

Detecção de mudanças a partir de imagens de fração: uma abordagem *fuzzy* empregando o conceito de pixel mistura

Hélio Radke Bittencourt ¹
Vitor Haertel ²

¹ Programa de Pós-Graduação em Geografia – POSGEA/UFRGS
Pontifícia Universidade Católica do Rio Grande do Sul – PUCRS/FAMAT
Av. Ipiranga, 6681 – 90619-900 – Porto Alegre – RS, Brasil
heliorb@pucrs.br

² Universidade Federal do Rio Grande do Sul – UFRGS
Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia – CEPSSRM
Caixa Postal 15052 – 91501-970 – Porto Alegre – RS, Brasil
victor.haertel@ufrgs.br

Abstract: It is well known that the concept of mixed pixels allows the interpretation digital images at sub-pixel level. This is the rationale behind the generation of fraction images. Under this concept, a novel approach to detect changes in multitemporal remote sensing image data is proposed in this paper. Fraction images are initially produced for each multitemporal image data set, as the proposed approach is based on the temporal changes that occur in the fractions at every pixel, i.e., the proposed analysis is performed at a sub-pixel level. In the fraction-change space, two distributions are estimated, one to model the fractions that have not changed between the two dates and a second to model the fractions that have changed. The proposed approach based on changes at sub-pixel level, implements a fuzzy-like classification approach, allowing the definition of a continuum of degrees in change, eliminating the need for setting thresholds to separate change from no change classes. Initial results obtained on two Landsat TM images covering an area located in north of Brazil are presented and discussed.

Palavras-chave: change detection, fraction images, mixed pixels, detecção de mudanças, imagens de fração, pixel mistura.

1. Introdução

A detecção de mudanças em imagens digitais em conjuntos de imagens multitemporais cobrindo uma mesma cena tem atraído o interesse de diferentes áreas do conhecimento, dentre as quais se destaca o Sensoriamento Remoto. Bazi et al. (2005) consideram a detecção de mudanças ocorridas na superfície terrestre por meio de uma seqüência de imagens multitemporais uma das mais importantes aplicações da tecnologia de sensoriamento remoto.

Um vasto número de textos sobre detecção de mudanças pode ser encontrado na literatura especializada. Singh (1989) apresenta uma importante revisão sobre o assunto, classificando as técnicas existentes até então em dez categorias. Mas (1999) faz uma comparação entre seis procedimentos. Mais recentemente, Radke et al. (2005) publicam uma vasta revisão dos algoritmos de detecção de mudanças mostrando tratar-se de uma área de pesquisa bastante ativa e de interesse crescente.

Bovolo e Bruzzone (2007) destacam o uso de abordagens não supervisionadas em aplicações relacionadas à detecção de mudanças multitemporais e apresentam uma análise do vetor de mudanças no domínio polar. Bovolo et al. (2008) apresentam uma abordagem não supervisionada bastante complexa fazendo uso de *support vector machine*.

Uma abordagem usual consiste em trabalhar com a imagem de diferenças entre os momentos $t=1$ e $t=2$, denotada por $D=I_1-I_2$. A escolha do limiar τ de forma que um pixel seja alocado na classe de mudanças se $|D(x,y)| > \tau$ é um problema recorrente. Muitas vezes a escolha de τ se dá de forma empírica, embora existam procedimentos automáticos como a

proposta de Bruzzone e Prieto (2000). De uma forma geral, procedimentos com pouca ou nenhuma intervenção do analista são desejáveis.

Apesar da vasta literatura sobre o tema, o conceito de pixel mistura e o uso de imagens de fração na detecção de mudanças ainda são incipientes. Haertel et al. (2004) utilizaram algoritmos de agrupamento (*cluster*) para determinação das classes de mudanças a partir da imagem de diferenças derivadas das frações de vegetação, solo e sombra. Bittencourt e Haertel (2008) apresentam uma abordagem *bayesiana* iterativa complexa onde os resultados encontrados foram similares aos de Haertel et al. (2004).

No presente trabalho é proposta uma nova abordagem para o problema com base na estimação das distribuições das mudanças temporais que ocorrem entre imagens coletadas em diferentes datas. A análise é desenvolvida em nível de sub-pixel dentro de um critério *bayesiano* que elimina a necessidade de definição de limiares na tomada de decisão sobre onde ocorreram mudanças.

2. Metodologia

A abordagem proposta baseia-se na detecção de alterações a partir de imagens de fração. Neste estudo foi utilizado o Modelo Linear de Mistura Espectral (MLME) (Shimabukuro e Smith, 1991). O MLME consiste em um sistema de equações lineares relacionando a resposta espectral do pixel com as respostas das classes componentes consideradas (*endmembers*) e das frações ocupadas por cada componente no pixel, conforme a Equação 1.

$$R_k = \sum_{j=1}^m r_{j,k} f_j + v_k \quad (k = 1, \dots, p) \quad (1)$$

onde, R_k representa a resposta espectral de um pixel na banda espectral k , $r_{j,k}$ a resposta espectral do j -ésimo componente na banda espectral k , f_j a fração da área total do pixel ocupada pelo componente j , m o número componentes considerados, v_k o valor do erro residual em para a banda espectral k e p o número de bandas espectrais. As respostas espectrais R_k e $r_{j,k}$ podem ser expressas em termos de reflectância espectral, radiância espectral ou número digital (Haertel e Shimabukuro, 2005).

Empregando o MLME, imagens de fração podem ser estimadas para cada componente individual em cada data. Por subtração pode-se produzir, para cada uma das componentes, imagens mostrando as diferenças entre os valores das frações ocorridas entre as duas datas. A análise proposta neste estudo é desenvolvida com base nas mudanças ocorridas nas frações associadas às componentes, isto é, no espaço denominado por Haertel et al. (2004) de “espaço das diferenças entre as frações”. Na abordagem proposta por aqueles autores, a detecção de mudanças ocorridas entre duas datas é realizada no espaço de diferenças de frações empregando algoritmos de *clustering*. Neste estudo é proposta uma abordagem *bayesiana* que permite detectar mudanças a nível de sub-pixel permitindo a implementação de critérios do tipo *fuzzy*, eliminando, desta forma, a necessidade de definição de duas classes mutuamente excludentes (mudança, não-mudança).

Na implementação deste estudo foram selecionadas três componentes a serem consideradas na geração das imagens fração: vegetação, solo exposto e sombra. Tratando-se de cenas naturais é comum a extração destas componentes. Como a terceira componente (sombra) pode ser escrita como combinação linear das anteriores, ao menos de uma pequena diferença devida ao resíduo v_k , o problema fica reduzida ao \mathfrak{R}^2 .

No espaço das diferenças entre as frações é esperado um alto grau de correlação negativa entre as variações das frações vegetação e solo exposto. Pixels que não sofreram alteração entre as duas datas tendem a ocupar a região central do diagrama de dispersão, enquanto pixels que sofreram alterações tendem a deslocar-se para uma das duas extremidades,

denotando aumento na fração vegetação e um correspondente decréscimo na fração solo ou o oposto.

O primeiro autovetor da matriz de covariâncias do conjunto de dados ilustra claramente a direção em que ocorrem as variações temporais nas frações vegetação e solo. Desta forma, o autovalor (λ_1) associado a este autovetor pode ser interpretado como a variância associada ao conjunto das mudanças temporais, estimadas pelas diferenças entre as frações vegetação e solo, isto é, a variância da classe “mudança” (ω_1). O segundo autovetor é ortogonal ao primeiro, definindo, portanto, a direção no espaço das diferenças entre as frações ao longo da qual não ocorreram alterações. Desta forma, uma interpretação pode ser atribuída ao autovalor associado (λ_2). Este autovalor estima a variância dos dados (diferenças entre as frações) associada à classe “não-mudança” (ω_2). Esta variância responde pelas diferenças residuais causadas por influências da atmosfera, problemas de registro, iluminação, entre outras.

Estas duas interpretações para os autovetores e autovalores derivados da matriz de covariância no espaço de diferenças de fração permitem, então, estimar as funções densidade de probabilidade associadas às classes ω_1 e ω_2 . Será feita a suposição de que o modelo subjacente é gaussiano em ambas as classes.

Por razões de conveniência computacional as diferenças entre as frações foram re-escaladas para o formato *byte* [0-255], com a origem (zero mudança) no ponto (127,5 – 127,5). Os vetores média das duas distribuições Normais bivariadas são estimados conforme mostra a Equação 2, onde \bar{D}_X e \bar{D}_Y representam as médias ocorridas nas diferenças de frações vegetação (X) e solo exposto (Y).

$$\hat{\mu}_1 = \begin{bmatrix} \bar{D}_X \\ \bar{D}_Y \end{bmatrix}, \quad \hat{\mu}_2 = \begin{bmatrix} 127,5 \\ 127,5 \end{bmatrix} \quad (2)$$

A matriz covariância da classe ω_1 é estimada diretamente a partir do conjunto de dados, enquanto em ω_2 a condição de não haver correlação entre as frações é imposta (Equação 3).

$$\hat{\Sigma}_1 = \begin{bmatrix} s_{D_X}^2 & s_{D_X D_Y} \\ s_{D_X D_Y} & s_{D_Y}^2 \end{bmatrix}, \quad \hat{\Sigma}_2 = \begin{bmatrix} \lambda_2 & 0 \\ 0 & \lambda_2 \end{bmatrix} \quad (3)$$

Uma vez estimados os parâmetros para as duas distribuições, estes valores podem ser utilizados na estimação do grau de pertinência de cada pixel às classes ω_1 e ω_2 , em uma abordagem sililar à empregada no conceito de classificação *fuzzy*. Os graus de pertinência a cada uma das duas classes são aqui interpretados como o grau de mudança ocorrida no pixel. Esta é uma vantagem na abordagem proposta, em nível de sub-pixel, removendo a dificuldade inerente aos processos que vem sendo propostos na literatura que consiste na necessidade de definir-se um limiar entre as duas classes (mudança, não-mudança).

Os graus de pertinência são aqui calculados pela Equação 4 (Wang, 1990):

$$w_i = \frac{G_i(\mathbf{x})}{\sum_{i=1}^2 G_i(\mathbf{x})} \quad i=1, 2 \quad (4)$$

onde w_i representa o grau de pertinência do pixel \mathbf{x} à classe ω_i e $G_i(\mathbf{x})$ representa o valor da função densidade da distribuição normal bivariada em \mathbf{x} .

3. Resultados experimentais

A metodologia proposta foi testada sobre imagens do satélite Landsat, sensor TM, referentes aos anos de 1991 e 1994 cobrindo uma área do norte do Brasil próxima da fronteira com a Venezuela e Guyana. Ambas as imagens foram radiometricamente normalizadas e retificadas, além de terem sido registradas. A Figura 1 apresenta a área de estudo e a Figura 2 as imagens.

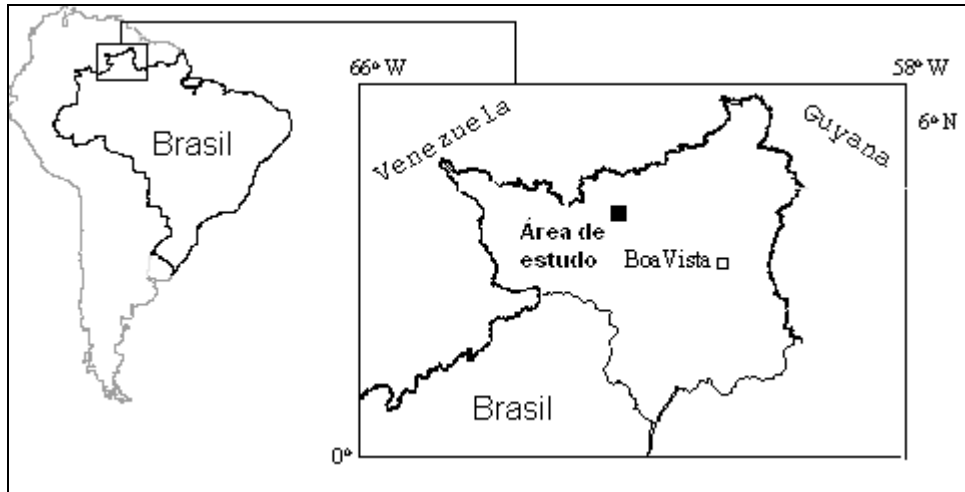


Figura 1 – Localização da área de estudo




Figura 2 – Imagens Landsat-TM da área de estudo em 1991 e 1994 respectivamente. Composições coloridas em cores naturais.

A região de estudo compreende uma região com duas áreas bem distintas: a primeira localizada numa região de baixa elevação coberta pela floresta amazônica, a segunda localizada numa região mais elevada conhecida como Platô Tepequem. Uma descrição mais detalhada da região de estudo pode ser obtida em Haertel et al. (2004).

Embora as três componentes de fração tenham sido extraídas da imagem original, apenas as frações de vegetação e solo foram consideradas, conforme já mencionado na seção 2. Como as duas imagens foram adquiridas sob altos níveis de elevação solar e o terreno não apresenta altos níveis de elevação, os efeitos de sombra são baixos. Esse fato corrobora para a opção de exclusão desta componente.

Assim, como era esperado, as frações de vegetação e solo se mostraram inversamente correlacionadas conforme mostra a Figura 3. A extração dos autovalores e autovetores associados a Σ mostram que 77,3% da variabilidade presente nos dados ocorre na direção do primeiro autovetor da matriz covariância ($\lambda_1=225,37$). O segundo autovalor ($\lambda_2=66,11$) consiste do principal dado de entrada deste estudo, pois é utilizado como estimativa da variância natural presente nos dados, sendo utilizado na definição dos parâmetros da função densidade associada a ω_2 . As Equações 5 e 6 mostram as funções densidade de probabilidade gaussianas associadas às classes ω_1 e ω_2 (com mudança e sem mudança, respectivamente).

$$G_i(x) = (2\pi)^{-1} |\hat{\Sigma}_i|^{-1/2} \exp\left[-\frac{1}{2}(x - \hat{\mu}_i)' \hat{\Sigma}_i^{-1} (x - \hat{\mu}_i)\right] \quad i=1, 2 \quad (5)$$

com parâmetros

$$\hat{\mu}_1 = \begin{bmatrix} 123,99 \\ 131,61 \end{bmatrix}, \hat{\Sigma}_1 = \begin{bmatrix} 165,48 & -77,15 \\ -77,15 & 126,00 \end{bmatrix} \quad \hat{\mu}_2 = \begin{bmatrix} 127,5 \\ 127,5 \end{bmatrix}, \hat{\Sigma}_2 = \begin{bmatrix} 225,37 & 0 \\ 0 & 66,11 \end{bmatrix} \quad (6)$$

As duas classes apresentam vetores média muito próximos, entretanto as matrizes covariância são completamente diferentes. Por essa razão a classificação depende fortemente da estatística de segunda ordem.




Figura 3 – Diagrama de dispersão entre diferenças nas frações de vegetação (D_X) e solo exposto (D_Y) e histograma bidimensional

Contrariando técnicas convencionais, os pixels não foram rotulados em uma das classes ω_1 e ω_2 , mas sim os graus de pertinência foram calculados. Em se tratando de apenas duas classes, os graus de pertinência são complementares (ver Equação 4). Optou-se, portanto, pela interpretação do grau de pertencimento a classe ω_1 (com mudança). A Figura 4 mostra, na cor preta, alterações no pixel que excederam o limite de 70%. Nessas regiões ocorreram atividades de desmatamento e/ou mineração, sendo muito semelhantes às regiões encontradas por Haertel et al. (2004).

Visualizando as Figuras 2 e 4 pode-se perceber que diferenças entre as imagens ocasionadas pela cobertura de nuvens não foram captadas pela técnica. Isso pode ser visto como uma vantagem, principalmente se considerarmos que este tipo de mudança geralmente não é de interesse do pesquisador. Outras imagens com diferentes percentuais de mudança foram produzidas, entretanto optou-se pela inclusão de apenas uma neste texto.




Figura 4 – Imagem de mudança obtida a partir da técnica proposta destacando pixels com nível de alteração superior a 70%

4. Conclusões e Recomendações

Neste estudo é proposta uma nova metodologia para detecção de mudanças baseada no conceito de pixel mistura. Esta metodologia permite abordar o problema da detecção de alterações em conjuntos de imagens multitemporais em um nível de sub-pixel. Desta forma é possível detectar-se mudanças ocorridas dentro de um *continuum*, sem a necessidade de estimar-se um limiar entre as duas condições (mudança, não-mudança). Os testes iniciais aplicando esta metodologia mostram resultados encorajadores. Tratando-se aqui de uma metodologia ainda em fase de desenvolvimento, estudos adicionais necessitam ser efetivados para um melhor entendimento do processo de mudanças em imagens multitemporais.

Agradecimentos

Este trabalho é apoiado pelo CNPq, Edital Universal, processo # 473560/2006-2. Os autores agradecem ao pesquisador Raimundo Almeida-Filho do Instituto Nacional de Pesquisas Espaciais – INPE pelas imagens.

Referências

Bazi, Y.; Bruzzone, L.; Melgani, F. An unsupervised approach based on the generalized Gaussian model to automatic change detection in multitemporal SAR images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 43, n. 4, 2005.

Bittencourt, H. R.; Haertel, V. Uso de Imagens de Fração na detecção de mudanças. In: XIII Simposio Latinoamericano de Percepción Remota, 2008, **Memorias...** La Habana, Cuba, 2008.

- Bovolo, F. E.; Bruzzone, L. A Theoretical Framework for Unsupervised Change Detection Based on Change Vector Analysis in the Polar Domain. **IEEE Transactions on Geoscience and Remote Sensing**, v. 45, n. 1, pp. 218-236, 2007.
- Bovolo, F. E.; Bruzzone, L. Marconcini, M. A Novel Approach to Unsupervised Change Detection Based on a Semisupervised SVM and a Similarity Measure. **IEEE Transactions on Geoscience and Remote Sensing**, v. 46, n. 7, pp. 2070-2082, 2008.
- Bruzzone, L. E.; Prieto, D. F. Automatic Analysis of the Difference Image for Unsupervised Change Detection, **IEEE Transaction on Geoscience and Remote Sensing**, vol. 38, no. 3, pp. 1171-1182, May 2000.
- Haertel, V., Shimabukuro, Y. E., And Almeida-Filho, R., Fraction Images in Multitemporal Change Detection, **International Journal of Remote Sensing**, v. 25, n.. 23, pp. 5473-5489, 2004.
- Haertel, V.; Shimabukuru, Y. E. Spectral Linear Mixing Model in Low Spatial Resolution Image Data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 43, n. 11, pp. 2555-2562, 2005.
- Mas, J. F. Monitoring land-cover changes: a comparison of change detection techniques. **International Journal of Remote Sensing**, v. 20, n. 1, pp. 139-152, 1999.
- Radke, R. J.; Andra, S.; Al-Kofahi, O.; Roysam, B. Image Change Detection Algorithms : a systematic survey. **IEEE Transactions on Image Processing**, v. 14, n. 3, 2005.
- Shimabukuru, 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, pp. 16-20, 1991.
- Singh, A. Digital Change Detection techniques using remotely-sensed data. **International Journal of Remote Sensing**, v. 10, n. 6, pp. 989-1003, 1989.
- Wang, F. Fuzzy supervised classification for remote sensing images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 28, n. 2, pp. 194-302, 1990.