelagem Bayesiana de um processo condicionalmente auto-regressivo. Um maior detalhamento sobre o modelo CAR pode ser encontrado em Besag, York e Mollié (1991), Schmidt, Nobre e Ferreira (2003), Galvanin (2007).

Seja uma área de interesse dividida em  $n$  sub-regiões, regulares ou não. A medida de interesse observada em cada sub-região  $i$  ( $i = 1, \dots, n$ ) é representada por  $Z_i$ . Um possível modelo para  $Z_i$  é apresentado a seguir.

$$Z_i = \mu + \sum_{k=1}^q \beta_k X_{k i} + S_i, \quad (1)$$

onde:  $\mu$  representa um fator comum a toda região em estudo;  $X_i = (X_{1i}, \dots, X_{qi})$  representa um vetor de possíveis covariáveis para a  $i$ -ésima área, que podem explicar o processo;  $\beta_k$  representa o efeito da  $k$ -ésima covariável na resposta  $Z$ ;  $S = (S_1, \dots, S_n)$  são os efeitos aleatórios que podem ser vistos como variáveis latentes que capturam efeitos desconhecidos ou não medidos pelas covariáveis.

Sob o enfoque Bayesiano, a Equação 1 representa o primeiro nível da hierarquia do modelo. No segundo nível deve-se especificar a distribuição a priori do vetor paramétrico  $\theta = (\mu, \beta_1, \dots, \beta_q, S)$ . Geralmente assume-se a priori que esses parâmetros são independentes e que  $\mu, \beta_1, \dots, \beta_q$  seguem uma distribuição normal centrada em 0 (zero) com baixa precisão. Dessa forma, deixa-se que os dados dêem maiores informações sobre tais parâmetros.

Assume-se para o efeito aleatório  $S_i$  uma priori auto-regressiva condicional intrínseca (Besag, York e Mollié, 1991). A estrutura dessa priori é dada por:

$$(S_i | S_j = s_j, j \neq i) \sim N(m_i, \nu_i), \quad (2)$$

sendo,

$$m_i = \frac{\sum_{j \in \delta_i} w_{ij} S_j}{\sum_{j \in \delta_i} w_{ij}} \quad \text{e} \quad \nu_i = \frac{\nu^*}{\sum_{j \in \delta_i} w_{ij}},$$

onde:  $\delta_i$  representa o conjunto de áreas adjacentes a  $i$ ; e  $\nu^*$  um termo comum de variância. Essa especificação resulta na seguinte distribuição a priori conjunta para o vetor de erros aleatórios  $S$ ,

$$(S/v^*) \propto \frac{1}{v^{*n/2}} \exp \left\{ -\frac{1}{2v^*} \sum_{i=1}^n \sum_{j<i} w_{ij} (S_i - S_j)^2 \right\}. \quad (3)$$

que é uma distribuição imprópria já que é baseada nas diferenças pareadas entre os  $S_i$ 's, ou seja essa priori é invariante à locação. Como prioris impróprias podem resultar em posteriores impróprias, na prática impõe-se uma restrição para que esses efeitos somem 0 (zero). A especificação se completa ao se determinar a matriz de vizinhança  $W = [w_{ij}]$  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

$$m_i = \frac{\sum_{j \in \delta_i} S_j}{|N_i|} \quad \text{e} \quad v_i = \frac{v^*}{|N_i|}, \quad (4)$$

com  $|N_i|$  representando o número de vizinhos da  $i$ -ésima região e para  $v^*$  assume-se uma distribuição a priori gama invertida. A média condicional de  $S_i$ ,  $m_i$ , é dada pela média aritmética dos efeitos aleatórios dos seus vizinhos, e a variância condicional  $v_i$  é proporcional ao número de vizinhos, donde vem a denominação CAR intrínseco. Essa especificação é especialmente relevante quando a região é dividida em sub-regiões irregulares. Outras estruturas de vizinhanças podem ser adotadas, por exemplo, alguma baseada na distância entre os centróides das sub-regiões (Schmidt, Nobre e Ferreira, 2003).

## 2.2 MRF para análise de imagens por regiões

A formulação de um MRF para problemas de análise de imagem pode ser realizada segundo alguns preceitos, ou seja, parte-se de uma imagem segmentada e constrói-se um grafo de regiões adjacentes (*Region Adjacency Graph* (RAG)). Cada nó do RAG corresponde a uma região da imagem e dois nós tem conectividade entre eles se as duas regiões correspondentes compartilham de uma mesma fronteira. Em seguida, assume-se que a interpretação do nó, dado o conhecimento específico dos objetos de interesse, e os atributos obtidos da imagem observada, dá-se de acordo com um MRF. Assim, o problema de análise de imagem é resolvido como um problema de estimativa MAP (*Maximum a Posteriori*). Uma das grandes vantagens desta abordagem é a possibilidade de modelar o conhecimento contextual, isto é, as relações entre o objeto de interesse e os demais presentes na cena.

Uma clique  $c$ , neste contexto, é um subconjunto de nós do RAG (ou simplesmente  $G$ ) tal que cada par de diferentes nós em  $c$  são vizinhos. A coleção de

todas as cliques de  $G$  com relação ao sistema de vizinhança  $\eta$  é representado como  $C(G, \eta)$ . De acordo com Koppurapu e Desai (2001), assumindo que  $X$  tem um número finito de configurações em relação ao espaço amostral  $S$ , e que  $P[X = x] > 0$ , então  $X$  é um MRF, com respeito ao sistema de vizinhança  $\eta$ , se e somente se  $X$  tem distribuição de Gibbs, isto é,

$$P[X = x] = \frac{1}{Z} e^{-U(x)} \quad (5)$$

onde,  $x$  é uma realização de  $X$  e  $Z$  é a constante de normalização dada por,

$$Z = \sum_{\text{toda conf. } x} e^{-U(x)}, \quad (6)$$

e  $U(x)$  conhecida como a função de energia de Gibbs, dada por,

$$U(x) = \sum_{c \in C(G, \eta)} V_c(x^c), \quad (7)$$

na qual,  $V_c(x^c)$  é a função potencial da clique, sendo  $x^c$  o valor das variáveis associadas com os nós pertencentes à clique  $c \in C(G, \eta)$ .

Segundo Modestino e Zhang (1992), devido à estrutura na qual as propriedades locais e globais são relacionadas através de cliques, a abordagem baseada no modelo de MRF para análise de imagem fornece vantagens em relação à representação do conhecimento, aprendizado e otimização. O conhecimento específico a priori é denotado por  $\kappa$ , o qual está relacionado com os objetos constituintes da cena e que se pretende identificar. A caracterização de  $\kappa$  implica em calcular valores para todos os atributos que são considerados importantes para o processo de rotulação. A caracterização e representação do conhecimento a priori para rotulação de objetos presentes na cena não é um problema bem resolvido. O procedimento geral consiste na criação de um conjunto de atributos e sua validação através de estudos empíricos (Modestino e Zhang, 1992). Assume-se agora que a distribuição de probabilidade do vetor aleatório  $X$  definido sobre o RAG, dado o conhecimento a priori  $\kappa$  e o conjunto de atributos  $F$ , é um MRF, isto é,

$$P[X = x | F = f, \kappa] = \frac{1}{Z} \exp^{-U(x|f, \kappa)} \quad (8)$$

$$U(x | f, \kappa) = \sum_{c \in C(G, \eta)} V_c(x^c | f^c, \kappa). \quad (9)$$

O problema de análise de imagem é resolvido como um problema de estimação do MAP, isto é

$$x_* = \arg \max_x P[X = x | F = f, \kappa], \quad (10)$$

ou, de forma equivalente,

$$x_* = \arg \min_x U(x | f, \kappa). \quad (11)$$

### 3. EXTRAÇÃO AUTOMÁTICA DE CONTORNOS DE TELHADOS EM UM MDE UTILIZANDO INFERÊNCIA BAYESIANA E MODELO MRF

A metodologia proposta para a extração de contornos de telhados consiste inicialmente na extração de contornos dos objetos altos existentes na cena para, na etapa seguinte, utilizar esses objetos para a extração apenas dos contornos de telhados de edifícios. A seção 3.1 apresenta a metodologia para a extração automática de feições relacionadas com objetos altos em um MDE, utilizando Inferência Bayesiana e o modelo CAR. A seção 3.2 apresenta a metodologia desenvolvida para separar os contornos de telhados de edifícios, via MRF, dentre todos os objetos altos detectados na primeira etapa.

#### 3.1 Metodologia para a extração automática de regiões altas em um MDE utilizando Inferência Bayesiana e o modelo CAR

A metodologia proposta para a extração automática de regiões altas tem os seguintes passos: interpolação de dados, segmentação dos dados via divisão recursiva, fusão de regiões, preenchimento de contornos, vetorização e poligonização. Esses passos são discutidos brevemente a seguir. Mais detalhes podem ser encontrados em Galvanin (2007) e Galvanin et al. (2007), e também em outras referências a serem citadas na seqüência.

Inicialmente os dados de perfilamento a laser são interpolados para gerar uma malha regular (MDE). Neste trabalho o método de interpolação utilizado foi o vizinho mais próximo. Este método é bastante simples e computacionalmente atrativo. Tem como principal característica assegurar que o valor interpolado seja um dos valores originais, ou seja, não gera novos valores.

A partir dessa etapa é realizada a segmentação por divisão recursiva usando a estrutura *quadtree*. Essa técnica de segmentação particiona inicialmente o MDE em quatro sub-regiões de tamanhos idênticos. Cada sub-região é analisada em relação à sua homogeneidade usando um limiar pré-estabelecido com base em conhecimentos

a priori sobre a altura dos objetos presentes na cena ( $\lambda = 25m$ ). 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. Jain et al. (1995) descreve detalhadamente a técnica de divisão recursiva via estrutura *quadtree*.

As informações fornecidas pelo método de divisão recursiva são utilizadas para a fusão de regiões com certo grau de similaridade. As regiões adjacentes são conectadas usando a propriedade de altura na forma do conhecimento de que os telhados são mais altos que as regiões adjacentes. Logo é possível, na etapa de segmentação, separar os objetos altos (como por exemplo, edifícios, árvores, caixas d'água etc.) dos objetos baixos (quintais, pátios, corredores, canteiros, carros, barracas, ruas, terrenos etc.). No entanto, alguns objetos indesejáveis ainda farão parte do conjunto de objetos altos (por exemplo, árvores, caixas d'água etc.). Neste trabalho optou-se por utilizar o modelo CAR, visto que este permite obter diretamente as distribuições condicionais completas dos parâmetros do modelo, fator determinante para o uso do método de Monte Carlo via Cadeia de Markov (MCMC), neste caso o amostrador de Gibbs. Neste trabalho a idéia é usar modelos que especifiquem que o processo de interesse é influenciado, de alguma forma, pela resposta do mesmo em localizações vizinhas.

Após esta etapa, as regiões podem ser extraídas. Para a extração das regiões foi aplicada a técnica de preenchimento de polígonos seguida pelos métodos de vetorização e 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.

### **3.2 Extração automática de contornos de telhados de edifícios**

A segunda etapa da metodologia consiste na separação dos telhados entre os objetos altos extraídos na primeira etapa da metodologia. As regiões altas são agora estruturadas segundo um RAG, onde cada nó do RAG corresponde a uma região alta. Nesta etapa é utilizada uma abordagem baseada em MRF. Essa modelagem deve propiciar a obtenção apenas dos contornos correspondentes aos telhados.

Nesta etapa são calculados vários atributos com base no MDE. A análise de cada região, dadas as medidas de alguns atributos realizadas nas regiões do MDE, por hipótese obedece a um MRF. Assim, a construção do MRF envolve a definição de funções apropriadas e o problema de análise é resolvido a partir da estimativa MAP. A partir do conhecimento a priori do objeto de interesse é possível realizar a extração automática de contornos de telhados. Nesta etapa a metodologia proposta envolve os seguintes passos: caracterização do conhecimento sobre contornos de edifícios, definição da função de energia e minimização da função de energia.

Para definir a clique, inicialmente assumiu-se que os objetos altos  $(R_i, i = 1, \dots, n)$ , imersos num fundo  $F$ , são modelados como um MRF. A vizinhança  $\eta_{R_i}$ , isto é, das regiões  $R_j$  vizinhas de  $R_i$  ( $i \neq j$ ), é definida na forma,

$$\eta_{R_i, r} = \left\{ R_j \mid \text{dist} (R_j, R_i) \leq r \right\},$$

onde: a função *dist* é dada pela distância euclidiana entre os centros de massa de dois objetos analisados  $(R_i, R_j)$ ; e  $r$  é a distância máxima permitida entre  $R_i$  e  $R_j$ .

A construção da função de energia  $U(I | F, \kappa)$  depende substancialmente do conhecimento a priori sobre as propriedades do objeto telhado. O conhecimento a priori a respeito do objeto de interesse denotado por  $\kappa$  é muito importante na análise de imagem, pois impõe uma forte suposição sobre o que se espera da cena antes de aplicar o algoritmo para realizar a análise. A caracterização de  $\kappa$  implica em estabelecer valores nominais para os atributos que são considerados importantes para decisão em uma análise.

Os atributos para a clique de primeira ordem utilizados neste trabalho foram a área e a retangularidade. Esses atributos podem ser expressos matematicamente segundo as propriedades geométricas do objeto. O atributo de área permite que objetos pequenos, como caixas d'água, cuja área é relativamente menor em relação aos telhados, possam ser descartados. Para que isso seja possível, a equação de energia deve penalizar pequenas áreas.

O atributo de retangularidade ( $R$ ) é definido como o ângulo formado pelos eixos principal e secundário do objeto. A direção do eixo principal corresponde à primeira direção mais freqüente do objeto e a direção do eixo secundário corresponde à segunda direção mais freqüente. Estas direções são obtidas a partir do cálculo das direções dos segmentos de reta que compõem o polígono representativo de um dado objeto. Para obter as freqüências angulares, é necessário dividir o círculo trigonométrico num número apropriado de setores. O número de setores depende da qualidade de definição dos lados dos contornos. Para os contornos de telhados extraídos de dados laser, que são relativamente irregulares, é suficiente adotar uma subdivisão trigonométrica com 24 setores de 15 graus. Cada setor é representado pelo seu valor angular central (por exemplo, o setor de amplitude  $[345^\circ; 360^\circ]$  é representado pelo ângulo  $372,5^\circ$ ). Para calcular a freqüência de um dado setor, é necessário: 1) identificar os segmentos do polígono do objeto cujas direções pertencem ao setor; 2) a freqüência do setor é dada pelo valor inteiro da soma dos comprimentos dos segmentos identificados previamente. Os valores angulares centrais correspondentes aos dois setores mais freqüentes correspondem às direções principais do objeto em análise. Em se tratando de objetos geometricamente bem definidos, como telhados, as direções principais se destacarão das demais.

A retangularidade é expressa matematicamente por,

$$R = |\text{sen } \theta| \quad (12)$$

onde:  $\theta$  é o ângulo entre os eixos principal e secundário.

O atributo R beneficia os objetos com formas geométricas regulares, onde prevalecem os ângulos retos nos vértices do contorno. O valor ótimo para R é 1 (um), sendo este um dos valores a ser incluído no conhecimento  $\mathcal{K}$ . O valor de R é 1 (um) em situações ideais, quando  $\theta = 90^\circ$  ou  $\theta = 270^\circ$ .

O terceiro atributo baseia-se em cliques de segunda ordem. Sendo  $\theta_{ij}$  o ângulo entre as direções principais de dois objetos  $(R_i, R_j)$ , define-se o seguinte atributo de relacionamento espacial,

$$\Phi(R_i, R_j) = \text{sen}(2 \theta_{ij}). \quad (13)$$

Esse atributo possibilita a verificação do paralelismo ou perpendicularismo entre objetos, pois se  $\theta_{i,j} = 0^\circ$  (objetos com eixos principais paralelos) ou se  $\theta_{i,j} = 90^\circ$  (objetos com eixos principais perpendiculares),  $\Phi(R_i, R_j) = 0$ . Portanto, no conhecimento  $\mathcal{K}$  deve ser assumido que o valor ótimo para este parâmetro é 0 (zero). Esse atributo favorece o agrupamento de telhados, isto porque os eixos principais dos telhados são paralelos ou perpendiculares, o que não ocorre com outros objetos.

A análise de objetos usando a abordagem MRF tem como princípio a minimização da função de energia. Para o problema em questão, espera-se que para um determinado MDE a solução seja ótima, isto é, que seja obtida uma configuração de contornos de telhados, correspondente ao valor mínimo da função de energia. Entretanto, essa análise ótima depende de como a função de energia é definida.

A Equação de energia (Equação 14) foi desenvolvida para a extração de contornos de telhados, a partir de contornos de objetos altos previamente extraídos, ficando (GALVANIN, 2007),

$$\begin{aligned}
 U = & \alpha \sum_{i=1}^n (1 - r_i) + \beta \sum_{i=1}^n \frac{(1 - p_i)}{A_i} \\
 & + \omega \sum_{i=1}^n \sum_{j \in (G, \eta)} p_i p_j \left| \text{sen}(2 \theta_{ij}) \right| \\
 & + \gamma \sum_{i=1}^n \left[ p_i \ln p_i + (1 - p_i) \ln (1 - p_i) \right]
 \end{aligned} \tag{14}$$

onde:  $\alpha$ ,  $\beta$ ,  $\omega$  e  $\gamma$  são pesos que dão a importância relativa para cada termo das funções de energia;  $r_i$  é a medida de retangularidade do objeto  $R_i$ ;  $A_i$  é a área do objeto  $R_i$ ;  $p_i$  (ou  $p_j$ ) é uma medida individual de compatibilidade de  $R_i$  (ou  $R_j$ ) com um contorno de telhado;  $\theta_{ij}$  é o ângulo entre as direções dominantes dos objetos  $R_i$  e  $R_j$ .

Minimizar a função de energia U (equação 14) implica em minimizar simultaneamente os quatro termos de energia de U. No final do processo de minimização, isto é, quando U for mínimo, obtém-se uma configuração ótima dos contornos que são telhados de edifícios. O valor final de  $p_i$  para contornos de telhados é um, enquanto que para os outros objetos é zero. O algoritmo de otimização utilizado foi o *simulated annealing* (SA), que é eficiente na obtenção do mínimo global, mesmo quando a função de energia possui mínimos locais. Como uma exposição compreensiva do algoritmo SA necessitaria de muito espaço, remete-se o assunto para referências relevantes, como Kopparapu e Desai (2001).

#### 4. RESULTADOS E ANÁLISE

Nesta seção são apresentados e analisados os resultados da metodologia proposta para a extração automática de contornos de telhados. Foram utilizadas malhas de pontos laser irregularmente distribuídos, sendo que cada ponto possui as coordenadas *Universe Transverse Mercator* (UTM) (E, N), a altura ortométrica (h) e a intensidade de retorno do pulso laser (I). O atributo I pode ser utilizado para gerar imagens de intensidade. Esses dados se referem a uma área urbana de Curitiba, PR. A fim de verificar experimentalmente o desempenho da metodologia proposta, cinco regiões com diferentes complexidades foram selecionadas. O método de interpolação pelo vizinho mais próximo foi aplicado preliminarmente a estes dados para gerar malhas regulares (MDE's) de dados com espaçamento de 70 cm entre pontos na malha. O aplicativo Surfer foi utilizado para realizar esta tarefa. O MDE de cada área teste foi segmentado via divisão recursiva usando a estrutura *quadtrees*. Esse método de segmentação foi implementado em Builder C++ 4.0. Para a implementação do método de fusão Bayesiana utilizou-se o software WinBUGS

(<http://www.mrc-bsu.cam.ac.uk/bugs/winbugs/contents.shtml>), com uma cadeia de 32000 iterações onde as 22000 primeiras foram descartadas. A análise de convergência foi feita através do diagnóstico de Gelman e Rubin (1992) e das trajetórias das cadeias geradas. Isto é necessário, pois caso não se tenha indicação de convergência o modelo deve ser revisto antes de adotado para a aplicação a que se destina. O método que identifica os contornos de telhado entre os contornos de objetos altos foi desenvolvido em Builder C++ 4.0.

Os resultados obtidos com a metodologia proposta foram contornos locais representando telhados. Vale ressaltar que não houve a preocupação de regularizar geometricamente esses contornos. A análise foi realizada visual e numericamente, tendo por base comparações entre os resultados obtidos com o método de extração e os correspondentes resultados obtidos manualmente. Estes últimos foram obtidos através de digitalização manual dos contornos de telhados nas imagens de intensidade obtidas a partir do componente de intensidade (I) de retorno do pulso laser. Os contornos obtidos dessa forma são denominados *contornos de referência*. Ambos os grupos de contorno (extraído e de referência) foram sobrepostos sobre as imagens de intensidade para possibilitar a análise visual dos resultados. Os resultados da extração e de referência foram também comparados numericamente, consistindo em obter as porcentagens de falsos positivos (extração errada), falsos negativos (não extração) e a razão de extração de edifícios (REE), proposta por Ruther, Martine e Mtaló (2002) é dada pela seguinte formulação

$$REE = \frac{EC}{EC + EE} \times 100, \quad (15)$$

onde: EC é o número de estruturas identificadas corretamente pelo método de extração; e EE é o número de estruturas identificadas erroneamente pelo método de extração.

Outro indicador de qualidade, proposto por Ruther, Martine e Mtaló (2002), foi adaptado e utilizado neste trabalho. Trata-se da completeza de área (CA) do contorno de telhado, obtida em função das áreas dos contornos extraídos e dos respectivos contornos de referência obtidos por um operador,

$$CA = \left\{ 1 - \left( \frac{|A - B|}{A} \right) \right\} \times 100, \quad (16)$$

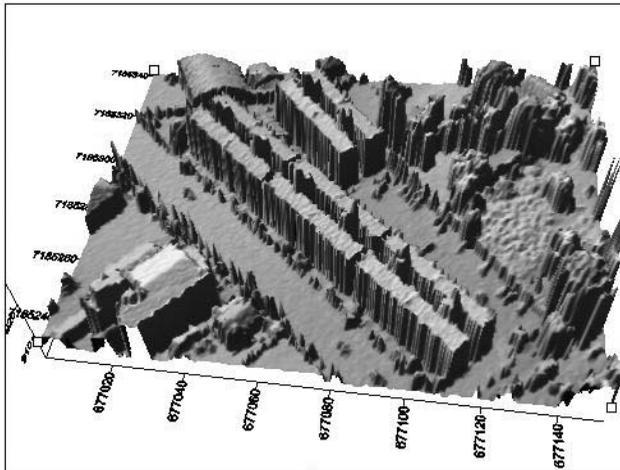
onde: A é a área do contorno de telhado extraída pelo operador; e B é a área do contorno de telhado obtida pelo método de extração.

McKeown et al. (2000) sugere que uma sobreposição de 50% é adequada para assumir que o telhado foi detectado. Cabe ainda ressaltar que as porcentagens de falsos positivos (extração errada) e a REE são complementares (a soma de ambos é 100%), e, portanto, neste caso optou-se apenas pela utilização da REE.

Neste trabalho foram utilizados alguns limiares, tais como: energia inicial no algoritmo SA (1000), para os parâmetros da função de energia foi considerado  $\alpha = \beta = \gamma = 0,7$  e  $\omega = 0,99$ . Esses valores foram adotados com o objetivo de se verificar a minimização da função de energia e o comportamento de cada termo da função de energia, respectivamente, em relação a obtenção do contorno de telhado.

Das 5 áreas teste selecionadas, a área teste 1 foi escolhida para uma análise mais detalhada. Este procedimento visa mostrar com mais detalhes o funcionamento da metodologia e as características dos resultados gerados em cada etapa da metodologia. A área teste 1 apresenta relativa complexidade para o processo de extração, visto que apresenta tanto edifícios de maior porte quanto casas. Há também a presença de árvores e outros objetos, fatores que implicam em maior complexidade. A figura 1 mostra uma visualização tridimensional do MDE referente à área teste 1, onde os objetos altos são facilmente identificados. Têm-se no total 6 edifícios isolados, sendo que 3 deles estão alinhados e praticamente ligados, 2 outros estão isolados e o último é um edifício menor cercado por vegetação.

Figura 1 – Visualização tridimensional do MDE - área teste 1.

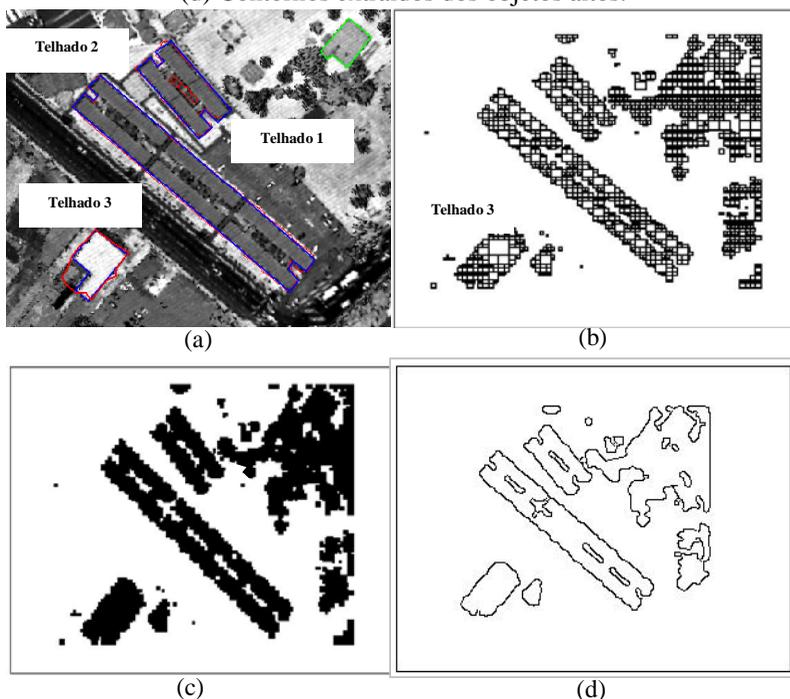


Na Figura 2 são mostrados os resultados obtidos pela metodologia proposta para a área teste 1, incluindo os resultados das etapas intermediárias. O resultado final são polígonos de contornos de telhados no referencial do MDE, os quais estão sobrepostos em vermelho na imagem de intensidade (figura 2(a)). Essa figura mostra também os correspondentes polígonos de referência (em azul) e um falso negativo (em verde). O resultado obtido pela fusão bayesiana de regiões é mostrado na figura 2(b). A figura 2(c) mostra o resultado da técnica de preenchimento de

contornos aplicada às regiões altas detectadas pela fusão bayesiana. A figura 2(d) mostra a representação dos contornos de objetos altos em polígonos, sendo que este resultado é vantajoso em dois aspectos: a compacidade e a simplicidade da representação dos contornos.

Verifica-se por inspeção visual dos resultados apresentados na figura 2 que o maior telhado existente na área teste 1 (três edifícios alinhados) foi fundido ainda na etapa de fusão bayesiana (figura 2(b)), resultando em um único contorno de telhado. Isso provavelmente se deve ao fato da sombra (ausência de dados do primeiro pulso laser) nas fendas entre essas edificações, fazendo com que o método de interpolação pelo vizinho mais próximo preencha essas fendas estreitas com alturas dos telhados.

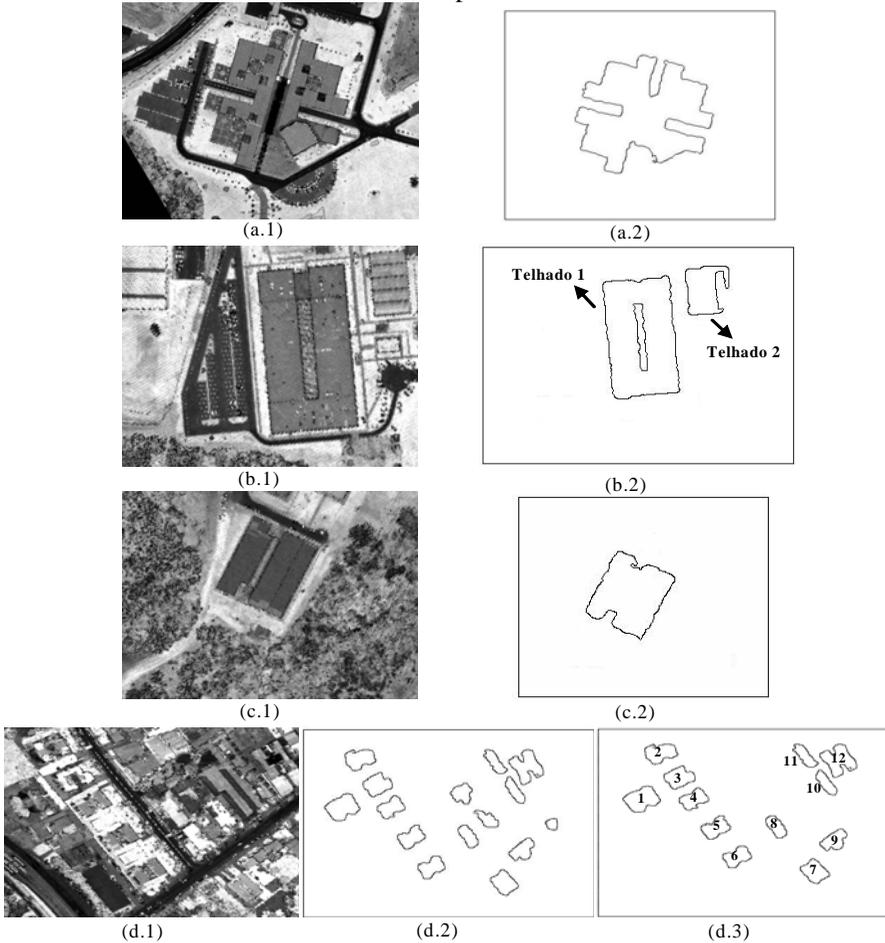
Figura 2 – Resultados da metodologia de extração de contornos de telhados para a área teste 1. (a) Imagem intensidade referente à área teste 1 e resultados finais sobrepostos; (b) Detecção dos objetos altos; (c) Imagem binária com objetos altos; e (d) Contornos extraídos dos objetos altos.



A figura 2(a) mostra (em verde) um edifício de porte bem menor misturado com a vegetação adjacente, sendo que neste caso não foi possível ainda na primeira etapa da metodologia separar essa edificação (ver figuras 2(b), 2(c) e 2(d)). Isso mostra que outras estratégias são necessárias para filtrar a vegetação antes de se

realizar a segunda etapa da metodologia. Nota-se também que a fusão bayesiana conseguiu separar eficientemente os outros dois telhados isolados.

Figura 3 – Resultados obtidos para as áreas testes 2, 3, 4 e 5. (a.1) e (a.2): Imagem intensidade referente à área teste 2 e respectivo resultado; (b.1) e (b.2): Imagem intensidade referente à área teste 3 e respectivo resultado; (c.1) e (c.2): Imagem intensidade referente à área teste 4 e respectivo resultado; (d.1), (d.2) e (d.3): Imagem intensidade referente à área teste 5, contornos de objetos altos e contornos de telhados, respectivamente.



A figura 3 apresenta resumidamente os resultados obtidos para as áreas testes 2, 3, 4 e 5. Para estes experimentos apresentam-se apenas as imagens de intensidade de retorno do pulso laser e os respectivos resultados finais, com exceção do experimento 5, para o qual também é apresentado o resultado (figura 3(d.2)) da primeira etapa do método. A figura 3(d.2) facilita a visualização dos falsos positivos. As imagens intensidades são apresentadas apenas com o intuito de visualização das respectivas áreas testes. Deve-se ressaltar que a visualização tridimensional do MDE proporciona uma boa verificação visual dos objetos existentes na área, fato que auxiliou na quantificação das edificações existentes em cada área de interesse tornando possível dizer se uma edificação faria ou não parte da extração.

A tabela 1 apresenta os resultados numéricos obtidos para os 5 experimentos. Estes parâmetros possibilitam avaliar quantitativamente a metodologia. Nesta tabela podem ser identificadas 4 colunas principais: a coluna 1 identifica os experimentos; a coluna 2 mostra as porcentagens de falsos negativos (FN) para cada experimento; a coluna 3 mostra as porcentagens de razão de extração de edifício (REE) para cada experimento; e a coluna 4 mostra as porcentagens de completeza de área (CA) para cada experimento. A quantidade de valores numéricos na coluna do parâmetro CA depende do número de telhados extraídos. Por exemplo, o experimento 1, detalhadamente descrito acima, resultou na extração de 3 telhados. Este experimento mostra que a metodologia teve um bom desempenho na extração dos contornos dos telhados 1 (CA= 92%) e 2 (CA= 88%) e um desempenho regular na extração do telhado 3 (CA= 62%). Um contorno de telhado não foi extraído, resultando num valor de 25% para FN. Como não houve falsos positivos, REE atingiu o valor ótimo, isto é, 100%.

Tabela 1 – Parâmetros para a avaliação numérica dos experimentos.

Exp	FN (%)	REE (%)	CA (%)				Exp.				FN (%)				
1	25	100	92				88				62				
2	0	100	94												
3	0	100	91								97				
4	0	100	95												
5	14,3	100	81	98	94	92	95	94	98	98	98	98	98	83	80

A área teste 2 (figura 3(a.1)) possui apenas um edifício, mas com relativa irregularidade geométrica. Os resultados finais obtidos com a metodologia de extração automática de contornos de telhados de edifícios são mostrados na figura 3(a.2). Como mostra a tabela 1, o experimento 2 não apresentou falsos positivos (REE= 100%) e falsos negativos (FN= 0%). Outro indicativo importante foi o alto valor obtido para a completeza de área (CA= 94%), mostrando que a região de

contorno extraída tem alta sobreposição em relação à região de contorno de referência.

A área teste 3 (figura 3(b.1)) possui dois edifícios com formas geométricas relativamente simples. A figura 3(b.1) mostra que os resultados obtidos podem ser considerados satisfatórios. Vale ressaltar que o telhado 2 foi extraído mesmo possuindo um porte bem menor que o telhado 1. Embora a equação de energia penaliza objetos de área relativamente menor, pode-se notar que a extração de ambos os telhados é favorecida pelos atributos de relacionamento espacial e de retangularidade. Como ocorreu no experimento anterior, a tabela 1 mostra que não houve a ocorrência de falsos positivos (REE= 100%) e falsos negativos (FN= 0%). Os altos valores obtidos para a completeza de área (91% para o telhado 1 e 97% para o telhado 2) evidenciam grande sobreposição entre ambos os contornos extraídos com os respectivos contornos de referência.

A área teste 4 (figura 3(c.1)) possui baixa complexidade, visto que contém apenas um objeto isolado, o qual foi corretamente extraído (figura 3(c.2)). Dessa forma, não houve a ocorrência de falsos negativos. A tabela 1 mostra também que não ocorreram falsos positivos (REE= 100%) e que os contornos extraídos e de referência possuem sobreposição de 95%.

A área teste 5 (figura 3(d.1)) exibe uma complexidade bem maior em relação às áreas testes anteriores. Nesta área teste é possível identificar 15 objetos altos, dos quais 14 são edifícios. Alguns desses edifícios apresentam certa irregularidade local nos contornos, mas possuem forma geral relativamente regular. Isto pode ser observado no resultado obtido com a fusão bayesiana (figura 3(d.1)), que tem por função detectar os objetos altos. Diante dessas características, existe a necessidade de usar, em relação ao atributo de direção, setores com amplitudes de aproximadamente 15° para calcular as direções principais dos objetos. Este procedimento permite geralmente determinar as duas direções predominantes (principais) dos objetos mesmo quando as formas não são bem regulares. Uma maior dificuldade pode surgir no cálculo da direção secundária, especialmente no caso de objetos alongados e com arredondamento nos lados menores. Existem nesta área teste dois edifícios com esta característica (figura 3(d.2)). Conforme mostra a figura 3(d.3), mesmo assim estes telhados foram extraídos, o que certamente foi possível devido à injunção espacial, que depende somente da direção principal. Os resultados obtidos podem ser considerados satisfatórios, visto que dos 15 objetos altos extraídos pela fusão bayesiana (figura 3(d.2)), 12 foram extraídos na segunda etapa do metodologia. Dois edifícios não foram extraídos (FN= 14,3%, tabela 1) devido às formas irregulares resultantes da fusão bayesiana. Nenhum objeto alto foi erroneamente identificado como telhado de edifício, motivo pelo qual o valor de REE atingiu o valor ótimo. A tabela 1 mostra que 5 telhados extraídos (2, 7, 8, 9 e 10) apresentam valores de CA bem próximo do valor ótimo e que outros 3 telhados (1, 11 e 12) apresentaram valores de CA abaixo de 90%.

## 5. CONCLUSÕES

Neste trabalho foi apresentada uma metodologia automática de extração de contornos de telhados de edifícios em um MDE obtido a partir de dados de varredura a laser, bem como os resultados obtidos com a metodologia proposta. Esta metodologia baseia-se em duas etapas principais. Na primeira etapa é realizada a extração de regiões altas (edifícios, árvores etc.) do MDE. Na segunda etapa são extraídas as regiões altas que correspondem aos contornos de telhados.

Foram realizados cinco experimentos com dados reais, os quais forneceram subsídios para a análise do desempenho da metodologia proposta. A escolha das áreas teste levou em conta a complexidade das configurações de objetos presentes na cena. Desta forma, foram selecionadas desde áreas teste com telhados isolados até com agrupamentos de telhados. Essa escolha teve como principal objetivo verificar a robustez da metodologia em diferentes tipos de cena.

De uma forma geral, um bom indicativo de robustez da metodologia proposta foi a ausência de falsos positivos e a verificação de poucos falsos negativos. O atributo de completude de área mostrou que geralmente os polígonos extraídos possuem alta superposição com os respectivos polígonos de referência.

O método de fusão bayesiana mostrou-se eficiente na tarefa de separar os objetos altos (como por exemplo, edifícios, árvores, caixas d'água etc.) dos objetos baixos (quintais, pátios, corredores, canteiros, carros, barracas, ruas, terrenos etc.), proporcionando uma grande redução da complexidade da cena. Entretanto, nem sempre é possível separar edifícios e árvores de portes parecidos, conforme se verificou no experimento 1. O modelo MRF possibilitou na segunda etapa da metodologia utilizar injunções espaciais, as quais possibilitaram modelar melhor a cena. Isto ficou evidente no experimento 5, principalmente pela presença de dois telhados alongados e com lados menores arredondados. Nesse caso, apenas a direção do eixo principal dos objetos pôde ser calculada com boa qualidade, o que prejudicou o cálculo do atributo de retangularidade, mas não o de relacionamento espacial. Em outras palavras, as injunções espaciais podem auxiliar na discriminação dos objetos de interesse em várias situações, mesmo que o atributo de retangularidade não seja bom.

Conclui-se então de forma geral que a metodologia desenvolvida possibilitou a extração de contornos de telhados de forma satisfatória, mas com a limitação principal de que os polígonos extraídos, mesmo que passem por pós-processamentos para a regularização de seus contornos, são aproximações para os respectivos telhados. Essa é uma limitação bem conhecida dos métodos que usam somente dados laser (regulares ou não) para extração de contornos de telhados (KAARTINEN et al., 2005). Para melhoria desses contornos é necessário integrar dados laser com dados fotogramétricos.

## AGRADECIMENTOS

Os autores são gratos à FAPESP (pelo apoio na forma de Auxílio à Pesquisa), ao CNPQ (pelo apoio na forma de bolsa de produtividade em Pesquisa - PQ), à CAPES (pelo apoio na forma de bolsa de doutorado) e ao instituto LACTEC (pela concessão de dados laser).

## REFERÊNCIAS

- AREFI, H.; HAHN, M. *A hierarchical procedure for segmentation and classification of airborne LIDAR images*. In: Geoscience and Remote Sensing Symposium, 7, 2005. *Proceedings...* 2005. p. 4950 - 4953.
- BESAG, J.; YORK, J.; MOLLIE, A. *Bayesian Image Restoration, with two applications on Spatial Statistics*. *Annals of the Institute of Statistical Mathematics*, v. 43, p. 1-59, 1991.
- BRETAR, F.; ROUX, M. *Hybrid image segmentation using LiDAR 3D planar primitives*. In: ISPRS WORKSHOP LASER SCANNING, 2005, Enschede, the Netherlands. *Proceedings...* 2005.
- DUBES, R. C. E JAIN, A. K. *Random Field Models in Image Analysis*. *Journal of applied Statistics*, v. 16, n. 2, p. 131-164. 1989.
- GALVANIN, E. A. S. *Extração automática de contornos de telhados de edifícios em um modelo digital de elevação, utilizando Inferência Bayesiana e campos aleatórios de markov*. 2007. 165 f. Tese (Doutorado em Ciências Cartográficas) – Universidade Estadual Paulista, Presidente Prudente.
- GALVANIN, E. A. S.; DAL POZ, A. P.; SOUZA, A. D. P. *Segmentação de dados de perfilamento a laser em áreas urbanas utilizando uma abordagem bayesiana*. *Boletim de Ciências Geodésicas*, v.13, p.76/1 - 90, 2007.
- GELMAN, A.; RUBIN, D.B *Inference from iterative simulation using multiple sequences*, *Statistical Science*, 7, 457-511, 1992.
- HAALA, N.; BRENNER, C. *Extraction of buildings and trees in urban environments*. *ISPRS Journal of Photogrammetry e Remote Sensing*, v.54, p.130-137, 1999b.
- JAIN, R.; KASTURI, R; SCHUNCK, B. G. *Machine vision*. MIT Press and McGraw-Hill, Inc New York, 1995.
- KAARTINEN et al. *Accuracy of 3d city models: EUROSUR comparison*. In: ISPRS Workshop "Laser scanning 2005", Enschede, the Netherlands, September 12-14. *Proceedings...* 2005.
- KOPPARAPU, S. K.; DESAI, U. B. *Bayesian approach to image interpretation*. 127p., 2001.
- MATIKAINEN, L.; HYYPPÄ J.; HYYPPÄ H. *Automatic detection of buildings from laser scanner data for map updating*. In: ISPRS Workshop Laser Scanning, 2005. *Proceedings...* 2005.
- MCKEOWN, D. M.; BULWINKLE, T. M.; COCHRAN, S.; HARVEY, W.; MCGLONE, C.; SHUFELT, J. A. *Performance evaluation for automatic*

- feature extraction*. International Archives of Photogrammetry and Remote Sensing, v. 33, part B2, p. 379–394, 2000.
- 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.
- RÜTHER, H.; MARTINE, H. M.; MTALO, E. G. *Application of snakes and dynamic programming optimization technique in modeling of buildings in informal settlement areas*. ISPRS Journal of Photogrammetry and Remote Sensing, v. 56, p. 269-282, 2002.
- SCHMIDT, A. M.; NOBRE, A. A.; FERREIRA, G. S. *Alguns Aspectos da Modelagem de Dados Espacialmente Referenciados*. Revista brasileira de estatística, Brasil, v. 63, n. 220, p. 59-88, 2003.
- SOHN, G.; DOWMAN, I. J. *Building extraction using Lidar DEMs and Ikonos images*. In: ISPRS, v. XXXIV, p. 3/W13. Dresden, Germany. *Proceedings...* 2003.
- The BUGS project. United Kingdom. 2004. disponível em: <http://www.mrc-bsu.cam.ac.uk/bugs/winbugs/contents.shtml>. Acesso em: 14 de fevereiro de 2004.
- TARSHA-KURDI, F.; LANDES, T.; GRUSSENMEYER, P.; SMIGIEL, E. *New Approach for Automatic Detection of Buildings in Airborne Laser Scanner Data Using first Echo only*. In: Symposium of ISPRS Commission III Photogrammetric Computer Vision, Bonn, Germany. *Proceedings...* 2006.
- TÓVÁRI, D.; PFEIFER, N. Segmentation based robust interpolation – A new approach to laser data filtering. In: ISPRS Workshop "Laser Scanning", Enschede, the Netherlands. *Proceedings...* 2005.
- VOSSelman, G. Fusion of Laser Scanning Data, Maps, and Aerial Photographs for Building Reconstruction. In: International Geoscience and Remote Sensing Symposium, Toronto, Canada. *Proceedings...* 2002.

(Recebido em Janeiro/08. Aceito em junho/08).