

Detecção de mudanças suave a partir de imagens de fração

Hélio Radke Bittencourt¹
Dejanira Luderitz Saldanha²

1 Pontifícia Universidade Católica do Rio Grande do Sul – PUCRS
Faculdade de Matemática, Departamento de Estatística
Av. Ipiranga, 6681 – 90619-900 – Porto Alegre – RS, Brasil
heliorb@pucrs.br

² Universidade Federal do Rio Grande do Sul – UFRGS
Programa de Pós-Graduação em Geografia – POSGEA
Av. Bento Gonçalves, 9500, Prédio 43113, SI 203, CEP: 91501-970 Porto Alegre – RS, Brasil
dejanira.saldanha@ufrgs.br

Abstract. Automatic change detection is an important challenge in multitemporal remote sensing applications. Some studies have been demonstrated that fraction images can be useful for land cover change detection because the radiometric problems are minimized and the interpretation of changes in land cover is facilitated, since the fractions have a physical meaning. Furthermore, interpretations at the subpixel level are possible. Because the sampling training is not required, unsupervised techniques are often chosen for the generation of change maps without intervention of the analyst. This work presents a soft classification procedure for detecting changes between a pair of fraction images. The technique is applied after the generation of binary change maps by a hard classifier based on Mahalanobis distance. The hard algorithm requires multivariate normality assumption for the differences among fractions, but the soft one – logistic regression – assumes nothing about the probability distribution of variables, requiring the estimation of few parameters. The soft classification allows estimating the probability of each pixel belonging to the change class; these probabilities are used to create a gradual change map. This approach was tested using a pair of synthetic images and the results were analyzed in terms of Mean Square Error (MSE). The results indicate that the soft classification have produced better results than only using the hard algorithm.

Palavras-chave: change detection, soft classification, logistic regression, synthetic images, detecção de mudanças, classificação suave, regressão logística, imagens sintéticas.

1. Introdução

A literatura científica que aborda o tema da detecção de mudanças na superfície terrestre por meio de imagens multiespectrais é extensa. No entanto, constata-se que há temas menos explorados, como, por exemplo, a utilização de imagens de fração produzidas pelo Modelo Linear de Mistura Espectral (MLME). No MLME pressupõe-se que um espectro pode ser modelado pela combinação linear de espectros puros, conhecidos por *endmembers* (Roberts et al., 1998), de forma que, conhecendo-se as respostas espectrais dos componentes puros, as proporções destes podem ser estimadas, gerando as denominadas imagens de fração (Shimabukuro e Smith, 1991).

A proposição de utilizar imagens de fração para detecção de mudanças é motivada por quatro vantagens que elas apresentam em relação às imagens multiespectrais convencionais: 1) a correção radiométrica deixa de ser um problema crítico no espaço de frações, o que ocorre quando se trabalha diretamente com a resposta espectral; 2) a interpretação dos resultados é facilitada, visto que os componentes das imagens de fração têm um significado físico direto; 3) a dimensionalidade do problema é reduzida; e 4) existe a possibilidade da análise das alterações em um nível de subpixel. Esta última vantagem é especialmente interessante em imagens como a do sensor Landsat-TM, cuja resolução espacial corresponde a um pixel de 30×30m.

Todos os algoritmos de detecção de mudanças utilizados sobre imagens de fração tendem a valer-se das três primeiras vantagens, entretanto apenas classificadores suaves ou *fuzzy* têm

a capacidade de explorar também a quarta vantagem, ou seja, a detecção em nível de subpixel. Este texto tem por objetivo apresentar uma proposta de classificador suave para detecção de mudanças com o objetivo de flexibilizar os resultados de uma classificação rígida por meio de regressão logística. O estudo é parte da tese de doutoramento de Bittencourt (2011).

2. Método

A classificação pode ser definida como uma tarefa de processamento de informação na qual entidades (ou padrões) são rotuladas em categorias gerais. No caso da classificação de imagens digitais, estas entidades geralmente são pixels e as informações são oriundas de algum sistema sensor.

A notação doravante utilizada considera $\mathbf{x}(i,j)$ um vetor de informações correspondente a um pixel, posicionado na linha i e coluna j . O conjunto de classes é denotado por Ω e as classes consideradas por ω_i . No caso de detecção de mudanças binária, $\Omega = \{\omega_c, \omega_{nc}\}$, onde ω_c representa a classe de mudanças e ω_{nc} a classe de não-mudanças.

A forma mais comum de classificação é conhecida como dura ou rígida. Nesse tipo de classificação, os limites de decisão entre as classes são bem definidos, de forma que cada pixel é atribuído a uma única classe (Ferreira, 2003). Assim, um pixel $\mathbf{x}(i,j)$, ao ser alocado à classe ω_i , exclui a possibilidade de ser alocado a qualquer outra classe ω_j ($i \neq j$).

Os métodos de classificação rígidos são divididos em dois tipos: os supervisionados e os não-supervisionados. Os métodos supervisionados requerem conhecimento prévio da área de estudo por parte do analista. Tal conhecimento permite a definição de um conjunto de classes $\Omega = \{\omega_1, \dots, \omega_k\}$ para as quais serão selecionadas amostras de treinamento como dado de entrada para algoritmos de classificação. Os métodos não-supervisionados, por sua vez, não requerem amostras de treinamento e tampouco definição prévia das classes que compõem a imagem. Os métodos não-supervisionados são quase um sinônimo de algoritmos de agrupamento ou *clustering*. Em geral, depois de escolhido o algoritmo, a única intervenção do analista dá-se na definição do número de grupos a ser criado.

Os métodos de classificação rígida podem ser, ainda, subdivididos em paramétricos e não-paramétricos. Os métodos paramétricos requerem a suposição de modelos probabilísticos subjacentes nas classes consideradas, os quais são descritos por conjuntos de parâmetros a serem estimados. Os métodos não-paramétricos, ou de distribuição livre, não fazem suposição quanto à forma funcional dos dados de entrada, ou seja, não é necessária a especificação de um modelo que descreva o comportamento probabilístico dos padrões em cada classe.

A classificação suave, conforme Cheng et al. (2006), não designa um pixel a uma classe, mas, sim, atribui a ele uma probabilidade ou grau de pertinência a uma classe de Ω . Dentre as técnicas capazes de realizar classificação suave, pode-se destacar: regressão logística, redes neurais, algoritmo *c-means fuzzy* e regressão por árvores de decisão (Cheng et al., 2006).

Este estudo combina um classificador paramétrico baseado na distância de Mahalanobis (rígido) com a técnica parcialmente paramétrica da regressão logística (suave). Do ponto de vista prático, o mesmo pode ser considerado não-supervisionado, uma vez que o usuário não necessita selecionar amostras de treinamento, pois o procedimento foi automatizado.

2.1 Detecção de mudanças rígida

Dentre os procedimentos de detecção de mudanças encontrados na literatura, técnicas baseadas na imagem de diferença são as mais comumente encontradas (Bruzzone e Prieto, 2000; Teng et al. 2008). Assuma que \mathbf{X} seja uma imagem de diferenças de fração ($\mathbf{X} = \mathbf{X}_2 - \mathbf{X}_1$) derivada de um par de imagens espectrais da mesma cena, coletadas em t_1 e t_2 .

Seguindo Bittencourt e Haertel (2011), considere também que a cena representada inclui m *endmembers*, de forma que m frações podem ser produzidas. Na geração das frações há a

suposição de que a soma dos m componentes seja unitária, o que faz com que uma das frações seja redundante. Assim sendo, apenas $v=m-1$ frações são consideradas.

Para fins estatísticos, assume-se que os componentes da imagem de diferenças \mathbf{X} sejam observações de uma variável aleatória v -dimensional normalmente distribuída (Equação 1). De acordo com Bruzzone e Serpico (1997) essa suposição é razoável em se tratando de sensores passivos.

$$p(\mathbf{x}) = (2\pi)^{-v/2} |\Sigma|^{-1/2} \exp\left[-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_x)' \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu}_x)\right] \quad (1)$$

onde $\boldsymbol{\mu}_x$ e Σ são os parâmetros da distribuição normal multivariada: vetor media e matriz covariância, respectivamente.

A densidade da distribuição normal multivariada apresenta contornos de probabilidade constante para todo \mathbf{x} , tal que, $(\mathbf{x} - \boldsymbol{\mu}_x)' \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu}_x) = c^2$ onde c é uma constante (Johnson e Wichern, 2007). Essa expressão, também conhecida como distância de Mahalanobis de \mathbf{x} em relação a $\boldsymbol{\mu}_x$, descreve a superfície de um elipsóide centrado em $\boldsymbol{\mu}_x$. Os eixos de cada elipsóide têm as direções dos autovetores de Σ^{-1} , e seus comprimentos dependem dos autovalores dessa mesma matriz. A constante c^2 , que delimita estes contornos, é definida pela distribuição Qui-quadrado com v graus de liberdade. Ao escolher $c^2 = \chi_{v,\alpha}^2$, se está definindo que o volume sob o elipsóide seja igual a $1 - \alpha$ (Equação 2),

$$P\left[(\mathbf{x} - \boldsymbol{\mu}_x)' \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu}_x) \leq \chi_{v,\alpha}^2\right] = 1 - \alpha \quad (2)$$

com $\chi_{v,\alpha}^2$ sendo o valor da distribuição Qui-quadrado com v graus de liberdade que concentra $100 \times (1 - \alpha)\%$ de área à esquerda. A Equação 3 apresenta a regra de decisão utilizada para classificação rígida:

$$\begin{aligned} \text{Se } (x - \boldsymbol{\mu}_x)' \Sigma^{-1} (x - \boldsymbol{\mu}_x) \leq \chi_{v,\alpha}^2, \text{ então } \mathbf{x} \in \omega_{nc} \\ \text{Se } (x - \boldsymbol{\mu}_x)' \Sigma^{-1} (x - \boldsymbol{\mu}_x) > \chi_{v,\alpha}^2, \text{ então } \mathbf{x} \in \omega_c. \end{aligned} \quad (3)$$

2.2 Detecção de mudanças suave

A regressão logística foi utilizada como uma maneira de flexibilizar os resultados da classificação rígida. Em sua forma tradicional, a regressão logística é uma técnica estatística que relaciona um conjunto de variáveis independentes a uma variável dependente binária (Hosmer e Lemeshow, 2000).

O principal problema da regressão logística é a necessidade de amostras de treinamento para a estimação dos parâmetros, característica de um procedimento supervisionado. Uma solução para automatizar o processo, sem necessidade de seleção de amostras de treinamento, é a utilização de uma amostra aleatória de pixels representativos de ambas as classes (ω_c e ω_{nc}) extraídos da imagem binária resultante da classificação rígida. Como a classificação proposta em 4.1 considera os pixels como entidades independentes, o número de alarmes falsos tende a ser grande. Sendo assim, sugere-se que um procedimento de filtragem seja incorporado ao processo para que pixels não representativos da classe de mudanças (ω_c) sejam eliminados, não causando distorções no processo de estimação do modelo logístico.

A regressão logística permite a estimação direta da probabilidade de ocorrência de um evento por meio da Equação 4, o que configura um procedimento de classificação suave

(Cheng et al., 2006). O modelo de regressão logística pode ser considerado um procedimento parcialmente paramétrico, pois apenas o logaritmo da razão entre a probabilidade de ocorrência e não ocorrência de um evento estão sendo modelados.

$$P(\omega_c | \mathbf{x}) = \frac{\exp(\beta_0 + \boldsymbol{\beta}' \mathbf{x})}{1 + \exp(\beta_0 + \boldsymbol{\beta}' \mathbf{x})} \quad (4)$$

onde β_0 e $\boldsymbol{\beta}' = [\beta_1, \dots, \beta_v]$ são parâmetros a serem estimados.

O modelo de regressão logística assume que a soma das probabilidades dos eventos ω_c e ω_{nc} seja unitária: $P(\omega_c) + P(\omega_{nc}) = 1$. Assim, a tarefa do modelo pode ser expressa pela Equação 5, ou seja, a probabilidade de pertencer à classe ω_c é obtida através do modelo a partir do conhecimento do vetor de diferenças de fração \mathbf{x} .

$$\mathbf{d} \rightarrow P(\omega_c | \mathbf{d}) \in [0, 1]. \quad (5)$$

Graficamente, a relação entre um componente do vetor \mathbf{x} , digamos x_i , e a probabilidade de pertencer à classe ω_c descreve o característico formato de “S” (Hosmer e Lemeshow, 2000). Como as variáveis que compõem a imagem de diferenças de frações variam no intervalo $[-1, 1]$, sendo os extremos associados à mesma classe ω_c , deve-se tomar o módulo das diferenças antes de proceder com a regressão logística (Figura 1).




Figura 1 – Exemplo da probabilidade de pertencer à classe ω_c estimada pela regressão logística

Os parâmetros do modelo de regressão logística são estimados pelo método da máxima verossimilhança. Como o sistema de equações a ser solucionado é não-linear, métodos computacionais numéricos são necessários. Neste estudo foi utilizada a função MNRFIT disponível no Matlab[®], a qual permite modelar a regressão logística binária tradicional, bem como variações que incluem a regressão logística politômica e ordinal.

O procedimento suave segue os mesmos passos do classificador rígido proposto por Bittencourt e Haertel (2011) até a classificação multivariada em ω_c ou ω_{nc} . Após a geração da imagem binária, uma amostra aleatória de pixels é selecionada para estimação dos parâmetros do modelo logístico, o qual será responsável pela suavização dos resultados. Nesta etapa, as diferenças são tomadas em módulo. O algoritmo culmina com a geração do mapa das probabilidades $P(\omega_c | |\mathbf{x}|)$.

3. Resultados

Um estudo foi conduzido sobre imagens sintéticas com o objetivo de avaliar quantitativamente o procedimento suave de detecção de mudanças. Segundo Bruzzone e Serpico (1997) dispor de informação de verdade terrestre em datas distintas pode ser uma tarefa muito difícil. Por esse motivo, estudos têm sido conduzidos com imagens sintéticas como, por exemplo, Bruzzone e Prieto (2000) e Celik (2009).

A Tabela 1 apresenta características da imagem utilizada na geração do conjunto de imagem sintética. Diferentes níveis de ruído gaussiano foram adicionados com relação sinal-ruído (SNR) variando de 5 a 15dB.

Tabela 1 – Características da imagem utilizada no experimento

<i>Tipo de imagens</i>	<i>Satélite / Sensor</i>	<i>Órbita ponto</i>	<i>Data de aquisição</i>	<i>Mudanças inseridas</i>	<i>Tipo de Ruído / SNR</i>	<i>Erro de registro</i>
Sintético	Landsat 5 – TM	221/81	03/02/2007	- Mudanças graduais - Áreas não retangulares.	Gaussiano 05 – 15dB	Não há

O experimento consistiu de um recorte de 1000×1000 pixels da cena correspondente à órbita 220, ponto 21, do sistema sensor Landsat-TM (Figura 2). De um total de sete bandas espectrais disponibilizadas, seis foram utilizadas, ficando ausente apenas a banda correspondente à faixa termal, devido à menor resolução espacial.




Figura 2 – Cena Landsat-TM correspondente à órbita-ponto 220/81 e detalhe do recorte efetivamente utilizado no experimento

A área do recorte abrange principalmente os municípios de Barra do Ribeiro e Tapes, Rio Grande do Sul. A região caracteriza-se pela presença de três unidades geomorfológicas: Planície Lagunar, Planície Litorânea Interna, Planície Alúvio-Coluvionar. Para geração das imagens de fração, três *endmembers* foram considerados – vegetação, solo exposto e água – conforme apresentado na Figura 3.




Figura 3 – Imagens de fração utilizadas no experimento: vegetação, solo exposto e água

As imagens de diferença foram criadas pela operação de subtração entre as imagens ruidosas (adicionadas das regiões de mudança) e a imagem original. A Figura 4 apresenta uma imagem de diferença contaminada por ruído gaussiano e o mapa de referência.




Figura 4 – Imagens de diferenças de fração contaminada com ruído (SNR=10dB) e mapa de referência

Este experimento contém duas regiões não retangulares de alteração e uma barra que simula uma mudança gradual nas frações de água e vegetação. A diminuição na fração de água variou de 10% até 90%, sendo o valor subtraído adicionado à fração de vegetação. A barra de mudanças gradual objetiva uma melhor avaliação do procedimento de classificação *suave*. A classificação rígida não pode representar as regiões de mudança com diferentes níveis de alteração. A classificação suave, por sua vez, tem a capacidade de representar valores intermediários entre 0 e 1.

Foi constatado no processo de estimação que as estimativas para os parâmetros da regressão logística variam bastante, indicando que a combinação entre o nível de confiança e o valor de SNR pode gerar mapas das probabilidades de mudança um tanto distintos. A Figura 5 apresenta o resultado obtido com o classificador rígido, sem filtragem, e o resultado produzido após a suavização pelo método de regressão logística para um nível de confiança de 90% e três níveis de SNR.




Figura 5 – Mapas de mudanças binários gerados pelo classificador rígido – sem filtragem – e pelo classificador suave para um nível de confiança de 90% e três diferentes níveis de ruído

O mapa de probabilidades para SNR=15dB apresentou resultado similar ao classificador rígido, no entanto é possível perceber áreas com probabilidades inferiores a 1 no caso de pequena mudanças. Para SNR=10dB parte das alterações graduais foi detectada pelo método suave, levando a um resultado muito superior ao encontrado pelo classificador rígido. Quando SNR baixou para 5dB, apenas as mudanças muito fortes foram detectadas na técnica suave. Constatou-se que a taxa de alarmes falsos foi minimizada no procedimento suave.

O conhecimento do mapa de referências possibilitou o cálculo do erro quadrático médio (MSE), proporcionando uma avaliação quantitativa dos resultados (Tabela 3).

Tabela 3 – Valores do Erro Quadrático Médio (MSE) para os mapas de mudança gerados pelos classificadores rígido e suave

$(1-\alpha)\times 100$	SNR (dB)	Classificador rígido (sem filtragem)	Classificador Suave
90	5	11,601	0,879
90	10	6,122	0,369
90	15	0,603	0,534
95	5	5,482	0,898
95	10	2,516	0,344
95	15	0,454	0,416
99	5	2,052	0,946
99	10	0,871	0,300
99	15	0,455	0,413

De uma forma geral, o classificador suave apresentou menores valores do erro quadrático para todas as combinações de níveis de confiança e SNR em comparação ao classificador rígido sem filtragem.

4. Considerações Finais

Este texto apresentou uma proposta de algoritmo suave para detecção de mudanças baseado em regressão logística. Os resultados apontam para a viabilidade da técnica, visto que os mapas de probabilidade gerados mostraram-se superiores aos mapas binários resultantes da proposta rígida. O estudo revelou que, embora a regressão logística seja um procedimento supervisionado, a utilização de resultados do classificador rígido como dado de entrada permitiu que o procedimento fosse automatizado sem a intervenção do analista. Contudo, percebeu-se certa instabilidade nas estimativas dos parâmetros conforme a escolha do nível de confiança e o nível de ruído introduzido.

Mesmo que os resultados não tenham reproduzido o mapa de mudanças original, destaca-se que os mapas de probabilidade têm a capacidade de apresentar, numa escala de cinza, níveis intermediários da probabilidade de pertencer à classe ω_c , o que seria impossível com classificadores rígidos. Essa flexibilidade mostra-se em sintonia com o conceito de pixel mistura, sob o qual se admite que mudanças possam ocorrer em nível de subpixel.

Agradecimentos

Os autores agradecem à FAPERGS (ARD 03/2012, Processo 1672/12-2) e ao CNPq, Chamada Universal 2012 (Processo 477112/2012-9).

Referências Bibliográficas

- Bruzzone, L.; Prieto, D. F. Automatic Analysis of the Difference Image for Unsupervised Change Detection, **IEEE Transaction on Geoscience and Remote Sensing**, v. 38, n. 3, p. 1171-1182, 2000.
- Bruzzone, L.; Serpico S. B. An Iterative Technique for the detection of land-cover transitions in multitemporal remote sensing images, **IEEE Transaction on Geoscience and Remote Sensing**, v. 35, n. 4, p. 858-867, 1997.
- Bittencourt, H. R. **Detecção de mudanças a partir de imagens de fração**. 2011. 113 p. Tese (Doutorado em Geografia) – Universidade Federal do Rio Grande do Sul, Porto Alegre. 2011.
- Bittencourt, H. R.; Haertel, V. Uma abordagem multivariada para detecção de mudanças a partir de imagens de fração. In: XV Simpósio Brasileiro de Sensoriamento Remoto, 2011, Curitiba. **Anais...** São José dos Campos: INPE, 2011.
- Celik, T. Unsupervised Change Detection in Satellite Images Using Principal Component Analysis and k-Means Clustering, **IEEE Geoscience and Remote Sensing Letters**, v. 6, n. 4, p. 772-776, 2009.
- Cheng, Q.; Varshney, P.; Arora, M. K. Logistic Regression for feature selection and soft classification of remote sensing data. **IEEE Geoscience and Remote Sensing Letters**, v. 3, n. 4, p. 491-494, 2006.
- Ferreira, M. E. **Análise do Modelo Linear de Mistura Espectral na Discriminação de Fitofisionomias do Parque Nacional de Brasília (Bioma Cerrado)**. 2003, 127p. Dissertação (Mestrado em Geologia) – Universidade de Brasília, Brasília, 2003.
- Hosmer, D. W.; Lemeshow, S. **Applied Logistic Regression**, 2 ed. New York: Wiley, 2000.
- Johnson, R. A.; Wichern, D. W. **Applied Multivariate Statistical Analysis**. New Jersey: Prentice-Hall, 1982.
- Roberts, D.A. et al. Mapping Chaparral in the Santa Monica Mountains using multiple endmember spectral mixture models. **Remote Sensing of Environment**, v. 65, n. 3, p. 267-279, 1998.
- Shimabukuro, Y. E.; Smith, J. A. The least-squares mixing models to generate fraction images from remote sensing multispectral data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 29, n. 1, p. 16-20, 1991.
- Teng, S.P., Chen, Y. K., Cheng, K. S., and Lo, H. C. Hypothesis-test-based landcover change detection using multi-temporal satellite images. **Advances in Space Research**, v. 41, p. 1744-1754, 2008.