

DETECÇÃO NÃO SUPERVISIONADA DE MUDANÇAS BASEADA EM DESVIOS SOBRE REFERENCIAIS RELATIVOS

Rogério Galante Negri¹ e Alejandro C. O. Frery²

¹ Universidade Estadual Paulista, Instituto de Ciência e Tecnologia, São José dos Campos, Brasil
rogerio.negri@unesp.br

² Universidade Federal de Alagoas, Laboratório de Computação Científica e Análise Numérica, Maceió, Brasil
acfrery@laccan.ufal.br

RESUMO

A detecção de mudança utilizando dados de Sensoriamento Remoto é um tópico de grande interesse. Devido a importância deste tipo de aplicação, o desenvolvimento de métodos cada vez mais acurados surge como um desafio contínuo. Este trabalho introduz um novo método de detecção de mudanças automatizado baseado nos conceitos de agrupamento de dados e estimação não paramétrica de distribuição de probabilidade. Enquanto o uso de agrupamentos é motivado pela necessidade da definição de referenciais de comparação específicos para diferentes tipos de alvos, distribuições de probabilidade são adotadas para expressar os desvios de comportamento dos alvos entre os instantes observados. Um estudo de caso sobre o mapeamento das mudanças ocorridas em uma região nas proximidades do rio Tapajós, fazendo uso do método introduzido e de outro método existente na literatura, evidencia o potencial desta nova proposta.

Palavras-chave – Detecção de mudança, não supervisionado, agrupamento, distribuição de probabilidade.

ABSTRACT

Remote Sensing change detection is a topic of great interest for several areas of application. The development of more precise change detection methods is a constant challenge. This study introduces a novel automatic change detection method based on data clustering and non parametric density function estimation. While the use of clusters is motivated by the need of define relative references to compare the different kinds of targets, probability density functions are adopted to model the deviations of such targets when compared in two distinct instants. We carried a case study about the changes in a region near to Tapajós River in order to compare the proposed method with another unsupervised method well-known in literature. The results show the potential in the introduced method.

Key words – Change detection, unsupervised, clustering, probability distribution.

1. INTRODUÇÃO

Detecção de mudanças no uso e cobertura do solo por meio de imagens de Sensoriamento Remoto é um tópico de grande interesse para as ciências ambientais, cartografia, geografia, ecologia e hidrologia [1]. Este tipo de aplicação consiste no

processo de identificar alterações ocorridas entre duas ou mais imagens adquiridas em instantes diferentes [2].

A detecção de mudanças de forma acurada é extremamente importante para o entendimento das relações de interação entre fenômenos antrópicos e naturais, possibilitando assim a promoção de melhores tomadas de decisão. Face a esta realidade, o desenvolvimento de novas técnicas torna-se um tópico de pesquisa continuamente ativo [3].

As técnicas de detecção de mudança são fortemente suportadas por conceitos derivados das áreas de Reconhecimento de Padrões e Processamento Digital de Imagens. De acordo com [4], as técnicas de detecção de mudança podem ser agrupados dentre as seguintes categorias: (i) álgebra entre imagens; (ii) transformação de imagens; (iii) extração de atributos; (iv) classificação de imagens; (v) outros métodos. Porém, autores como [5], distinguem os métodos de detecção de mudança de uma forma menos específica dentre os tipos supervisionado e não-supervisionado. Enquanto os métodos supervisionados necessitam de dados para o treinamento de um classificador, a abordagem não supervisionada é guiada de forma automática com base em processos como limiarização e agrupamento de dados. Esta característica de independência de conhecimento *a priori* torna os métodos não supervisionados mais atraentes em comparação aos supervisionados.

Diante desta breve discussão apresentada, este trabalho consiste em introduzir um novo método de detecção de mudança não supervisionado fundamentado em conceitos de agrupamento de dados e análise de desvios bitemporais observados sobre funções densidade de probabilidade obtidas sobre os alvos que compõem a cena.

Com a finalidade de verificar o potencial da nova proposta, é realizado um estudo de caso sobre as mudanças na cobertura do solo em uma região nas proximidades do rio Tapajós. Comparações envolvendo o método proposto em [6], amplamente consagrado na literatura, são incluídas neste estudo.

2. UMA NOVA PROPOSTA DE DETECÇÃO DE MUDANÇA

2.1. Notações e conceitos preliminares

Sejam $\mathcal{I}^{(1)}$ e $\mathcal{I}^{(2)}$ duas imagens definidas sobre um suporte $\mathcal{S} \subset \mathbb{N}^2$ e referentes a uma mesma localização geográfica, porém tomadas em instantes distintos. Denota-se por $\mathbf{x}_i^{(j)} = \mathcal{I}^{(j)}(s_i)$ o vetor de atributos associado à posição $s_i \in \mathcal{S}$, sendo $\mathbf{x}_i^{(j)}$ um elemento do espaço de atributos \mathcal{X} . Os valores associados às componentes de $\mathbf{x}_i^{(j)}$ representam medidas

captadas pelo sensor imageador sobre uma determinada posição na superfície terrestre.

Segundo esta notação, as alterações ocorridas entre $\mathcal{I}^{(1)}$ e $\mathcal{I}^{(2)}$ com relação a s_i pode ser representada pelo escalar z_i . Por sua vez, \mathcal{Z} é a imagem, também definida sobre o suporte \mathcal{S} , tal que $\mathcal{Z}(s_i) = z_i$. Em tempo, cabe observar que z_i pode ser alcançado de diferente formas, por exemplo, através da diferença entre índices (e.g. NDVI, NDWI e SAVI) e/ou transformações espectrais. Uma escolha simples e conveniente corresponde à magnitude das alterações entre instantes [7], fazendo assim \mathcal{Z} expressa por:

$$\mathcal{Z}(s_i) = \|\mathbf{x}_i^{(1)} - \mathbf{x}_i^{(2)}\|_2, \quad (1)$$

onde $\|\cdot\|_2$ é a norma ℓ^2 .

É definido por agrupamento $\mathcal{G}_k^{(j)}$, $k = 1, \dots, c$, o conjunto de posições s_i de \mathcal{I}_j cujos vetores de atributos $\mathbf{x}_i^{(j)}$ compartilham de determinada similaridade entre si. Formalmente:

$$\mathcal{G}_k^{(j)} = \{s_i : \mathbf{x}_p^{(j)} \in \mathcal{G}_k^{(j)}, \mathbf{x}_q^{(j)} \notin \mathcal{G}_k^{(j)}; m(\mathbf{x}_i^{(j)}, \mathbf{x}_p^{(j)}) < m(\mathbf{x}_i^{(j)}, \mathbf{x}_q^{(j)})\}, \quad (2)$$

sendo $m(\cdot, \cdot)$ uma função que mede a dissimilaridade entre os dados de entrada.

Por fim, o conjunto $\mathcal{V}_\rho(s_i) = \{t \in \mathcal{S} : 0 \leq d(s_i, t) \leq \rho\}$ representa a vizinhança de s_i segundo um determinado raio de vizinhança ρ , sendo $d(\cdot, \cdot)$ a distância euclidiana. Ao desejar que a vizinhança exerça influência na definição do vetor de atributos associado a s_i , e consequentemente nas definições apresentadas anteriormente, é suficiente a substituição de $\mathbf{x}_i^{(j)}$ pela seguinte forma alternativa:

$$\bar{\mathbf{x}}_i^{(j)} = \frac{\sum_{t \in \mathcal{V}(s_i)} \mathbf{x}_t^{(j)}}{\#\mathcal{V}(s_i)}. \quad (3)$$

2.2. Motivação e formalização da proposta

As seguintes premissas motivam o desenvolvimento do método de detecção de mudança em proposição:

- (i) Fatores associados ao processo de aquisição dos dados podem influenciar a representação dos alvos, e ainda, tal influência pode acontecer de forma distinta sobre os diferentes tipos de alvos existentes nas cenas;
- (ii) Dadas $\mathcal{I}^{(1)}$ e $\mathcal{I}^{(2)}$, imagens referentes a uma mesma região geográfica em instantes distintos, então devem existir diferenças não provenientes de fatores relacionados ao processo de aquisição, as quais tendem a ocorrer em menor frequência.

De modo mais detalhado, a premissa (i) considera a existência de diferentes fatores que podem influenciar a representação dos alvos presentes na cena, de forma que alvos semelhantes sejam representados de formas distintas em instantes distintos. Exemplos de tais fatores são as interferências atmosféricas, variações devido a sazonalidade, ângulo/tipo de visada, diferentes canais (i.e., bandas ou polarizações), resoluções, ou ainda, a consideração de

diferentes sensores. Ainda, esta premissa admite que seja desconhecida a relação capaz de modelar a variação desempenhada pelos alvos em uma determinada região quando observados em instantes distintos. Já a premissa (ii) estabelece que ao comparar dos alvos presentes em $\mathcal{I}^{(1)}$ e $\mathcal{I}^{(2)}$ devem existir determinadas diferenças/variações não associadas ao processo de aquisição. Tais diferenças correspondem a conversões do tipo do alvo, cuja detecção é desejada.

Sendo assim, a premissa (i) motiva que sejam adotados referenciais distintos, de modo que as diferenças de comportamento relacionados a fatores irrelevantes (e.g., processo de aquisição, características ambientais, tipo do alvo, etc.) sejam contornados e não influenciem negativamente na detecção de mudanças. Para tal, são determinados agrupamentos $\mathcal{G}_k^{(1)}$, $k = 1, \dots, c$, sobre $\mathcal{I}^{(1)}$, que por definição são compostos por alvos (expressos em função dos respectivos vetores de atributos) cujo comportamento são similares.

Neste contexto, cada agrupamento representa um *referencial relativo* em $\mathcal{I}^{(1)}$ segundo as localizações s_i em que existe determinado comportamento comum. Em posse destes referenciais relativos, é verificado o comportamento das alterações/divergências entre $\mathcal{I}^{(1)}$ e $\mathcal{I}^{(2)}$, expresso pelo conjunto:

$$\mathcal{Z}(\mathcal{G}_k^{(1)}) = \{\mathcal{Z}(s_i) : s_i \in \mathcal{G}_k^{(1)}\} \quad (4)$$

Ao recapitular a premissa (ii), que supõe existência de diferenças, observadas em menor frequência, entre $\mathcal{I}^{(1)}$ e $\mathcal{I}^{(2)}$ devido a fatores não relacionados à variáveis do sistema de imageamento e/ou ambientais, verifica-se que tais diferenças são potencialmente detectadas com base nos desvios observados sobre a distribuição de probabilidade $f_k(z)$ modelada sobre $\mathcal{Z}(\mathcal{G}_k^{(1)})$. Dessa forma, valores de diferença associados a altas probabilidades de ocorrência estão relacionados a baixas probabilidades de representarem mudança de tipo de alvo. Inversamente, valores extremos, associados a baixas probabilidades de ocorrência, tendem a representar mudanças de tipo de alvo.

A determinação dos valores de diferenças, expresso pelo intervalo $[a, b]$, tais quais incidem uma confiança de $1 - \alpha$ de “não representar mudança”, pode ser realizada com solução do seguinte problema de otimização:

$$\begin{aligned} & \min (b - a) \\ & \text{sujeito a: } \alpha = \int_a^b f_k(z) dz \end{aligned} \quad (5)$$

Assim, para cada conjunto $\mathcal{Z}(\mathcal{G}_k^{(1)})$, com $k = 1, \dots, c$, é possível determinar a probabilidade que cada elemento z_i possui em representar uma mudança. Uma vez que as posições s_i associadas a z_i são conhecidas via $\mathcal{G}_k^{(1)}$, a construção de um mapa de mudanças expresso em função da respectiva probabilidade de ocorrência associada torna-se um processo direto e simples.

3. EXPERIMENTOS E RESULTADOS

Esta seção apresenta um estudo de caso sobre o emprego do método formalizado na Seção 2.2 na detecção e mapeamento de mudanças ocorridas na região do município de Santarém, estado do Pará, entre os anos de 1989 e 1999. O período considerado caracteriza expansão da ocupação sobre esta área de estudo mediante a remoção de sua cobertura vegetal nativa. As imagens utilizadas foram tomadas pelo sensor TM a bordo do satélite LANDSAT-5 nas datas 22/08/1989 e 02/08/1999. Tais imagem, ilustradas na Figuras 1(a) e 1(b), possuem 30 m de resolução espacial, dimensão de 900×500 pixels e cinco bandas multiespectrais, no intervalo do azul ao infravermelho médio, devidamente georreferenciadas a fim de garantir comparação restrita a uma mesma área de estudo.

Como base de comparação, são incluídos resultados obtidos com o métodos proposto em [6], aqui denominado por PCAkMeans. Este método combina os conceitos de agrupamento e análise de componentes principais para construção de uma proposta não supervisionada de detecção de mudanças. Uma vez que a proposta deste trabalho e de [6] permitem o ajuste da influência da vizinhança (ρ), diferentes valores para este parâmetro considerados. As comparações serão baseadas na medida *FI-Score*, computadas 100 vezes sobre uma parcela de 25%, selecionada aleatoriamente, a partir dos dados admitidos como verdade terrestre de mudança, exibidos na Figura 1(c). Sobre estes 100 valores calculado para um dado resultado de detecção de mudança, são determinados os valores médios e desvios padrão da medida *FI-Score*. Ainda, o teste de Wilcoxon foi aplicado a fim de verificar a significância estatística entre os métodos comparados. Com relação ao método proposto, será adotado o limiar $\alpha = 0,1$, que de modo equivalente indica que as áreas identificadas como “mudança” correspondem aos 90% mais extremos dentre às diferenças observadas entre imagens segundo um alvo de determinado tipo.

Com relação ao processo de determinação dos agrupamentos $\mathcal{G}_k^{(1)}$, foi feito uso do Algoritmo Hierárquico Divisivo [8] baseado em sucessivas partições binárias via *K*-Médias. Para obtenção das distribuições de probabilidade $f_k(\cdot)$ relativas a $\mathcal{Z}(\mathcal{G}_k^{(1)})$, com $k = 1, \dots, c$, foi empregado o estimador de densidade kernel gaussiano [9] com uso da regra de Silverman na determinação da largura da banda. A implementação do método proposto e demais técnicas citadas foram realizadas com uso da linguagem de programação IDL (*Interactive Data Language*).

Na Tabela 1 são apresentados os valores médios e desvios padrão da medida *FI-Score*, computados segundo as especificações estabelecidas anteriormente, obtidos pelos métodos considerados neste estudo diante diferentes valores de $\rho \in \{3, 5, 7, 9, 11\}$. Segundo estes resultados, a nova proposta foi superior em comparação ao método PCAkMeans. Evidentemente, tais resultados são estatisticamente diferentes entre si diante uma significância de 1%.

A superioridade numérica apresentada na Tabela 1 é corroborada pelos mapeamentos de ocorrência de “mudanças” e “não mudança” ilustrados na Figura 2 sob a consideração de vizinhanças com raio igual a sete.

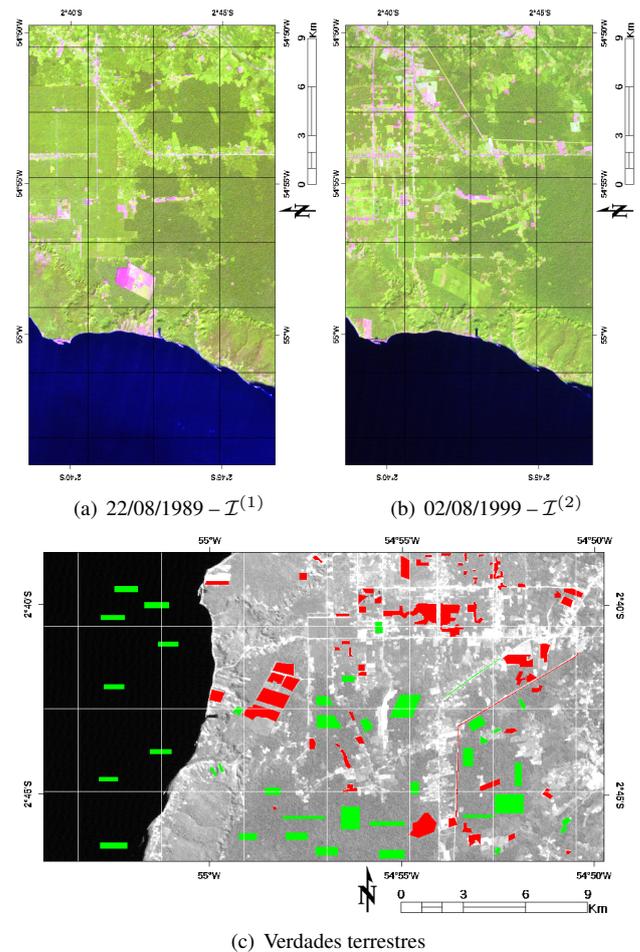


Figura 1: Imagens utilizadas neste estudo de caso em composição colorida R(NIR)G(4)B(3) e amostras de verdade terrestre sobre ocorrência de “mudança” (vermelho) e “não mudança” (verde) na cobertura do solo representadas sobre a banda do infravermelho próximo referente a imagem de 1999.

Método	Raio da vizinhança (ρ)	
	$\rho = 3$	$\rho = 5$
PCAkMeans	$0,285 \pm 8,08 \cdot 10^{-3}$	$0,291 \pm 7,86 \cdot 10^{-3}$
Proposta	$0,577 \pm 6,99 \cdot 10^{-3}$	$0,592 \pm 7,31 \cdot 10^{-3}$
	$\rho = 7$	$\rho = 9$
PCAkMeans	$0,294 \pm 7,49 \cdot 10^{-3}$	$0,288 \pm 7,43 \cdot 10^{-3}$
Proposta	$0,593 \pm 7,51 \cdot 10^{-3}$	$0,592 \pm 7,61 \cdot 10^{-3}$
	$\rho = 11$	
PCAkMeans	$0,279 \pm 7,41 \cdot 10^{-3}$	
Proposta	$0,584 \pm 7,50 \cdot 10^{-3}$	

Tabela 1: Valores de *FI-Score* e respectivo desvio padrão computados sobre os resultados obtidos pelo novo método proposto e PCAkMeans diante diferentes raios de vizinhanças.

Nestes resultados é possível verificar a robustez do método proposto com relação à detecção de falsos positivos sobre a região do rio Tapajós e sobre os alvos localizados ao leste da área de estudo.

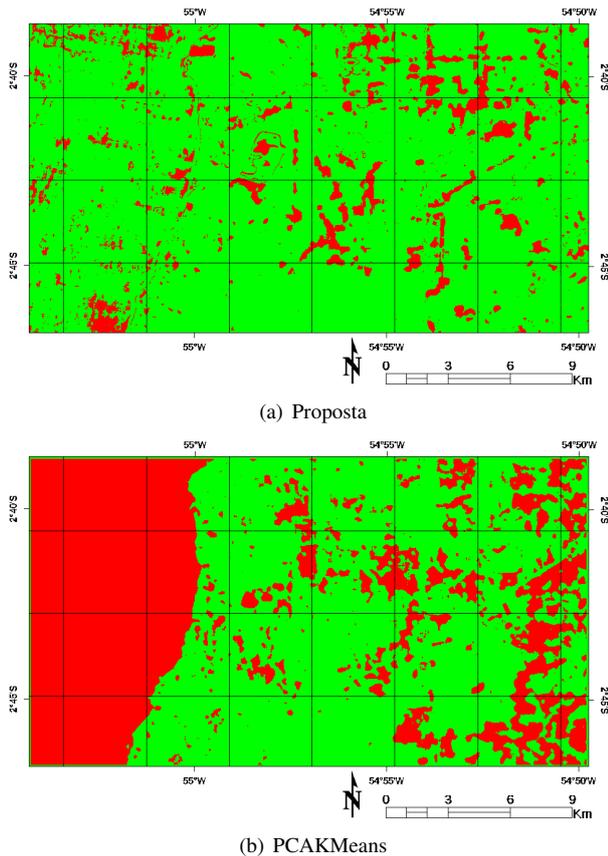


Figura 2: Mapa com representação das áreas de “mudanças” (vermelho) e “não mudança” (verde) segundo os métodos comparados com $\rho = 7$.

4. CONCLUSÕES

Este trabalho foi introduzido um novo método não supervisionado de detecção de mudanças. Baseado nas suposições que a existência de diferenças entre duas imagens são causadas por fatores ambientais e/ou relacionados a características do sistema de imageamento, seu desenvolvimento utiliza referenciais relativos no processo de comparação entre imagens assim como distribuições de probabilidade, estimadas sobre os desvios computados, como ferramenta para detecção de alterações nos tipos dos alvos.

Os resultados obtidos sobre o estudo de caso realizado apontam o potencial da nova proposta e superioridade em comparação ao método proposto em [6]. Apesar da superioridade referente à acurácia dos resultados, cabe mencionar que o método introduzido apresenta maior custo computacional, uma vez que, além da obtenção de

agrupamentos para definição dos denominados *referenciais relativos*, torna-se necessária a resolução do problema de otimização (Equação 5) associado a cada um dos agrupamentos. Em termos numéricos, enquanto o método PCAKMeans exigiu aproximadamente 80s para o processamento dos dados deste estudo de caso, foram necessários aproximadamente 400s pelo método proposto.

Como perspectivas futuras para este trabalho, são mencionadas: (i) otimização do custo computacional; (ii) verificação de outros algoritmos de agrupamento que podem ser combinados a este método e os respectivos impactos causados sobre a acurácia dos resultados; e (iii) investigação de outras medidas para quantificação das diferenças entre imagens.

Agradecimento: Os autores agradecem à FAPESP (Proc.: 2018/01033-3) pelo auxílio financeiro.

5. REFERÊNCIAS

- [1] SRIVASTAVA, P. K. et al. Selection of classification techniques for land use/land cover change investigation. *Advances in Space Research*, v. 50, n. 9, p. 1250–1265, 2012.
- [2] LIU, S. et al. Hierarchical Unsupervised Change Detection in Multitemporal Hyperspectral Images. *IEEE Transactions on Geoscience and Remote Sensing*, v. 53, n. 1, p. 244–260, 2015.
- [3] LU, D. et al. Change detection techniques. *International Journal of Remote Sensing*, v. 25, n. 12, p. 2365–2401, 2004.
- [4] WU, C.; DU, B.; ZHANG, L. Slow Feature Analysis for Change Detection in Multispectral Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, v. 52, n. 5, p. 2858–2874, 2014.
- [5] VOLPI, M. et al. Unsupervised change detection with kernels. *IEEE Geoscience and Remote Sensing Letters*, v. 9, n. 6, p. 1026–1030, 2012. ISSN 1545-598X.
- [6] 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, Oct 2009. ISSN 1545-598X.
- [7] JOHNSON, R. D.; KASISCHKE, E. S. Change vector analysis: A technique for the multispectral monitoring of land cover and condition. *International Journal of Remote Sensing*, Taylor & Francis, v. 19, n. 3, p. 411–426, 1998.
- [8] THEODORIDIS, S.; KOUTROUMBAS, K. *Pattern recognition*. San Diego: Academic Press, 2009. 961 p. ISBN 9780080949123.
- [9] SILVERMAN, B. W. *Density Estimation for Statistics and Data Analysis*. London: Chapman & Hall, 1986.