

Uma abordagem multivariada para detecção de mudanças a partir de imagens de fração

Hélio Radke Bittencourt¹
Vitor Haertel²

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@puccrs.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. Land cover change detection is a major goal in multitemporal remote sensing applications. It is well known that images acquired on different dates tend to be highly influenced by radiometric differences and registration problems. Using fraction images, obtained from the linear model of spectral mixing (LMSM), radiometric problems can be minimized and the interpretation of changes in land cover is facilitated because the fractions have a physical meaning. This paper explores a multivariate approach to change detection problems between a pair of fraction images that allows the definition of a probabilistic threshold for labeling pixels into class change. The algorithm creates a binary change map which can be combined with the differences in the fractions. By using a clustering algorithm it is possible to create a new map that identifies the kinds of change. The algorithm is simple and fast and does not require the choice of components since all fractions are used simultaneously. It is required that the differences of fractions are multivariate normal because the technique is based on the fact that the contours of constant density are limited by chi-square distribution, according to the choice of level of significance. The results, obtained on synthetic images, indicate that the procedure is efficient.

Palavras-chave: change detection, image processing, fraction images, detecção de mudanças, processamento de imagens, imagens de fração.

1. Introdução

A detecção automática de alterações entre imagens digitais tem atraído atenção em diferentes campos de estudo, incluindo o monitoramento de câmeras de vídeo, diagnóstico médico, infra-estrutura civil e sensoriamento remoto. Apesar de existir diferenças entre as áreas de aplicação, pesquisadores tendem a utilizar metodologia e algoritmos similares (Radke et al., 2005). Dentre as aplicações de sensoriamento remoto, destacam-se o monitoramento de queimadas, a avaliação de desastres naturais, análise de expansão urbana e o monitoramento de áreas cultivadas.

A maior parte dos procedimentos de detecção de mudanças sugerido na literatura é baseada na imagem de diferenças (Bruzzone e Prieto, 2000; Celik, 2009; Teng et al. 2008), ou seja, na subtração entre duas imagens da mesma cena coletadas em diferentes datas, t_1 e t_2 . Sob a hipótese de que apenas uma pequena área correspondente à imagem sofre alterações de t_2 em relação à t_1 , mudanças poderão ser detectadas nas caudas da função densidade de probabilidade associada à imagem de diferença (Bruzzone e Serpico, 1997). O problema que surge é a definição de um limiar para separação entre as classes mudança (ω_c) e não-mudança (ω_{nc}).

Uma variedade de técnicas de detecção de mudanças pode ser encontrada na literatura especializada (Singh, 1989; Radke et al., 2005), mas poucos estudos têm sido relatados empregando imagens de fração e de procedimentos multivariados. Dentre as poucas aplicações de imagens de fração, destaca-se o uso de algoritmos de agrupamento (Haertel et al., 2004), árvores de decisão (Lu et al., 2004) e abordagem *fuzzy* baseada no algoritmo *Expectation Maximization* (Bittencourt e Haertel, 2009; Zanotta e Haertel, 2010).

Técnicas que simplesmente rotulam pixels às classes ω_c e ω_{nc} são muito mais numerosas do que aquelas que procuram identificar o tipo de mudanças ocorrida na superfície terrestre. A Análise do Vetor de Mudanças (CVA) é uma das poucas que permite a identificação da natureza das mudanças num espaço de coordenadas polares (Malila, 1980; Michalek et al., 1993; Bovolo e Bruzzone, 2007).

Este texto tem por objetivo propor e testar um procedimento multivariado para detecção de mudanças a partir de duas imagens de fração extraídas de um par de imagens espectrais coletadas em t_1 e t_2 . A técnica cria dois mapas a partir da imagem de diferenças de fração: um mapa binário identificando pixels associados à classe ω_c e um mapa da natureza das mudanças gerado a partir de uma análise de agrupamento combinada com o mapa binário. O uso de imagens de fração para detecção de mudanças foi motivado por três vantagens que, ao menos teoricamente, elas apresentam sobre as tradicionais imagens espectrais: a) minimizam problemas radiométricos; b) permitem uma interpretação mais simples dos resultados e c) possibilitam interpretação ao nível de sub-pixel. Neste estudo, apenas as duas primeiras vantagens são exploradas.

2. Métodos

A abordagem proposta neste texto consiste de um conjunto de etapas cuja sequência é apresentada na Figura 1. As etapas são detalhadas nas subseções a seguir.

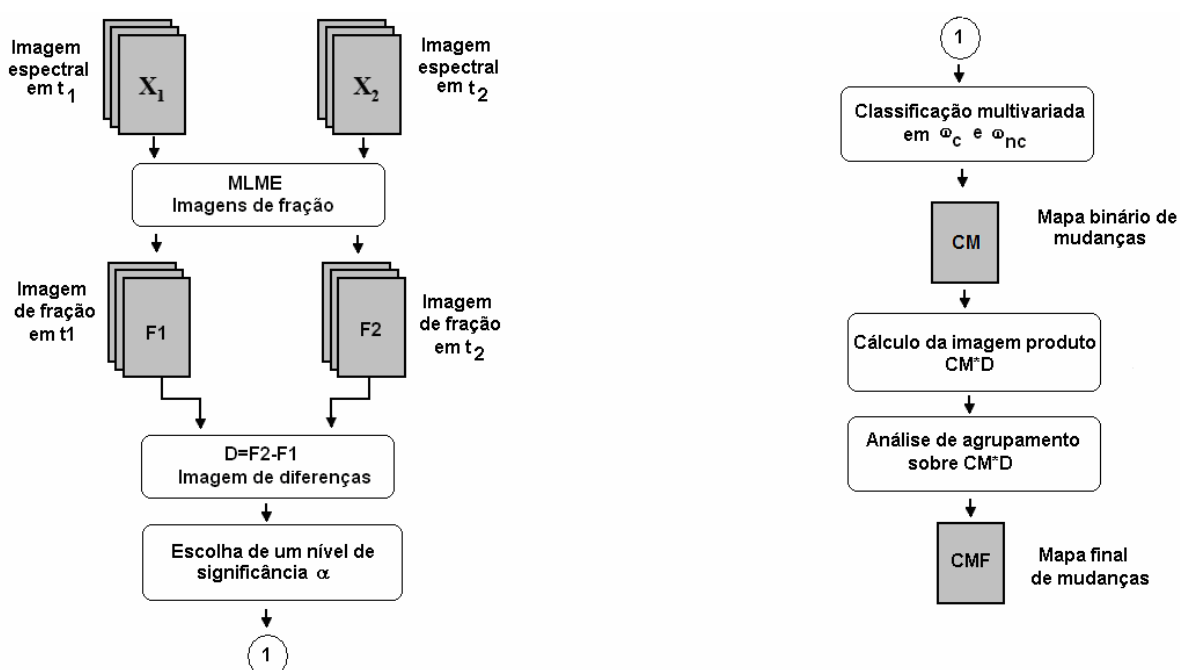


Figura 1 – Fluxograma do procedimento de detecção de mudanças descrito neste texto

2.1 Imagens de Fração

A geração das imagens de fração inicia com a seleção de um conjunto de *endmembers* representativos da cena em consideração. Depois da seleção dos *endmembers*, as proporções dos componentes em cada pixel da imagem são estimadas por meio do Modelo Linear de Mistura Espectral (Shimabukuro e Smith, 1991; Haertel e Shimabukuro, 2005).

O modelo linear para o pixel $\mathbf{x}(i,j)$ é expresso pela Equação 1:

$$\mathbf{R}_{i,j} = \mathbf{S}_{i,j} \mathbf{F}_{i,j} + \mathbf{V}_{i,j} \quad \begin{matrix} i = 1, 2, \dots, I \\ j = 1, 2, \dots, J \end{matrix} \quad (1)$$

$(p \times 1) \quad (p \times m) \quad (m \times 1) \quad (p \times 1)$

onde \mathbf{R} é um vetor com a resposta espectral de um pixel nas p bandas, \mathbf{S} é uma matriz cujos elementos representam a resposta espectral do *endmember* ($e=1,2, \dots, m$) na banda espectral k ($k=1, 2, \dots, p$), \mathbf{F} é um vetor com as frações desconhecidas, \mathbf{V} um vetor de resíduos e $N=I*J$ representa o total de pixels da imagem. Na prática, $p > m$ e o sistema (1) pode ser resolvido por mínimos quadrados sujeitos as seguintes restrições (Equação 2):

$$0 \leq f_{ije} \leq 1 \quad \forall i, j, e \quad e \quad \sum_{e=1}^m f_e = 1 \quad (2)$$

O m -ésimo componente pode ser obtido por subtração de forma que apenas $v=m-1$ frações são utilizadas. Neste estudo faz-se necessária a inversão da matriz covariância no espaço de diferença de frações. A utilização de todos os m componentes tornaria a mesma singular, impossibilitando a inversão.

2.2 Detecção de mudanças a partir das imagens de fração

Seja \mathbf{X} uma imagem formada por N pixels. Assuma que a cena representada em \mathbf{X} inclui m *endmembers* de forma que m frações podem ser produzidas a partir de \mathbf{X} . Agora considere \mathbf{F} uma imagem formada por tais frações. Suponha, também, que existam duas imagens da mesma cena devidamente registradas (\mathbf{X}_1 e \mathbf{X}_2), coletadas em duas diferentes datas (t_1 e t_2), as quais produziram duas imagens de fração (\mathbf{F}_1 e \mathbf{F}_2), cuja diferença $\mathbf{F}_2 - \mathbf{F}_1$ é denotada por \mathbf{D} .

Assumindo que as diferenças em \mathbf{D} , excluindo o m -ésimo componente, são observações de uma variável aleatória v -dimensional normalmente distribuída (Equação 3).

$$p(\mathbf{d}) = (2\pi)^{-v/2} |\Sigma|^{-1/2} \exp\left[-\frac{1}{2}(\mathbf{d} - \boldsymbol{\mu}_d)' \Sigma^{-1} (\mathbf{d} - \boldsymbol{\mu}_d)\right] \quad (3)$$

onde $\boldsymbol{\mu}_d$ e Σ são os parâmetros vetor media e matriz covariância, respectivamente.

Por fim, assumo que $\Omega = \{\omega_c, \omega_{nc}\}$ é um conjunto exaustivo de classes associadas aos pixels da imagem. A classe ω_c representa pixels que sofreram alterações de t_1 para t_2 e ω_{nc} pixels que não se alteraram. Seja \mathbf{CM} um mapa de mudanças binário que indica a qual classe os pixels em \mathbf{D} são associados (Equação 4):

$$\mathbf{CM}(i, j) = \begin{cases} 0, & \mathbf{d}(i, j) \in \omega_{nc} \\ 1, & \mathbf{d}(i, j) \in \omega_c \end{cases} \quad (4)$$

Assumindo a presença de um ruído de magnitude inferior às reais mudanças de t_1 para t_2 , e sob a hipótese de que poucas mudanças ocorrem entre as datas (Bruzzone e Serpico, 1997), a função densidade da diferença de frações deverá mostrar que pixels associados à classe ω_c estão localizados nas caudas da distribuição. Considerando a suposição de normalidade

apresentada na Equação 3, os contornos de probabilidade constante da função densidade podem ser descritos pela Equação (5):

$$(\mathbf{d} - \boldsymbol{\mu}_d)' \boldsymbol{\Sigma}^{-1} (\mathbf{d} - \boldsymbol{\mu}_d) \leq \chi_{v,\alpha}^2 \quad (5)$$

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 (Teng et al, 2008; Johnson e Wichern, 1982). A elipse, elipsóide ou hiper-elipsóide de \mathbf{d} que satisfaz a Equação 5 contém $(1 - \alpha)$ da área total sob a normal multivariada com parâmetros $\boldsymbol{\mu}_d$ e $\boldsymbol{\Sigma}$.

O conceito para rotular os pixels às classes ω_t ou ω_{nc} no qual este estudo está baseado está relacionado à teoria de teste de hipóteses e foi inspirado em Teng et al. (2008). A região interna do contorno de densidade constante é associada à aceitação de H_0 : sem mudanças. Isso significa que pixels localizados nessa região serão associados à ω_{nc} e pixels fora dessa região indicarão que o pixel deva ser rotulado como ω_t .

A abordagem para construção do mapa de mudanças binário **CM** é computacionalmente simples e rápida, exigindo apenas que o pesquisador escolha um nível de significância α . Deve-se ter atenção na escolha do nível de significância, pois um valor alto (e.g. 10%) pode gerar um grande número de falsos alarmes, também conhecidos como Erro do tipo I. Por outro lado, a escolha de um nível muito baixo (e.g. 0,1%) pode deixar de detectar muitas mudanças importantes, gerando alarmes perdidos (Erro do Tipo II). Valores típicos para α são: 5%, 1% e 0,27%.

2.3 Descrição do conjunto de dados

Um conjunto de dados foi utilizado para avaliação da abordagem proposta. Consiste de uma imagem real fracionada em três *endmembers* (vegetação, solo exposto e água), gerando a imagem de fração \mathbf{F}_1 . Uma cópia de \mathbf{F}_1 foi criada introduzindo cinco regiões de mudança, conforme mostra a Figura 2. Diferentes níveis de ruído gaussiano também foram introduzidos sobre esta cópia.




Figura 2 – Conjunto de imagens de fração utilizado no primeiro experimento. Frações originais de vegetação, solo exposto e água (a)-(c); frações com as alterações + ruído gaussiano 20dB (d)-(f) e o mapa de referência (g).

A medida da intensidade do sinal em relação ao ruído entre a imagem de diferenças original \mathbf{D} e sua cópia ruidosa \mathbf{D}' foi definida de acordo com a medida S-N-R (*Signal-to-Noise-Ratio*) calculada pela Equação (6).

$$\text{SNR} = 10 \log_{10} \left(\frac{\text{tr}(\Sigma_{\mathbf{D}})}{\text{tr}(\Sigma_{\mathbf{D}-\mathbf{D}'})} \right) \quad (6)$$

2.4 Indicadores de desempenho

Experimentos que utilizam dados sintéticos permitem uma avaliação detalhada do desempenho do classificador, pois o verdadeiro mapa de mudanças é conhecido. A Tabela 1 apresenta a típica tabulação cruzada entre os resultados de um classificador binário e o mapa de referência.

Tabela 1 – Clássica matriz de confusão para avaliação de algoritmos de detecção de mudanças

Classe predita	Verdade terrestre / Mapa de referência	
	ω_t or +	ω_{nc} or –
ω_t or +	a	b
ω_{nc} or –	c	d

As seguintes medidas quantitativas foram utilizadas para avaliação da proposta:

- Acurácia (τ): definida como a proporção geral de pixels corretamente classificados.
- Coefficiente de concordância de *Kappa* (k): uma medida do grau de concordância proposta por Cohen (1960) e amplamente utilizada em aplicações de processamento de imagens (Congalton, 1991). O coeficiente k é uma espécie de acurácia que desconsidera a probabilidade de acerto casual.
- Taxa de Falsos Alarmes (FA): a razão entre o número de pixels que não sofreram mudanças, mas que foram classificados como ω_t .
- Taxa de detecção (DR): a razão entre o número de pixels positivos corretamente classificados como ω_t .

A Equação 7 apresenta os cálculos das medidas quantitativas para avaliação do desempenho.

$$k = \frac{p_e - p_o}{1 - p_o}, \text{ onde } p_o = \frac{a+d}{N}, p_e = \frac{(a+c)(a+b) + (b+d)(c+d)}{N^2} \text{ e } N = a+b+c+d. \quad (7)$$

$$\tau = \frac{a+d}{N}, FA = \frac{b}{a+b} \text{ e } DR = \frac{a}{a+c}.$$

2.5 Classes de Mudança

A construção de um mapa de mudanças binário (**CM**) não traz informação sobre os tipos de alteração que ocorreram na superfície terrestre de t_1 para t_2 . Neste estudo os pixels do **CM** associados à classe de mudança (ω) são submetidos a uma análise de agrupamento do tipo k -médias na qual o número de *clusters* a ser formados é o único dado de entrada a ser fornecido pelo pesquisador. Dessa forma é possível associar classes de mudança aos pixels gerando um mapa de mudanças temático (**CMF**).

3. Resultados

O experimento teve por objetivo investigar a eficiência do algoritmo proposto frente a diferentes níveis de ruído. O fato de a imagem de referência ser conhecida permitiu que as medidas quantitativas descritas em 2.4 fossem avaliadas. A Tabela 2 apresenta os indicadores para quatro diferentes níveis de confiança sob diferentes níveis de ruído. Percebe-se que, à medida que aumenta o nível de confiança, diminui a taxa de falsos alarmes (FA). Por outro lado, níveis de confiança demasiadamente altos podem diminuir a taxa de detecção. A Figura 3 mostra a evolução do coeficiente de concordância de *Kappa* de acordo com o valor do SNR para três diferentes níveis de confiança.

Tabela 2 – Indicadores quantitativos de desempenho do algoritmo frente a diferentes valores de SNR considerando diferentes níveis de confiança ($1-\alpha$).

$1-\alpha$	SNR (dB)	<i>Kappa</i>	Acurácia (τ)	FA	DR
95,00%	10	0,094	94,911%	5,1%	86,615%
95,00%	20	0,329	98,749%	1,2%	96,246%
95,00%	30	0,989	99,993%	0,0%	97,908%
95,00%	40	0,992	99,995%	0,0%	98,338%
95,00%	50	0,992	99,995%	0,0%	98,369%
99,00%	10	0,308	98,840%	1,1%	81,046%
99,00%	20	0,800	99,848%	0,1%	94,431%
99,00%	30	0,984	99,990%	0,0%	96,923%
99,00%	40	0,985	99,991%	0,0%	97,138%
99,00%	50	0,986	99,991%	0,0%	97,200%
99,74%	10	0,564	99,617%	0,3%	77,077%
99,74%	20	0,930	99,954%	0,0%	93,077%
99,74%	30	0,981	99,988%	0,0%	96,308%
99,74%	40	0,982	99,989%	0,0%	96,523%
99,74%	50	0,982	99,998%	0,0%	96,600%




Figura 3 – Evolução do coeficiente *Kappa* entre os resultados obtidos e o mapa de referência para diferentes níveis de confiança e ruído.

A Figura 4 apresenta os mapas de mudanças binários e temáticos para os níveis de significância de 99 e 99,74% para uma situação de nível moderado de ruído (SNR=20dB). Os mapas temáticos foram obtidos a partir da interpretação dos centróides dos *clusters* gerados

pelo algoritmo k -médias. De uma forma geral, as mudanças introduzidas foram facilmente detectadas. Tais regiões refletem mudanças que podem ocorrer em cenas naturais (desmatamento, preparo de área de cultivo, aterro e surgimento de um açude). A área de aterro na parte rasa da lagoa foi a região de mudanças mais difícil de ser detectada e interpretada. Os pixels dessa área foram agrupados no mesmo *cluster* dos pixels ruidosos.

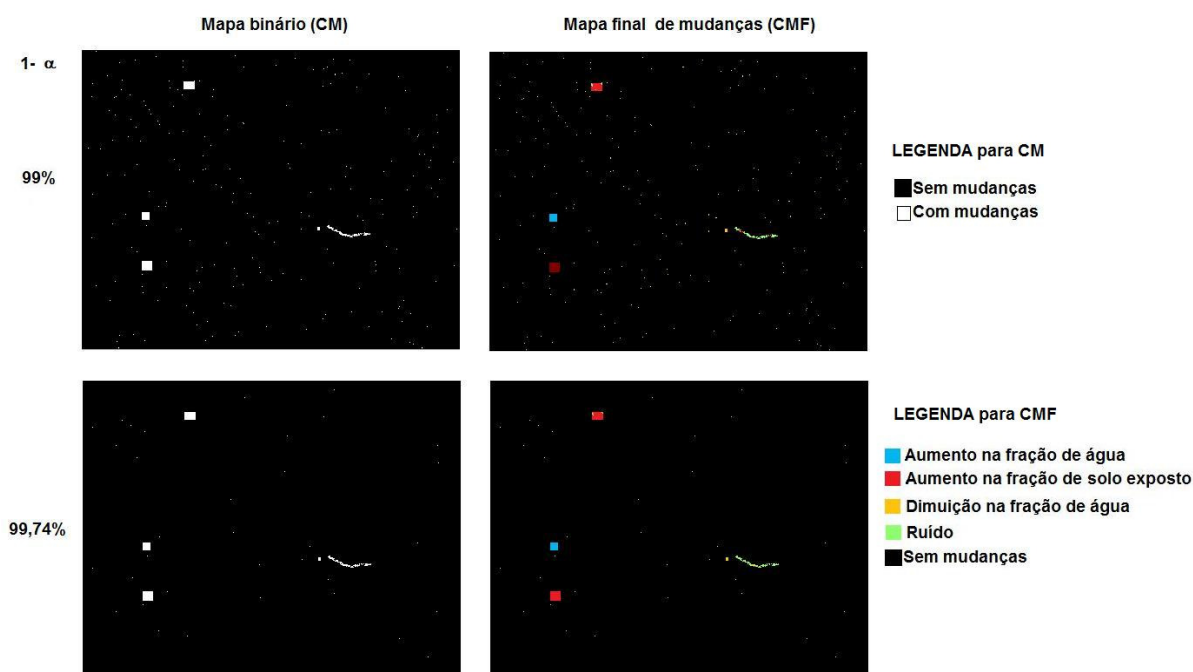


Figura 4 – Mapas de mudanças binário (CM) e temático (CMF) para níveis de confiança de 99 e 99,74% obtidos sobre a imagem sintética com SNR=20dB.

4. Conclusões

Este texto apresentou um procedimento multivariado para detecção de mudanças na superfície terrestre a partir de imagens de fração. Os resultados apresentados apontam para a viabilidade do procedimento mesmo na presença de ruído de magnitude moderada (SNR=20dB). Quando a intensidade do sinal em relação ao ruído torna-se muito baixa (SNR=10dB), os resultados perdem acurácia pois as alterações de superfície confundem-se com o ruído.

O uso de imagens de fração para detecção de mudanças permitiu uma interpretação facilitada dos resultados devido ao fato de que as dimensões têm um significado físico (e.g. vegetação, solo exposto e água). Tal característica fez com que os *clusters* resultantes da análise de agrupamento fossem rotulados a partir do conhecimento dos vetores média (centróides) dos mesmos. Outra vantagem é que, no espaço de frações, as correções radiométricas deixaram de ser um problema crítico. Além disso, após ter definido os *endmembers*, o pesquisador não precisa selecionar componentes para utilizar como dado de entrada, pois todas são utilizadas simultaneamente.

Por fim, sugere-se que o estudo tenha continuidade com a introdução de informações de contexto visando reduzir o efeito *salt-and-pepper*, comum quando os pixels são considerados como entidades independentes. Nesse sentido, relaxação probabilística, campos de Markov ou até mesmo simples filtros baseados em janelas móveis podem ser introduzidos.

Referências Bibliográficas

- Bittencourt, H. R.; Haertel, V. Detecção de mudanças a partir de imagens de fração: uma abordagem fuzzy empregando o conceito de pixel mistura. In: Simpósio Brasileiro De Sensoriamento Remoto, 14. (SBSR), 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 1275-1281. DVD, On-line. ISBN 978-85-17-00044-7. Disponível em: <<http://urlib.net/dpi.inpe.br/sbsr@80/2008/11.16.23.32>>. Acesso em: 26 out. 2010.
- 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, 2007.
- 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.
- Celik, T. Unsupervised Change Detection in Satellite Images Using Principal Component Analysis and k-Means Clustering, **IEEE Geoscience and Remote Sensing Letters**, Vol. 6, No. 4, pp. 772-776, 2009.
- Cohen, J. A. A coefficient of agreement of nominal scales. **Educational and Psychological Measurement**, Vol.20, pp. 37-46, 1960.
- Congalton, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, Vol. 37, pp. 35-46, 1991.
- 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.
- Johnson, R. A and Wichern, D. W. **Applied Multivariate Statistical Analysis**. Prentice-Hall, Englewood Cliffs, NJ, 1982.
- Lu, D., Batistella, M., and Moran, E. 2004. Multitemporal spectral mixture analysis for Amazonian land-cover change detection, **Canadian Journal of Remote Sensing**, Vol. 30, No. 1, pp. 87-100.
- Malila, W. A. Change vector analysis: An approach for detecting forest changes with Landsat, In: LARS Machine Processing Remotely Sensed Data Symposium. **Proceedings...**, pp. 326-335. 1980.
- Michalek, J. L.; Luczkovich, J.J. Multispectral Change Vector Analysis for Monitoring Coastal Marine Environments, **Photogrammetric Engineering and Remote Sensing**, v. 59, pp. 381-384, 1993.
- 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.
- 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, pp. 16-20, 1991.
- Singh, A. Digital Change Detection techniques using remotely-sensed data. **International Journal of Remote Sensing**, v. 10, n. 6, p. 989-1003, 1989.
- Teng, S.P., Chen, Y. K., Cheng, K. S., and Lo, H. C. Hypothesis-test-based landcover change detection using multi-temporal satellite images – A comparative study, **Advances in Space Research**, Vol. 41, pp. 1744-1754, 2008.
- Zanotta, D. C. and Haertel, V. A fuzzy approach to change detection. **IEEE Transactions on Geosciences and Remote Sensing**. *Submitted*, 2010.