

Markov Random Field: Uma abordagem para caracterização e reconhecimento de contornos de telhados

Edinéia Aparecida dos Santos Galvanin¹
Aluir Porfírio Dal Poz²

¹ Universidade do Estado de Mato Grosso - UNEMAT/Dep. de Matemática
CEP: 78390-000 – Barra do Bugres - MT, Brasil
{galvanin}@gmail.com

² Universidade Estadual Paulista – UNESP/Departamento de Cartografia
19060 – 900, Presidente Prudente, SP
{aluir}@fct.unesp.br

Abstract. Methodologies for automatic building roof extraction are important in the context of spatial information acquisition for geographical information systems (GIS). Thus, this work proposes a methodology for roof contour extraction from laser scanning data by Markov Random Field model. The methodology is based on extraction of high regions (buildings, trees etc.) from a Digital Elevation Model (DEM) derived from laser scanning data, and building roof contour extraction. The high object polygons are extracted by using vectorization and polygonization techniques. 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 objects), 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. The data area consists of a regular grid obtained by interpolating a laser scanning data set from Curitiba/PR city. The test area with different object configuration complexities was tested. Experiments carried out with laser scanning data's DEM showed that the methodology allows discriminating the urban objects in the scene properly.

Palavras-chave: roof contours, laser scanning data, energy function, contornos de telhados, dados de varredura a laser, função de energia.

1. Introdução

O MRF, ou Campo Aleatório de Markov, é um modelo que tem atraído muita atenção nos últimos anos. Os modelos MRF têm sido utilizados em aplicações de processamento de imagem de baixo nível, tais como segmentação e restauração de imagem (Geman e Geman (1984); Szirányi et al. (2000)). No entanto, recentemente vem sendo utilizado em tarefas de análise de imagem de alto nível (Kim e Yang (1995), Kinderman e Snell (1980), Koppurapu, e Desai (2001), Andersen et al. (2002)).

A análise de imagem usando MRF é formulada como um problema de estimação do *maximum a posteriori* (MAP). Este processo corresponde à resolução de um problema de minimização de energia. Em geral, a função de energia associada com problemas de visão é não-convexo, podendo então ter vários mínimos locais. Assim, a solução pode não corresponder a um mínimo global. Segundo Kinderman e Snell (1980), o MRF pode, também, ser definido, sobre grafos e aplicado para o problema de análise de imagem.

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 então resolvido como um problema de estimativa MAP. 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.

2.1 MRF em estrutura de grafo

Segundo Koppurapu e Desai (2001), a formulação de um MRF em estrutura de grafos inicia com uma imagem segmentada com n regiões $\{R_1, R_2, \dots, R_n\}$ e o RAG correspondente. Seja $G = \{R, E\}$ um RAG, onde $R = \{R_1, R_2, \dots, R_n\}$ representa o conjunto de nós R_i , $i = 1, 2, \dots, n$ e E denota o conjunto de arestas. Existirá uma aresta entre os nós R_i e R_j se as regiões correspondentes compartilharem, pelo menos parcialmente, de uma mesma fronteira.

O sistema de vizinhança em G será representado por

$$\eta = \{\eta(R_1), \eta(R_2), \dots, \eta(R_n)\} \quad (1)$$

onde $\eta(R_i)$, $i = 1, \dots, n$ é o conjunto de todos os nós em R vizinhos de R_i . Nota-se que $R_i \in \eta(R_j)$ se $R_j \in \eta(R_i)$.

Uma clique c , neste contexto, é um subconjunto de nós de G (isto é, R) 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 η é representado como $C(G, \eta)$.

Define-se uma função potencial da clique V_{c_i} envolvendo somente nós de c_i . Assim, cada função desse tipo expressa a forma e o grau de interação (primeira ordem, segunda ordem etc.) que cada nó R_i tem com seus vizinhos.

Nesse contexto definiremos $U(x)$ como a função de energia de Gibbs, dada por,

$$U(x) = \sum_{c \in C(G, \eta)} V_c(x^c) \quad (2)$$

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 $c \in C(G, \eta)$.

A distribuição de Gibbs, é dada por,

$$P[X = x] = \frac{1}{Z} e^{-U(x)} \quad (3)$$

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

$$Z = \sum_{\text{toda conf. } x} e^{-U(x)} \quad (4)$$

Seja $X = \{X_1, X_2, \dots, X_n\}$ a família de variáveis aleatórias definida sobre R , onde cada X_i corresponde a R_i . Além disso, assume-se que X_i toma valores em um espaço amostral finito. Segundo Koppurapu e Desai (2001), X é denominado um MRF sobre G com relação ao sistema de vizinhança η se e somente se:

$P[X = x] > 0$ para todas as realizações de X ;

$$P[X_i = x_i | X_j = x_j \quad \forall j \neq i] = P[X_i = x_i | X_j = x_j \quad \forall j : R_j \in \eta(R_i)].$$

Uma das vantagens do modelo de MRF é que geralmente sua função distribuição de probabilidade é dada pela distribuição de Gibbs conforme estabelece o teorema de Hammersley-Clifford (Besag, 1974).

De acordo com Kinderman e Snell (1980), 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 η , se e somente se X tem distribuição de Gibbs.

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 κ , o qual está relacionado com os objetos constituintes da cena e que se pretende identificar. A caracterização de κ 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 κ e o conjunto de atributos F , é um MRF, isto é,

$$P[X = x | F = f, \kappa] = \frac{1}{Z} \exp^{-U(x|f, \kappa)} \quad (5)$$

$$U(x|f, \kappa) = \sum_{c \in \mathcal{C}(G, \eta)} V_c(x^c | f^c, \kappa). \quad (6)$$

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

$$x_* = \arg \max_x P[X = x | F = f, \kappa], \quad (7)$$

ou, de forma equivalente,

$$x_* = \arg \min_x U(x|f, \kappa). \quad (8)$$

Para uma determinada imagem, uma análise ótima corresponde à minimização de uma função de energia. No entanto, essa análise ótima depende de como a função de energia é definida.

2.3 Solução MAP

Como foi discutido anteriormente o processo em questão, de análise de imagem, é formulado como um problema de estimativa MAP. Em geral, quando se tem um problema baseado num modelo MRF, a solução procurada geralmente envolve uma estimativa MAP, que é equivalente a um problema de minimização da função de energia dada por,

$$x_* = \arg \min_x \left[\begin{array}{l} \sum_{\forall c = \text{um nó clique}} V_c^l(x^c | f^c, \kappa) + \\ \sum_{\forall c = \text{múltiplos nós clique}} V_c^m(x^c | f^c, \kappa) \end{array} \right]. \quad (9)$$

Em geral, a expressão dentro do colchete na (Equação 9) possui vários mínimos locais. Assim, é necessária a aplicação de um algoritmo de minimização que possa fornecer um mínimo global. Entretanto, a utilização de um método simples de otimização envolve uma busca combinatorial exaustiva, resultando em uma complexidade exponencial da ordem de L^N , onde L é o número de rótulos e N o número de nós do grafo de adjacência (Modestino e Zhang (1992)).

Todavia, com o intuito de resolver o problema da busca combinatorial, alguns autores têm proposto esquemas de relaxação para encontrar a solução local ótima para o problema da estimativa MAP (Rosenfeld e Hummel (1976), Hummel e Zucker (1983)). Outra solução, descrita na literatura, para reduzir a complexidade exponencial é a utilização do algoritmo *Simulated Annealing* (SA). Este algoritmo é um procedimento de otimização, que encontra o

máximo global da distribuição a posteriori do MRF ou o mínimo da função de energia sem cálculos excessivos Geman e Geman (1984).

É oportuno registrar que a técnica de otimização mencionada já foi utilizada recentemente para a extração de feições cartográficas. De fato, Trinder et al. (2000) o apresenta como uma alternativa vantajosa ao princípio de minimização de energia usado para a solução do problema de contorno ativo (*snakes*), cuja desvantagem está associada à sensibilidade do processo de otimização ao estado inicial. Esses autores ressaltam, ainda, que a literatura não fornece informação sobre a escolha da temperatura inicial, ao contrário, essa escolha envolve tentativa e erro.

3. Caracterização do conhecimento sobre contornos de telhados

Para verificar o desempenho do MRF na análise de imagens por regiões, algumas regiões altas obtidas pela metodologia apresentada por Galvanin et al. (2007) são agora estruturadas segundo um RAG, onde cada nó do RAG corresponde a uma região alta. Essa modelagem deve propiciar a obtenção apenas dos contornos correspondentes aos telhados. Vale ressaltar que, como é necessário o cálculo de vários atributos, deve-se considerar que em uma quadra urbana existe um conjunto de objetos variados, onde a heterogeneidade geralmente é elevada. Isto implica que mais detalhes sobre o objeto de interesse devem ser explorados para auxiliar no seu reconhecimento. Os telhados possuem algumas propriedades de interesse, sendo elas, geométricas, ou seja, as que estão relacionadas com a área, o perímetro, a retangularidade, direção angular etc., e as relações contextuais nas quais o objeto telhado se relaciona com outros objetos presentes na cena (por exemplo, ângulos entre eixos de objetos).

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

$$\eta_{R_i, r} = \{R_j \mid \text{dist}(R_j, R_i) \leq r\} \quad (10)$$

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 Figura 1 mostra um exemplo de vizinhança ($\eta_{R_i, r}$), onde todas as regiões dentro do raio máximo são consideradas vizinhas da região i . Na Figura 1, os pontos representam o centro de massa dos objetos altos.




Figura 1 – Exemplo de vizinhança.

Uma vez estabelecido o critério de vizinhança ($\text{dist}(R_j, R_i) \leq r$), define-se uma vizinhança individual e, a partir desta definição, tem-se o sistema de vizinhança $\eta = [\eta(R_1), \dots, \eta(R_n)]$. Os conceitos de clique individual C e de coleção de cliques ($C(G, \eta)$) seguem o formalismo apresentado na seção de MRF em estrutura de grafos.

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 κ 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 κ implica em estabelecer valores nominais para os atributos que são considerados importantes para decisão em uma análise. Por exemplo, a área mínima de um edifício pode ser estabelecida como sendo 30m^2 . Já os valores nominais para o conjunto (F) de atributos podem ser medidos no polígono envolvente que contém cada objeto individual e entre polígonos caracterizando a relação contextual entre os objetos. Para tanto é necessário estabelecer um conjunto (F^c) de atributos sobre a clique. O conjunto (F) de atributos é expresso por, $F = \{F^c \mid \forall c \in C(G, \eta)\}$, onde $F^c = \{F_1^c, \dots, F_q^c\}$, é o conjunto de q atributos medidos sobre a clique individual c . Cabe ressaltar que esses q atributos seriam os mesmos usados na caracterização do conhecimento a priori κ , só que nesse caso eles assumem valores que caracterizam os objetos de interesse.

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. Segundo Galvanin (2007) o primeiro atributo baseia-se na área (A) do polígono envolvendo o objeto individual e é definido matematicamente pela fórmula de Gauss dada por:

$$A = \frac{\left| \sum_{i=0}^{n-1} E_i N_{i+1} - \sum_{i=0}^{n-1} E_{i+1} N_i \right|}{2} \quad (11)$$

onde (E, N) correspondem às coordenadas planimétricas de um ponto no referencial do Modelo Digital de Elevação (MDE).

Este atributo permite, por exemplo, que objetos pequenos como caixas d'água, cuja área é relativamente menor em relação aos telhados, possam ser eliminados da análise. Para que isso seja possível, a Equação de energia deve penalizar pequenas áreas.

O segundo atributo, retangularidade (R), é obtido através do ângulo formado pela direção principal e secundária do objeto. Para obter o eixo principal de um objeto são calculadas todas as direções dos segmentos de reta de um polígono representando o objeto. Para obter a direção mais freqüente que é correspondente à direção do eixo principal, faz-se uma divisão setorial, particionando o círculo trigonométrico em 24 setores de 15 graus (Figura 2(a)). Cada setor é representado pelo seu valor angular central (por exemplo, o setor de amplitude $[345^\circ; 360^\circ]$ é representado pelo ângulo $352,5^\circ$).

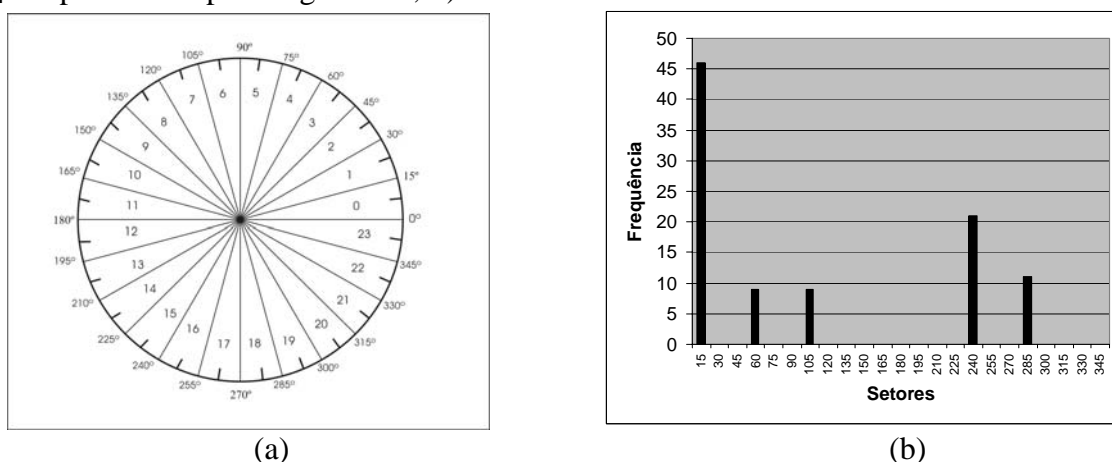


Figura 2 – (a) Divisão setorial do círculo trigonométrico e (b) Histograma de freqüência.

A direção do eixo principal e secundário de um objeto poderia ser representado na forma do histograma da Figura 2(b). Esse histograma é obtido após o cálculo da direção e

comprimento de cada segmento de reta do polígono que representa o objeto, ou seja, para uma dada direção de um dado segmento de reta, verifica-se qual setor que a contém, adicionando a este setor o valor inteiro do comprimento do respectivo segmento de reta, repete-se esse cálculo para todos os segmentos de reta do polígono e assim, identifica-se as direções dos eixos principal e secundário como sendo a primeira e a segunda direção mais freqüente, respectivamente.

Nesse caso, o resultado obtido para a direção do eixo principal e secundário pode ser representado no histograma a seguir onde $7,5^\circ$ é a direção do eixo principal (primeira mais freqüente) e $247,5^\circ$ é a direção do eixo secundário (segunda mais freqüente). Este resultado foi obtido a partir do contorno de um objeto real, que no caso é um telhado.

A retangularidade é expressa matematicamente por,

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

onde, θ 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 κ . 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 θ_{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 κ deve ser assumido que o valor ótimo para este parâmetro é 0 (zero)

Em relação às cliques, foram utilizadas neste trabalho as de primeira e segunda ordem. A clique de primeira ordem consiste de uma lista de objetos altos com atributos (área e retangularidade) caracterizando os objetos individualmente. Já a clique de segunda ordem é composta de uma lista de objetos, relacionando-se aos pares, caracterizadas por atributos relacionais (no caso o atributo dado pela Equação 13).

3.1 Definição da função de energia

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

$$U = \alpha \sum_{i=1}^n (1 - r_i) + \beta \sum_{i=1}^n \frac{(1 - p_i)}{A_i} + \omega \sum_{i=1}^n \sum_{j \in (G, \eta)} p_i p_j |\text{sen}(2 \theta_{ij})| \quad (14)$$

$$+ \gamma \sum_{i=1}^n \left[p_i \ln p_i + (1 - p_i) \ln (1 - p_i) \right]$$

onde: α , β , ω e γ 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; θ_{ij} é o ângulo entre as direções dominantes dos objetos R_i e R_j .

Minimizar a função de energia U (Equação 14) implica 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 SA, que é eficiente na obtenção do mínimo global, mesmo quando a função de energia possui mínimos locais.

4. Resultados

Nesta seção são apresentados e analisados os resultados da metodologia proposta para a extração de contornos de telhados a partir da caracterização do conhecimento de telhados. A imagem teste utilizada neste trabalho, Figura 3b, é uma imagem de intensidade obtida por perfilamento a laser, fornecida pelo Instituto de Tecnologia para o Desenvolvimento (LACTEC).




Figura 3 – (a) Visualização tridimensional do MDE da área teste. (b) Imagem intensidade referente à área teste; (c) resultado da extração usando a equação de energia via algoritmo SA.

Analisando-se a Figura 3(a), verifica-se que há na cena 14 (quatorze) edifícios e 1 (um) objeto qualquer com forma irregular. Alguns desses edifícios apresentam certa irregularidade local nos contornos, mas possuem forma geral relativamente regular. Diante dessas características, existe a necessidade de usar, no 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. De fato, verificou-se na Figura 3(c) a extração de dois telhados com formas mais alongadas, esta extração foi possível graças a inunção espacial, visto que este atributo depende somente da direção principal. A extração de telhados com certa irregularidade foi possível graças a robustez do método do círculo trigonométrico setorizado em calcular as direções principais dos telhados. Em dois casos, ficou claro que apenas a direção principal poderia ser calculada com confiabilidade, a qual é fundamental para o estabelecimento das inunções de relação espacial de paralelismo e perpendicularismo.

Conclusões

Neste trabalho foi apresentada uma metodologia de caracterização do conhecimento de contornos de telhados de edifícios em um MDE obtido a partir de dados de varredura a laser, bem como o resultado obtido com a metodologia proposta. A contribuição principal deste

trabalho está relacionada com a exploração de relações espaciais entre os edifícios na cena, o que foi viabilizado pelo modelo MRF.

O modelo MRF possibilitou a utilização de injunções espaciais, as quais possibilitaram modelar melhor a cena. Isto ficou evidente no experimento realizado, 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.

A contribuição principal deste trabalho está relacionada com a exploração de relações espaciais entre os edifícios na cena, o que foi viabilizado pelo modelo MRF. Cabe ressaltar que essa modelagem não tem sido comum na extração de contornos de telhados em dados de varredura a laser.

Agradecimentos

Os autores são gratos ao instituto LACTEC (pela concessão de dados laser).

Referências Bibliográficas

Andersen, H.; Reutebuch, S.; Schreuder, G. Bayesian object recognition for the analysis of complex forest scenes. In: Symposium Photogrammetric Computer Vision, 2002, Austria. **Proceedings...** 2002.

Besag, J. Spatial interaction and the analysis of lattice systems. **Journal of the Royal Statistical Association, Series B** 36, p. 192-236, 1974.

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**, vol.13, p.76 - 90, 2007.

S. Geman, S.; Geman, D. Stochastic relaxation, Gibbs distribution, and Bayesian restoration of images. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, p.721-741, 1984.

Hummel, R. A.; Zucker, S. W. On the foundation of relaxation labeling process. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, p.267-287, 1983.

Kim, I. Y.; Yang, H. S. An integrated approach for scene understanding based on Markov Random Field. **Pattern Recognition**, p.1887-1897, 1995.

Kinderman, R.; Snell, J. L. **Markov Random Fields and their applications**. Providence, R.I: American Mathematical Society, 1980.

Kopparapu, S. K.; Desai, U. B. **Bayesian approach to image interpretation**, 2001. 127 p.

Metropolis, N.; Rosenbluth, M. N.; Rosenbluth, A. H.; Teller, A. H.; Teller, E. Equations of state calculations by fast computation machines. **Journal Chemical Physics**, vol. 21, p.1087-1091, 1953.

Modestino, J. A.; Zhang, J. A Markov Random Field model based approach to image interpretation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, vol. 6, p.606-615, 1992.

Rosenfeld, A.; Hummel, R. A.; Zucker, S. W. Scene labeling by relaxation operations. **IEEE Trans. Syst. Man Cybern.** vol. SMC-6, p.420-433, 1976.

Szirányi, T.; Zerubia, J.; Czúni, L.; Geldreich, D.; Kato, Z. Image segmentation using Markov Random Field model in fully parallel cellular network architectures. **Real-Time Imaging**. v.6, p. 195-211, 2000.

Trinder, J. C.; Maulik, U.; Bandyopadhyay, S. Semi-automated feature extraction using simulated annealing. In: International Archives for Photogrammetry And Remote Sensing. v.33, part B3, 2000. **Proceedings...** p. 905-911, 2000.