

Application of Gaussian Markov Random Fields in Citrus Segmentation

João Paulo Herrera, Leandro Rosendo Candido

Laboratório de Imagens
EMBRAPA Instrumentação
São Carlos, Brasil
joao.herrera@outlook.com
l.candido@hotmail.com

Lúcio André de Castro Jorge

Laboratório de Imagens
EMBRAPA Instrumentação
São Carlos, Brasil
lucio.jorge@embrapa.br

Abstract— The Number of trees is an important key to maintain a high level production in crop citrus. In this paper, images taken through a camera which is engaged in Unmanned Aerial Vehicle (UAV) were processed by using Gaussian Markov Random Fields (GMRF), where each pixel of the image was classified according to its probabilistic value in comparison with all the available classes. Manual segmentation methods and Otsu threshold were also compared with the proposed one.

Keywords— Gaussian Markov Random Fields; Campos Aleatorios Markovianos Gaussianos; contagem de citrus; segmentação;

I. INTRODUÇÃO

Uma importante informação que os produtores de citros necessitam para garantir a qualidade e quantidade de produção são o número de plantas e suas respectivas dimensões, na qual se estimam o valor médio de frutas colhidas e o processo de podagem. Ainda nos dias atuais, muitos produtores realizam o monitoramento e controle de forma manual, outros tampouco se beneficiam com as vantagens que a atual tecnologia pode oferecer na agricultura. O processo manual é um processo muito suscetível a erros humanos, sendo assim recomendada sua automatização.

Diversas são as metodologias possíveis para identificação de padrões em imagens aéreas em uma lavoura. Sokkari e Osborne [1] separam as copas das árvores através do crescimento de regiões, onde a propagação toma partida através do supervisionamento realizado pelo usuário ao selecionar pixels que pertencem aos objetos de interesse. Bazi *et al* [2] utiliza a técnica SIFT para extrair características de plantações de palmeiras e as classificam por ELM (Extreme Learning Machine), aplicando também, uma variante do descritor de textura LBP para distinguir as palmeiras de outras vegetações. Hung *et al* [3] utiliza conhecimento *a priori* para identificação de copas de árvores em imagens aéreas tiradas por VANT's. Informações de cor e textura são adquiridas e combinadas com um template para geração de um mapa de contexto, no qual é utilizado SVM para separar 3 diferentes espécies de copas de árvores. Descombes e Pechersky [4], encontraram resultados relevantes incorporando Campos

Aleatórios Markovianos com um framework Bayesiano para segmentação de imagens áreas. A similaridade dos pixels é definida pela regra Gaussiana e, por fim, otimiza-se os resultados utilizando o algoritmo Metrópolis dinâmico.

Neste trabalho é proposto um método para análise e contagem de copas de citros utilizando Campos Aleatórios Markovianos Gaussianos (GMRF) aplicados para segmentação de imagens tiradas por VANT's, onde seu valor de exatidão é comparado com o processo atual realizado de forma manual e também com o método de limiarização de Otsu, conhecido como uma alternativa atraente para implementações baseadas em suposições [7]. A separação das plantas é realizada com o algoritmo de watershed.

II. CAMPOS ALEATÓRIOS MARKOVIANOS GAUSSIANOS (GMRF)

I. Dada uma imagem bidimensional $N \times M$, assume-se que esta pode ser representada por um modelo baseado em grafos não direcionados $G(V, A)$, onde V denota o conjunto de vértices, com cada vértice v ($v \in V$) sendo um atributo característico aleatório e A denota o conjunto de arestas. Em um dado conjunto de rótulos θ , cada atributo v é associado com um rótulo ω , para isso, procura-se um rótulo ótimo $\hat{\omega}$ que maximize a probabilidade de rotulação $P(\omega|v)$ obedecendo ao critério Maximum a Posteriori (MAP):

$$\hat{\omega}^{MAP} = \operatorname{argmax}_{\omega \in \Omega} P(\omega|v) \quad (1)$$

segundo o teorema de Bayes:

$$P(\omega|v) = \frac{P(v|\omega)P(\omega)}{P(v)} \quad (2)$$

onde $P(v|\omega)$ é a função de probabilidade condicional, $P(\omega)$ é a probabilidade *a priori* da classe ω e $P(v)$ é uma constante.

De acordo com o teorema de Hammersley-Clifford, um campo aleatório apenas será um Campo Aleatório Markoviano se e somente se $P(\omega)$ seguir a distribuição de Gibbs:

$$P(\omega) = \frac{1}{Z} \exp(-U(\omega)) = \frac{1}{Z} \exp\left(-\sum_{c \in C} V_c(\omega)\right) \quad (3)$$

onde Z é uma constante de normalização ($\sum_{\omega \in \Theta} \exp(-U(\omega))$) e U é a função de energia de ω dada pela soma dos potenciais de cliques $V_c(\omega)$.

Campos Aleatórios Markovianos é um modelo probabilístico no qual encapsula informações a partir de um contexto, que neste caso, trata o relacionamento de um pixel e seus respectivos vizinhos, uma vez que a vizinhança tem influência na decisão de classificação de um determinado pixel de uma imagem. Levando em conta o modelo baseado em grafos, define-se clique como sendo um subconjunto $C \subseteq V$ de vértices na condição em que exista uma conexão entre pares de vértices próximos entre si, exceto para casos de cliques unários ou cliques de primeira ordem. A ordem de um clique C é dada de acordo com o número de relações existentes, sendo importante ressaltar a utilização apenas dos cliques de primeira ordem e o os cliques de segunda ordem nesta abordagem.

O potencial do clique de primeira ordem refere-se à penalização da discrepância entre v em relação à uma determinada classe e pode ser calculado através da função logarítmica da probabilidade condicional $P(v|\omega)$ baseada na distribuição Gaussiana:

$$P(v|\omega) = \frac{1}{\sqrt{2\pi\sigma_\omega}} \exp\left(\frac{-(v - \mu_\omega)^2}{2\sigma_\omega^2}\right) \quad (4)$$

tal que:

$$V_{c_1} = \log P(v|\omega) \quad (5)$$

onde v representa o valor do atributo do vértice v e σ e μ representam as respectivas variância e média amostral de uma classe.

Cliques de segunda ordem são chamados de *smoothness prior* e referem-se às regularidades relativas entre pares de pixels vizinhos (homogeneidade). O potencial do clique de segunda ordem é dado por:

$$V_{c_2}(i, j) = \beta \delta(\omega_i, \omega_j) = \begin{cases} -\beta s e \omega_i = \omega_j \\ +\beta s e \omega_i \neq \omega_j \end{cases} \quad (6)$$

na qual a imagem vai se tornando mais homogênea conforme β aumenta.

Finalmente, como já mencionado, a função de energia potencial pode ser calculada pela soma dos potenciais de cliques e o rótulo ótimo $\hat{\omega}$ pode ser definido através de seu ponto mínimo [6]:

$$U(\omega) = \sum_p \left(\log(\sqrt{2\pi\sigma_\omega}) \exp\left(\frac{(v - \mu_\omega)^2}{2\sigma_\omega^2}\right) \right) + \sum_{p,q} \beta \delta(\omega_p, \omega_q) \quad (7)$$

$$\hat{\omega}^{MAP} = \operatorname{argmax}_{\omega \in \Omega} P(\omega|v) = \operatorname{argmin}_{\omega \in \Omega} U(\omega) \quad (8)$$

III. AQUISIÇÃO DAS IMAGENS

Foram utilizadas 20 imagens aéreas de uma plantação de citros obtidas com VANT da Embrapa Instrumentação. Os voos foram realizados a uma altitude de 300m, com velocidade de deslocamento de 100 km/h numa área da região de Matão, SP. Foi utilizada uma câmera Sony T3i com resolução máxima de 6Mpixel.

As imagens foram obtidas próximas do meio dia com boa iluminação.



Fig. 1. Imagem obtida com VANT em uma plantação de citros.

IV. PROCESSAMENTO

Campos Aleatórios Markovianos fornecem como saída objetos segmentados pixel a pixel, onde o rótulo de cada pixel é diretamente influenciado por sua respectiva vizinhança por meio de cálculos probabilísticos. Fatores como disparidade na iluminação, altitude de voo, sombras e posicionamento da câmera podem afetar diretamente na qualidade da segmentação. Plantações com diâmetros de árvores muito grandes podem também induzir negativamente na exatidão dos resultados devido à união das folhas das copas, dificultando a

identificação de cada uma das respectivas plantas. Para solucionar este caso específico, é aplicado o operador morfológico watershed.

O operador watershed utiliza a distância geodésica por meio de suas bacias de captação, na qual cada valor do gradiente da imagem forma um relevo útil para simulação do processo de inundação. [5] Na Figura 2 é apresentada a imagem original, a segmentação por MRF e o pós-processamento por watershed.

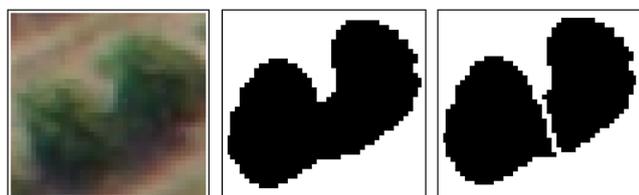


Fig. 2. Imagem apresentando copas unidas, segmentação por MRF e pós-processamento utilizando watersheds, respectivamente.

V. RESULTADOS

Imagens com texturas naturais tendem a apresentar pixels com baixo índice de homogeneidade, intensificando a complexidade do processamento e dificultando a exatidão dos resultados.

Das imagens analisadas utilizando ambas as técnicas – GMRF e Otsu, todas necessitaram de pós-processamento devido a problemas relacionados à variação na iluminação e união de copas. Particularmente, houve casos em que não foi possível generalizar os valores de média e variância para todos os elementos de uma classe utilizados para calcular a distribuição Gaussiana. Este problema ocorre devido à discrepância na intensidade de iluminação, e para solucioná-lo, utilizou-se um método de removedor de ruídos, que remove aglomerações com raio menor ou igual a 10 pixels. Em determinadas imagens, porém, a utilização do método não foi o suficiente para remover todas as excedências (amostras 12, 13, 14 e 15 da Tabela I), principalmente ao adotar a abordagem de Otsu, como pode ser visto na figura 3. Durante o processo de segmentação, sombras e os diâmetros das árvores também acabaram produzindo aglomerações nos pixels da classe que representava os pés, impossibilitando o reconhecimento individual de cada copa. Utilizou-se como pós-processamento o algoritmo watershed para minimizar os erros obtidos.

Para cada imagem, adquiriu-se o número total de copas através do método de contagem manual. Por fim, com o intuito de comparar diferentes metodologias, foram coletados os resultados de segmentação realizados por GMRF e de segmentação utilizando o método de limiarização de Otsu.

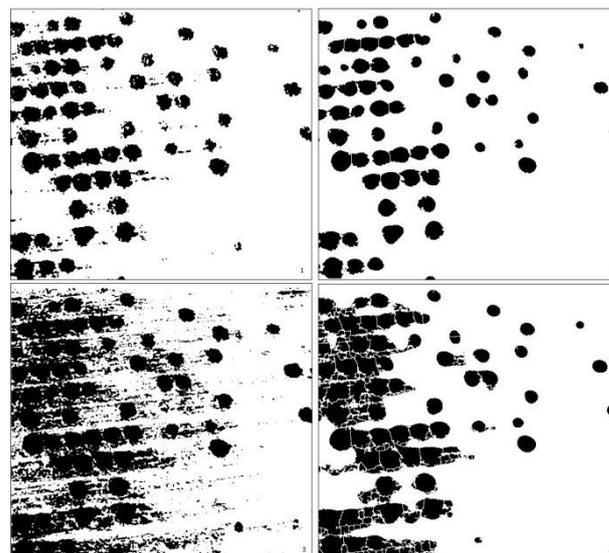


Fig. 3. Pela direita, resultados da segmentação: GMRF (cima) e Otsu (baixo). Pela esquerda, respectivas imagens resultantes após remoção de ruídos (raio de 10 pixels) e segmentação por watershed.

RESULTADOS

Amostra	Manual	GMRF	Otsu	Erro GMRF	Erro Otsu
1	93	95	114	2,2	22,6
2	1756	1701	1637	3,1	6,8
3	562	553	543	1,6	3,4
4	778	779	828	0,1	6,4
5	809	796	862	1,6	6,6
6	1032	1024	1061	0,8	2,8
7	1064	927	939	12,9	11,7
8	416	406	528	2,4	26,9
9	281	266	264	5,3	6,0
10	1277	1262	1312	1,2	2,7
11	801	790	834	1,4	4,1
12	521	864	1073	65,8	106,0
13	732	1048	1060	43,2	44,8
14	71	111	156	56,3	119,7
15	99	165	197	66,7	99,0
16	389	373	370	4,1	4,9
17	1183	1186	1200	0,3	1,4
18	979	945	1659	3,5	69,5
19	144	152	164	5,6	13,9
20	61	60	97	1,6	59,0
Erro Médio (%)				13,98	30,91

Na figura 4 pode ser observada a imagem original e o resultado final após GMRF, além do pós-processamento desempenhado pela remoção de ruídos e pelo método de watershed. Nas figuras 5 e 6 são mostrados resultados obtidos em imagens em boas e más condições.



Fig. 4. Resultados de segmentação obtidos utilizando o método GMRF.

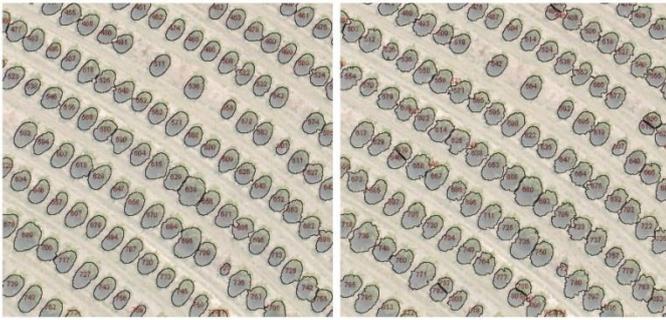


Fig. 5. Comparação entre métodos em uma imagem com boa qualidade. Na esquerda GMRF e na direita Limiarização de Otsu.

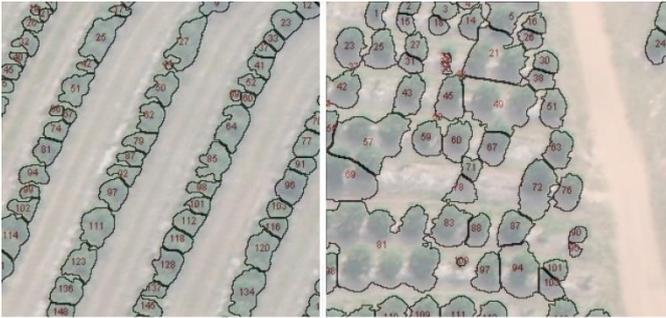


Fig. 6. Exemplos de maus resultados. Na esquerda GMRF e na direita Limiarização de Otsu. Diferentes intensidades de iluminação foram os principais fatores para aglomerações que podem ser vistas em ambas as técnicas.

VI. CONCLUSÃO

Imagens aéreas de plantações de citros obtidas por VANT foram processadas a fim de obter valores associados à produção e cultivo. Utilizou-se o método probabilístico Campos Aleatórios Markovianos baseado na distribuição Gaussiana. Algoritmos clássicos foram necessários para

realizar técnicas de pós-processamento, como o watershed, para separar união de plantas, e um removedor de ruídos, utilizado para eliminar os pixels da vegetação presente ao redor das árvores que eram classificados como parte dos pés. Conforme a tabela de resultados, o método de Campos Aleatórios Markovianos Gaussianos mostrou-se mais eficiente comparado à limiarização de Otsu (técnica amplamente utilizada para soluções que necessitam de segmentação automática) principalmente em imagens onde não há grandes discrepâncias no índice de luminosidade.

VII. AGRADECIMENTOS

Agradecemos ao apoio financeiro do projeto financeiro CNPq 403426/2013-8.

REFERÊNCIAS

- [1] Sokkarie, A. Osborne, J, "Object Counting and Sizing," Southeastcon'94, Creative Technology Transfer – A Global Affair, IEEE Trans, 1994.
- [2] Bazi, Y. Melek, S. Alajlan, N. AlHichri, H. "An Automatic Approach for Palm Tree Counting in UAV images", IGARSS, IEEE Trans. 2014.
- [3] Hung, C. Bryson, M. Sukkarieh, S. "Vision-Based Shadows-Aided Tree Crown Detection and Classification Algorithm Using Imagery from an Unmanned Airborne Vehicle" Australian Center for Field Robotics, 2006
- [4] Descombes, X. Pechersky, E. "Tree Crown Extraction Using a Three State Markov Random Field", RR-5882, 2006.
- [5] Meyer, F. "Topographic Distance and Watershed Lines" Signal Processing, vol. 38, 1994, 113 – 115.
- [6] Kato, Z. Pong, T. "Markov Random Field Image Segmentation Model for Color Textured Images", Image and Vision Computing, 2006, 1103 – 1114.
- [7] Gonzalez, R.C. Woods, R. E. "Processamento Digital de Imagens", 3ª ed., Pearson, 2009, p. 489.