# DETECÇÃO DE QUEIMADAS A PARTIR DE TÉCNICAS SEMI-AUTOMÁTICAS E OPERADORES MORFOLÓGICOS DE EROSÃO/DILATAÇÃO USANDO IMAGENS DE SENSORIAMENTO REMOTO

Daniel Capella ZANOTTA<sup>1</sup>

### Resumo

Este trabalho estuda um método semi-automático para detecção de queimadas na região do Pantanal a partir de imagens multitemporais de sensoriamento remoto. O método consiste na subtração de uma ou algumas bandas de imagens da mesma cena, mas tomadas em duas datas distintas, com posterior classificação automática a partir de um suporte Bayesiano de decisão auxiliado pelo algoritmo *Expectation Maximization* (EM), utilizado para determinar os parâmetros estatísticos das distribuições das classes consideradas como mudança e não mudança. Para obter resultados mais precisos, um operador morfológico de erosão-dilatação de imagens foi utilizado para atribuir informações de contexto espacial ao mapa de mudanças gerado pela classificação automática. Experimentos foram conduzidos para uma cena CBERS-2B, sensor CCD, com regiões atingidas por queimadas. Os resultados mostram que a acurácia é aumentada com a aplicação do contexto espacial, chegando a valores próximos a 95% de acerto quando comparados com um mapa de referência.

**Palavras-chave:** Sensoriamento remoto. Detecção de áreas queimadas. Contexto espacial. Pantanal.

#### **Abstract**

# Burned areas detection applying semi-automatic techniques and morphologic operators of erosion/dilation using remote sensing data

This work proposes a semi-automatic method to detect burned areas in the region of Pantanal from multitemporal remote sense images. The method aims at subtract the bands of two images acquired in different periods, with later classification using a Bayesian decision criteria assisted by the Expectation Maximization algorithm, in order to develop the statistical distribution parameters of the two classes considered: change and no change. To improve the process, a morphological operator based on the concepts of erosion-dilatation of digital images was used to introduce spatial context information to the map of changes generated by the automatic classification. Experiments were conducted for a CCD-CBERS-2B scene containing burned areas. The results show that the accuracy is improved with the application of the spatial context information, reaching values near 95% of success when compared with a reference map.

Key words: Remote sensing. Burnt areas detection. Spatial context contribution. Pantanal.

<sup>1</sup> Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia – UFRGS - Programa de Pós Graduação em Sensoriamento Remoto – PPGSR - Av. Bento Gonçalves, 9500 - Caixa Postal 15044 -91501-970 – Porto Alegre - RS, Brasil - E-mail: daniel.zanotta@ufrgs.br

# **INTRODUÇÃO**

Queimadas, provocadas ou acidentais, ocorrem com bastante freqüência na região do Pantanal. O Instituto Nacional de Pesquisas Espaciais (INPE) divulga dados mensais sobre a localização dos focos de queimadas para o Brasil e outros países da América do Sul com uma resolução espacial média de 28 km CPTEC (2009). A ocorrência de queimadas, principalmente nos meses caracterizados por baixas quantidades de chuva, aumenta consideravelmente, tornando difícil a tarefa de acompanhamento, delimitação precisa e controle das regiões atingidas.

Métodos de detecção automática de mudanças a partir do sensoriamento remoto têm sido largamente estudados por diversos pesquisadores nas últimas décadas com o intuito de auxiliar na produção sistemática de mapas de mudanças (FUNG, 1990, p.181; SINGH, 1989, p.989; e BRUZZONE; SERPICO, 1997, p.859). Dentre as técnicas utilizadas, a comparação por subtração de duas imagens da mesma área, mas adquiridas em tempos distintos, prevalece e serve como ponto de partida para a aplicação dos diferentes métodos propostos. Geralmente, uma ou mais bandas de interesse ou produtos como índices de vegetação são escolhidos para efetuar a subtração pixel a pixel gerando a imagem-diferença entre os dois períodos considerados. A escolha da(s) banda(s) dependerá do tipo de mudanças que se pretende detectar. A imagem-diferença resultante, em níveis de cinza, reflete não só as verdadeiras mudanças ocorridas, mas também as falsas mudanças geradas por erros no registro, mudanças aleatórias ou pequenas alterações que não são de interesse prático. A atribuição de um limiar separando a chamada classe alteração da classe não alteração se faz necessária para gerar um mapa binário de mudanças. Muitas vezes a escolha desse limiar recorre em métodos empíricos e arbitrários, diminuindo a precisão e o aspecto automático do processo.

#### **OBJETIVOS**

Neste estudo será analisado um método para detectar de maneira semi-automática os limiares de aceitação que definem as regiões que foram atingidas por queimadas, aplicando-se, posteriormente, informações de contexto espacial na classificação. Através do algoritmo *Expectation Maximization* (EM) (DUDA et al., 2001, p.525) proposto em Bruzzone e Prieto (2000, p.1175), os parâmetros das distribuições estatísticas das classes envolvidas são definidos e podem ser usados como informações de entrada em um suporte Bayesiano de classificação (DUDA et al., 2001, p.525). Valando-se do fato de existir forte correlação espacial em regiões que sofrem alterações desse tipo, neste trabalho propõe-se aplicar informações de contexto espacial através de operadores morfológicos básicos de erosão e dilatação de imagens binárias de acordo com Giardina e Dougherty (1988, p.153). Tal abordagem também se justifica pelo fato de existirem, além de erros no registro e mudanças aleatórias, grande quantidade de variações em curtos espaços de tempo na região estudada, causadas por alagamentos, avanço da vegetação, secas, quantidade de sedimento nos lagos, entre outros fatores que geram resultados com bastante ruído espacial, prejudicando a identificação das queimadas.

## MATERIAL E MÉTODOS

Duas imagens do satélite CBERS-2B sensor CCD (órbita/ponto 166/121) da região de Corumbá-MS tomadas nos dias 12/04/2009 e 20/06/2009 foram utilizadas para testar o método. A figura 1a mostra um recorte da região antes de sofrer a queimada e a figura 1b descreve a região logo após o evento. As imagens contam com 5 canais: os primeiros três na região do visível, o quarto correspondendo ao infravermelho próximo e o quinto à banda pancromática. Como as mudanças de interesse são causadas por queimadas, o canal quatro do sensor (0,77 - 0,89  $\mu$ m) foi selecionado como sendo o de maior contribuição informativa por salientar bem as áreas ocupadas por vegetação antes e depois da ocorrência dos focos de queimada. Foram aplicadas correção atmosférica e o registro das imagens, etapas imprescindíveis para a eficácia do processo de detecção.

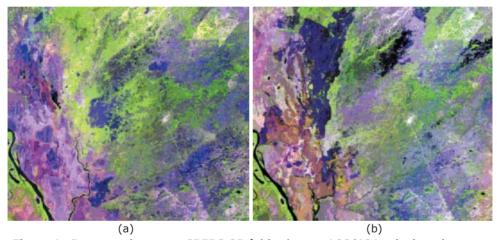


Figura 1 - Recortes das cenas CBERS-2B órbita/ponto 166/121 selecionadas para o estudo representadas através da composição 2(R) 4(G) 3(B): (a) imagem adquirida antes da queimada (12/04/2009). (b) imagem adquirida após a queimada (20/06/2009)

Após registrar e corrigir radiometricamente, as imagens foram comparadas por subtração pixel a pixel na banda quatro. Este processo resulta em uma imagem de diferenças, em níveis de cinza, salientando as mudanças ocorridas entre as duas datas consideradas. O algoritmo EM (Equações 1-4) foi empregado para definir automaticamente o limiar de separabilidade entre as classes mudança e não mudança, gerando assim, uma imagem binária com valores digitais de 255 (branco) representando as queimadas, e zero (preto) representando as regiões não afetadas por queimadas. O funcionamento do algoritmo é dividido em duas etapas: *Expectation* (Etapa 1) e *Maximization* (Etapa 2), as quais vão se alternando a cada iteração para estimar os parâmetros estatísticos [vetor de médias ( $\mu$ )] e matriz de covariâncias ( $\Sigma$ )] e as probabilidades a priori ( $P_{(\omega)}$ ) das duas classes consideradas (DUDA et al., 2001, p. 525). As informações iniciais para a operação do algoritmo são os contadores digitais da imagem de diferenças e parâmetros iniciais de  $\mu$ ,  $\Sigma$ , e  $P_{(\omega)}$  para as duas classes. O índice i representa a classe (mudança ou não mudança) e  $\theta$  a iteração em questão.

Etapa 1:

$$P(\omega_{i} \middle| x_{k}, \theta) = \frac{p(x_{k} \middle| \omega_{i}, \theta) P(\omega_{i})}{\sum_{j=1}^{c} p(x_{k} \middle| \omega_{j}, \theta) P(\omega_{j})} = \frac{\left| \sum_{j=1}^{c} p(x_{k} \middle| \omega_{j}, \theta) P(\omega_{j}) \right|}{\sum_{j=1}^{c} \left| \sum_{j} \right|^{-1/2} \exp\left[ -\frac{1}{2} (x_{k} - \mu_{i})^{t} \sum_{j=1}^{c-1} (x_{k} - \mu_{i}) \right] P(\omega_{i})}$$

$$= \frac{\left| \sum_{j=1}^{c} \left| \sum_{j} \right|^{-1/2} \exp\left[ -\frac{1}{2} (x_{k} - \mu_{j})^{t} \sum_{j=1}^{c-1} (x_{k} - \mu_{j}) \right] P(\omega_{j})}{\sum_{j=1}^{c} \left| \sum_{j} \right|^{-1/2} \exp\left[ -\frac{1}{2} (x_{k} - \mu_{j})^{t} \sum_{j=1}^{c-1} (x_{k} - \mu_{j}) \right] P(\omega_{j})}$$
(1)

Etapa 2:

$$P(\omega_i) = \frac{1}{n} \sum_{k=1}^{n} P(\omega_i \mid x_k, \theta)$$
 (2)

$$\mu_{i} = \frac{\sum_{k=1}^{n} P(\omega_{i} | x_{k}, \theta) x_{k}}{\sum_{k=1}^{n} P(\omega_{i} | x_{k}, \theta)}$$

$$(3)$$

$$\sum_{i} = \frac{\sum_{k=1}^{n} P(\omega_{i} \left| x_{k}, \theta \right) (x_{k} - \mu_{i}) (x_{k} - \mu_{i})^{t}}{\sum_{k=1}^{n} P(\omega_{i} \left| x_{k}, \theta \right)}$$

$$(4)$$

As estimativas de saída do algoritmo EM podem ser utilizadas como informações de entrada em um classificador Bayesiano (Equação 5), onde  $G_i(X)$  é a função de decisão para cada classe de alteração, p é a dimensionalidade dos dados, no caso p=2,  $\Sigma_i$  é a matriz de covariâncias,  $\mu_i$  a média,  $P(\omega_i)$  a probabilidade a priori de cada classe e X é o pixel em questão.

$$G_i(X) = (2\pi)^{-p/2} |\Sigma_i|^{-1/2} \exp[1/2(X - \mu_i)'\Sigma_i^{-1}(X - \mu_i)] P(\omega_i)$$
 (5)

Na consideração de duas classes  $\omega_{_{\! 1}}$  e  $\omega_{_{\! 2}}$  (mudança e não-mudança, respectivamente) a regra Bayesiana de decisão é dada por:

se  $G_1(X) > G_2(X)$  então:  $X \in \omega_1$  caso contrário:  $X \omega_2$ 

Para a imagem analisada, o método de detecção de mudanças retorna uma imagem binária [255,0] (255: mudança, 0: não-mudança). Esse resultado pode ser refinado com a inserção de informações de contexto espacial. Aqui foram testados os operadores morfológicos de erosão e dilatação de imagens (GIARDINA; DOUGHERTY, 1988, p.153). Os operadores funcionam de maneira aliada, onde a imagem de entrada sofre sucessivos eventos de erosão, e, após, o mesmo número de iterações do operador de dilatação. Na erosão, uma janela de dimensões *NxM* (neste caso 2x2 para permitir um bom controle de iteração para iteração) percorre todos os pixels da imagem. Se houver homogeneidade de valores dentro da janela (somente 255 ou somente 0), os pixels permanecem inalterados, mas se a janela for compreendida por valores heterogêneos (tanto 255 como 0), os contadores digitais 255 presentes na janela são substituídos por 0. Dessa forma, pequenos conjuntos de pixels com valores de 255 que se encontram isolados espacialmente na imagem, geralmente regiões que não representam queimadas. são atribuídos à classe não-mudanca.

O problema relacionado a esse método de erosão é que as áreas extensas da imagem ocupadas por valores de 255 são diminuídas a partir de sua borda, efeito causado pela erosão. Para contornar esse problema, após a aplicação do processo de erosão, um processo análogo de dilatação é aplicado na imagem. Esse procedimento funciona de forma semelhante ao processo de erosão, porém de maneira inversa. A mesma janela NxM percorre a imagem inteira e, se houver homogeneidade de valores dentro da janela (somente 255 ou somente 0), os pixels permanecem inalterados, mas se a janela for compreendida por pixels com valores tanto de 255 como 0, os valores de 0 são substituídos por valores de 255. Isso faz com que a imagem retorne a uma configuração espacial semelhante àquela encontrada imediatamente após a classificação Bayesiana, no entanto, sem a presença de pixels ruidosos, aumentando o grau de acurácia do processo.

O número de iterações sucessivas para a ação dos operadores de erosão e dilatação deve ser definido pelo processo. Um valor ótimo pode variar de acordo com o tamanho das regiões queimadas encontradas na cena. É interessante salientar que o número de iterações corresponde ao número de processos de erosão seguidos de dilatação da imagem; as iterações referentes à dilatação só iniciam uma vez terminado os processos de erosão; não devem ser realizados de forma intercalada (uma iteração de cada processo por vez).

# **RESULTADOS E DISCUSSÃO**

Com auxílio de um mapa de referência para queimadas gerado manualmente a partir de informações cedidas pela Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) (Figura 2c), as imagens produzidas pela classificação Bayesiana (Figura 2a) e pela posterior inserção das informações do contexto espacial (Figura 2b) foram analisadas e o grau de acurácia para os produtos gerados pelo processo de inserção do contexto foi calculado. A figura 2d mostra a imagem resultante circunscrita pelos limites do mapa de referência.

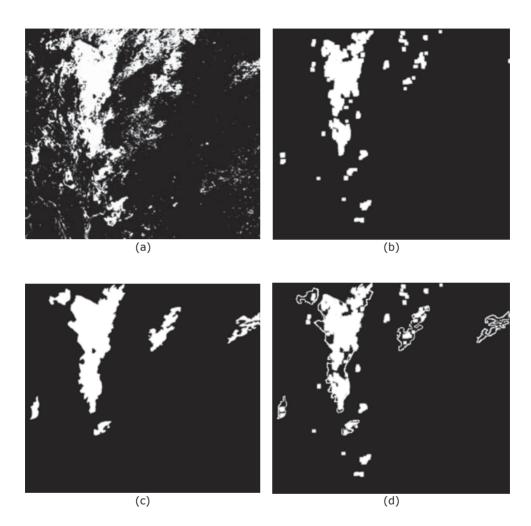


Figura 2 - Resultados encontrados com a metodologia analisada: (a) imagem classificada automaticamente a partir do algoritmo EM e classificação Bayesiana. (b) imagem classificada e tratada com informações do contexto espacial (20 iterações). (c) imagem de referência. (d) limites da imagem de referência circunscrevendo a imagem resultante da aplicação do contexto espacial

A figura 3 mostra uma curva para o percentual de acerto em função do número de iterações do operador erosão-dilatação. Com base nessa curva, podemos observar que o processo alcança uma razoável estabilidade a partir da vigésima iteração. Por essa razão, a figura 2a é o resultado da aplicação de 20 iterações.

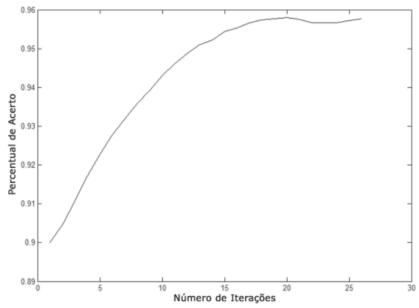


Figura 3 - Comportamento do percentual de acerto frente ao número de iterações aplicadas com os operadores de erosão-dilatação

A eficiência do processo de classificação seguido da aplicação dos operadores morfológicos de erosão-dilatação pode ser confirmada pela análise de contingência produzida a partir da imagem de referência comparada com as imagens geradas pela metodologia proposta. A tabela 1 mostra que uma redução considerável nos erros pós-classificação é alcançada com a combinação da classificação Bayesiana a partir de parâmetros estatísticos gerados automaticamente pelo algoritmo EM, seguida da aplicação de informações de contexto espacial pelo operador erosão-dilatação de imagens.

Tabela 1 - Resultados obtidos nos experimentos

Método de Detecção das Queimadas	Total de Pixels Classificados Corretamente	Total de Pixels Classificados Incorretamente	Percentual de acerto
Imagem Classificada	2119739	235234	90,0 %
Imagem Classificada + Aplicação do contexto com 20 iterações	2254902	100071	95,7 %

GEOGRAFIA

## **CONCLUSÕES**

Neste trabalho uma alternativa semi-automática para a detecção de queimadas foi proposta e testada para uma área do Pantanal. Os resultados obtidos revelam que a combinação de uma classificação Bayesiana com os operadores morfológicos de erosão seguida de dilatação apresentou resultados bastante satisfatórios na detecção de áreas atingidas por queimadas. É importante enfatizar que o número de iterações realizadas pelo processo de inserção do contexto espacial deve ser avaliado cuidadosamente. Neste trabalho comprovase que a aplicação do contexto espacial por operadores morfológicos desse tipo produz resultados satisfatórios, porém não define um método para encontrar um número ótimo de iterações para cada caso específico. Os resultados obtidos no processo erosão-dilatação mostram que a acurácia aumenta até um ponto, permanecendo estabilizada a partir de um determinado número de iterações. A tendência da curva é reduzir seu valor no eixo vertical após o período de estabilidade. Um método determinando um número ótimo de iterações deve ser elaborado e utilizado como critério de parada para o algoritmo.

Uma comparação com outros tipos de processos que visam à inserção de informações de contexto espacial pode ser realizada para confirmar a eficácia da metodologia utilizada neste trabalho. Um futuro desenvolvimento deste trabalho tem o objetivo de reunir e comparar outros métodos de inserção de informações de contexto espacial voltados para o aumento da acurácia do processo, assim como definir critérios eficientes de parada para os algoritmos.

## REFERÊNCIAS

BRUZZONE, Lorenzo.; PRIETO, Diego Fernandez. Automatic Analysis of the Difference Image for Unsupervised Change Detection. IEEE Transactions on Geoscience and Remote **Sensing**, Washington, DC, v. 38, n. 3, p. 1171-1182, 2000.

BRUZZONE, Lorenzo.; SERPICO, Sebastiano. An iterative technique for the detection of land-cover transitions in multitemporal remote-sensing images. IEEE Transactions on Geoscience and Remote Sensing, Washington, DC, v. 35, n. 4, p. 858-867, 1997.

Centro de previsão do Tempo e Estudos Climáticos CPTEC - INPE (www.cptec.inpe.br/ queimadas/) acessado em 10/08/2009.

DUDA, Richard O.; HART, Peter E.; STORK, David G., Pattern Classification, New York: John Wiley & Sons, 2001. 482 p.

FUNG, Tung. An assessment of TM imagery for land-cover change detection. IEEE Transactions on Geoscience and Remote Sensing, Washington, DC, v. 28, p. 681-684,

GIARDINA, Charles R.; DOUGHERTY, Edward R., Morphological Methods in Image and Signal Processing, Englewood Cliffs, New Jersey: Prentice-Hall, 1988. 321 p.

SINGH, Ashbindu. Digital change detection techniques using remotely-sensed data, International Journal of Remote Sensing, London, v. 6: 989-1003. 1989.