

Uso de mapas auto-organizáveis de Kohonen na detecção automática de mudanças na Represa de Paraibuna

Michael Douglas Lemes dos Santos ¹

Rodrigo Luiz Mendes Mota ²

Elcio Hideiti Shiguemori ¹

Alexandre Carlos Brandão Ramos ²

¹Instituto de Estudos Avançados - IEAv
Caixa Postal 6044 – 12228-970 – São José dos Campos - SP, Brasil
{michaeldouglas, elcio}@ieav.cta.br

² Universidade Federal de Itajubá - Unifei
Caixa Postal 50 - 37500-903 - Itajubá - MG, Brasil
{rodrigo.mota, ramos}@unifei.edu.br

Abstract. This paper presents an application of self-organizing maps for change detection in satellite images. The attention is focused on the challenging of change detection automatic in remote sensing, so in this study a post-classification technique based on Kohonen neural network is presented. A pair of images acquired by the Landsat satellite from different period of time from Paraibuna reservoir at State of São Paulo, Brazil, has been employed. As output of the self-organizing maps, it was obtained a map of colors. The results of change detection have been obtained through the comparison between the map of colors.

Palavras-chave: change detection, Kohonen, detecção de mudanças.

1. Introdução

Atualmente, uma grande quantidade de dados e imagens da superfície da Terra tem sido coletada para diversas aplicações do sensoriamento remoto, como por exemplo, no monitoramento ambiental, monitoramento da agricultura, gestão do planejamento urbano e análise do crescimento populacional (Mura et al., 2008). Com isso, tem crescido a necessidade de processos para extração automática de informações, como detecção de mudanças na cobertura do solo (Bruzzone e Bovolo, 2013).

Existem diversos métodos que auxiliam na identificação de mudanças de cobertura no solo, mas em muitos casos essa identificação é empírica ou manual por tentativa e erro (Bruzzone e Prieto, 2000). Outras técnicas são semiautomáticas, como apresentado em Gladstone et al. (2012).

A identificação automática de mudanças não é uma tarefa simples e na literatura são apresentados trabalhos que abordam este problema (Thankachan e Jose, 2014; Huang et al., 2014; Santos e Lingnau, 2013; Yousif e Ban, 2013). De acordo com Bruzzone e Bovolo (2013), ainda são necessários novos métodos mais eficientes.

As redes neurais artificiais têm se mostrado promissoras no processo de identificação automática de mudanças de cobertura no solo. Alguns trabalhos que apresentam contribuições utilizando redes neurais são encontrados na literatura (Ghosh et al., 2013).

Este artigo apresenta o uso de mapas auto-organizáveis de Kohonen para a detecção automática de mudanças. Como estudo de caso, as técnicas são aplicadas na identificação de mudanças em uma área alagada e com matas ciliares na região do reservatório de Paraibuna, São Paulo, Brasil. As regiões alteradas significativamente podem ser resultadas de áreas alteradas nas matas ciliares e mudanças na área alagada do reservatório.

Este artigo está organizado da seguinte forma. A Seção 2 contém uma revisão das técnicas de detecção de mudanças de imagem. A Seção 3 contém uma revisão sobre os mapas auto-organizáveis de Kohonen. Na Seção 4, os métodos utilizados são explicados. A Seção 5

contém os resultados do método proposto. Finalmente, na Seção 6, são apresentadas as conclusões.

2. Detecção de mudanças

Diferentes técnicas de detecção de mudanças têm sido propostas para diversas aplicações e podem ser classificadas como supervisionadas e não supervisionadas (Celik e Ma, 2010). As técnicas supervisionadas são baseadas em um método com supervisão, ou seja, é necessário um conjunto de treinamento gerado a partir de informações de campo para o processo de treinamento dos classificadores. As técnicas não supervisionadas realizam a detecção de mudanças fazendo a comparação direta de duas imagens (Celik e Ma, 2010).

Segundo Celik e Ma (2010), existem diferentes métodos de detecção de mudanças supervisionados, entre eles, baseados em: redes neurais artificiais (Mota et al., 2014); *kernels* (Samaniego et al., 2008), wavelets (Grandi et al., 2009), máquinas de vetores de suporte (Moser e Serpico, 2009) e pós-classificação (Alboody et al., 2008). Ainda de acordo com Celik e Ma (2010), os métodos não supervisionados analisam automaticamente as diferenças entre as imagens e entre esses métodos está a Análise de Componentes Principais (PCA) (Yousif e Ban, 2013), Índice de Vegetação por Diferença Normalizada (NDVI) (Santos e Lingnau, 2013) e as técnicas algébricas, como subtração de imagens e razão de imagens (Afify, 2011).

Existem também trabalhos que propõem novas técnicas de detecção automática de mudanças e realizam comparações e avaliações entre elas. Thankachan e Jose (2014) realizam a detecção de mudanças em imagens de Radar de Abertura Sintética (SAR) com base na evolução das estatísticas locais das imagens. Huang et al. (2014) investiga a detecção de mudanças de edifícios em áreas urbanas, utilizando imagens de alta resolução, com base em um índice chamado *Morfological Building Index* (MBI) proposto recentemente. As redes neurais artificiais também têm sido apresentadas como uma proposta para identificação de mudanças aplicadas às imagens de satélite. Ghosh et al. (2013) apresenta uma abordagem que utiliza a rede neural de Hopfield e imagens multiespectrais.

3. Mapas auto-organizáveis de Kohonen

As redes neurais artificiais supervisionadas e não supervisionadas têm sido utilizadas para a classificação e segmentação de imagens e tem-se obtido resultados satisfatórios (Oliveira et al., 2009; Indira e Ramesh, 2011). As redes neurais supervisionadas aprendem com padrões previamente rotulados e são usadas quando há informações precisas sobre as classes. Nas redes neurais não supervisionadas não há exemplos rotulados a serem aprendidos pela rede porque os padrões de treinamento pertencem a classes desconhecidas.

Para realizar a classificação de imagens com as redes neurais, alguns atributos são extraídos para caracterizar as imagens e serem usados como dados de entrada. Esses atributos podem ser obtidos das imagens através da matriz de co-ocorrência de níveis de cinza (GLCM) (Haralick et al., 1973), que mostra a relação entre os pixels e suas vizinhanças e orientação para a extração de características de textura, como homogeneidade (uniformidade), heterogeneidade (contraste) e aleatoriedade (entropia) da imagem.

Neste trabalho é utilizada a rede neural de Kohonen. O mapa auto-organizável de Kohonen foi proposto por Teuvo Kohonen (Kohonen, 1982) e se tornou uma das redes neurais artificiais não supervisionadas mais amplamente utilizadas (Thakare e Patil, 2014; Aghajari et al., 2013). Seu desenvolvimento foi baseado na característica do cérebro humano de se organizar em regiões, onde as entradas são representadas por mapas topologicamente ordenados.

Um mapa de Kohonen contém uma camada de entrada e uma camada de saída. A quantidade de nós na camada de entrada é igual ao número de dimensões dos dados da

entrada. A camada de saída é a camada de neurônios e pode assumir a forma retangular, hexagonal ou circular, onde as conexões determinam a vizinhança de um determinado neurônio (Haykin, 2009).

No início da operação da rede neural, os pesos sinápticos dos neurônios são inicializados com valores aleatórios, e a partir daí, a formação da rede passa por três processos. No processo competitivo todos os padrões de entrada são comparados com cada neurônio através da medida da distância Euclidiana. O neurônio com a menor distância Euclidiana é o vencedor e é ativado. No processo seguinte, conhecido como cooperativo, o neurônio vencedor determina a localização topológica de neurônios excitados conhecida como vizinhança topológica. A função de vizinhança topológica $h_{j,i}(x)$ é dada por (Kohonen, 1982; Haykin, 2009) (Equação 1):

$$h_{j,i}(x) = \exp\left(\frac{-d_{j,i}^2}{2\sigma^2}\right) \quad (1)$$

Onde o parâmetro σ é a largura da vizinhança topológica e mede o grau com que os neurônios excitados na vizinhança participam do processo de aprendizagem, j representa o neurônio vencedor, i representa cada um dos outros nós, x é o dado de entrada e $d = |j - i|$. A função de vizinhança $h_{j,i}(x)$ é gaussiana, portanto, seu valor se aproxima de 0 quando d aumenta.

O último processo é a adaptação sináptica, onde os pesos do neurônio vencedor j e de sua vizinhança topológica são atualizados (Kohonen, 1982; Haykin, 2009) (Equação 2):

$$w_j(n+1) = w_j(n) + \eta(n)h_{j,i(x)}(n)(x - w_j(n)) \quad (2)$$

Onde w é o peso sináptico, x é o dado de entrada, n é o número da iteração e η é a taxa de aprendizagem.

No processo de treinamento, a entrada é repetidamente apresentada à rede neural, enquanto, a taxa de aprendizagem η e o tamanho da vizinhança σ considerada decrescem gradualmente, e a estrutura forma um mapeamento topologicamente ordenado dos dados de treinamento (Haykin, 2009).

O mapa auto-organizável de Kohonen tem sido aplicado em imagens de satélite (Oliveira et al., 2009), no reconhecimento de padrões. No trabalho, a imagem de satélite de uma região da cidade de Iguatu, Ceará, é classificada utilizando a rede neural de Kohonen e o método da máxima verossimilhança. Em seguida, os resultados são comparados e no trabalho conclui-se que para os testes realizados, o mapa de Kohonen apresenta-se mais apto à detecção de áreas com bioma da caatinga. Outro trabalho, Indira e Ramesh (2011), utiliza o mapa de Kohonen para identificar as principais características presentes na imagem de satélite e aplica algoritmos genéticos aos resultados do SOM para obter melhores resultados de segmentação.

Empregar o SOM como um método de visão computacional em classificação de imagens é uma abordagem promissora, pois o aprendizado é não supervisionado e não necessita que nenhum dos dados das imagens seja pré-classificado.

4. Metodologia de Trabalho

4.1 Área de Estudo

A área de estudo está localizada na região do Vale do Paraíba no Estado de São Paulo, Brasil. A área possui 224km², pois é composta pelo reservatório de Paraibuna que tem 177km² e é interligado ao reservatório de Paraitinga, com 47km² (CESP, 2014), inseridos entre as latitudes 23°19'49" Sul e 23°33'50" Sul e longitudes 45°52'29" Oeste e 45°25'05"

Oeste. No entorno da Represa Paraibuna encontram-se os municípios de Paraibuna, Redenção da Serra e Natividade da Serra, no Estado de São Paulo, como mostra a Figura 1.



Figura 1. Localização da área de estudo no detalhe da imagem à direita. Fonte: Google Earth (2014)

Em 1978 foi concluída a Usina Hidrelétrica Paraibuna no município de Paraibuna, São Paulo, e a principal finalidade do reservatório se tornou regular a vazão do Rio Paraíba do Sul, responsável pelo fornecimento de água para cidades do Vale do Paraíba e do Estado do Rio de Janeiro (CESP, 2014). A região passou por uma falta de chuvas na bacia do Rio Paraíba do Sul desde o verão de 2013 e causou uma seca, levando o volume de armazenamento registrar o menor índice dos últimos dez anos (O VALE, 2014). Segundo Hirota (2014), a alteração de áreas nas matas ciliares, devido à ocupação por pastagens, agricultura e silvicultura, também contribuiu para a seca nos reservatórios do Estado de São Paulo, pois as florestas naturais protegem as nascentes e todo fluxo hídrico. O estudo defende ainda o monitoramento e fiscalização constante dessas áreas.

4.2 Materiais e métodos

Para este trabalho, foram utilizadas duas imagens da área de estudo para identificar as mudanças entre elas. Uma imagem foi obtida na data de 6 de junho de 2013 e outra em 12 de agosto de 2014, ambas path 218 e row 76, compostas pelas bandas 4 (R, 0,64 – 0,67 μ m), 5 (NIR, 0,85 – 0,88 μ m) e 6 (SWIR, 1,57 – 1,65 μ m), do satélite Landsat 8 (Earth Explorer, 2014). A Figura 2 e a Figura 3 mostram as áreas selecionadas das imagens e ambas possuem um segmento de 250x250 pixels.




Figura 2. Imagem de parte da represa de Paraibuna obtida em junho de 2013. Fonte: Earth Explorer (2014).




Figura 3. Imagem de parte da represa de Paraibuna obtida em agosto de 2014. Fonte Earth Explorer (2014).

Neste trabalho é utilizada a técnica de detecção de mudanças pós-classificação. Essa técnica requer que as imagens sejam previamente classificadas e isso é feito pelo mapa auto-organizável de Kohonen. Para a classificação de imagens com o uso de redes neurais artificiais, alguns atributos são extraídos para caracterizar as imagens e são usados como dados de entrada das redes. As características extraídas são a matiz, saturação e brilho para compor os dados de entrada do mapa de Kohonen e foram obtidas informações espectrais e estruturais das imagens fazendo a média em janelas de 33x33 pixels nas imagens.

A fim de encontrar a melhor topologia da rede neural de Kohonen, foram realizados vários testes, variando a taxa de aprendizado inicial e a largura da função de vizinhança inicial. Cada vetor de pesos sinápticos dos neurônios é rotulado de acordo com uma classe e os dados de entrada são inseridos novamente na entrada do mapa de Kohonen e são comparados com esses vetores de pesos. A classificação dos pixels é feita através da medida da distância Euclidiana de cada dado de entrada com todos os vetores de pesos. Essa comparação provoca a ativação de um neurônio e o pixel é atribuído à classe desse neurônio. Dessa forma, as imagens são classificadas em grupos com características semelhantes e os resultados são apresentados em um mapa de cores, onde cada cor representa as características dos grupos. A partir do mapa de cores é possível detectar as mudanças através da comparação das imagens.

5. Resultados e Discussão

Com o objetivo de avaliar os resultados obtidos pelo algoritmo proposto, esta seção descreve os resultados e a sua análise.




Figura 4. Mapa de cores obtido através da classificação da Figura 2.




Figura 5. Mapa de cores obtido através da classificação da Figura 3.

Para identificar as mudanças, primeiramente foram obtidas as classificações das imagens da Figura 3 e da Figura 4. Os mapas de cores obtidos pelas classificações são apresentados na Figura 5 e na Figura 6.

Posteriormente, os resultados dos mapas de cores mostrados na Figura 4 e na Figura 5 são comparados. A Tabela 1 apresenta as diferenças entre os resultados obtidos nos mapas de cores.

Tabela 1. Resultados da comparação dos mapas de cores

Neurônio	Imagem da Figura 2	Imagem da Figura 3	Diferenças
Classe neurônio 1	25836 pixels	19578 pixels	6250 pixels
Classe neurônio 2	30653 pixels	28122 pixels	2531 pixels
Classe neurônio 3	4009 pixels	9350 pixels	5341 pixels
Classe neurônio 4	2002 pixels	5450 pixels	3448 pixels

A análise do mapa auto-organizável de Kohonen mostra que é possível fazer as classificações das imagens com esse tipo de rede neural sem supervisão e em seguida identificar mudanças automaticamente entre as imagens de satélite aplicado ao uso e ocupação do solo.

Os resultados das classificações apresentados pelos mapas de cores são satisfatórios, porém, é possível continuar a pesquisa para obter melhores classificações utilizando os mapas de Kohonen e, conseqüentemente melhorar a identificação de mudanças entre as imagens de satélites.

6. Conclusões

Neste trabalho é apresentada uma aplicação de detecção automática de mudanças em imagens de satélite. O estudo concluiu que as técnicas utilizadas são promissoras, principalmente na região da represa de Paraibuna, porque foram detectadas as mudanças nos grupos de cada imagem, uma vez que o mapa auto-organizável de Kohonen foi treinado pela imagem original e depois usado para a classificação da segunda imagem utilizando as informações do treinamento. Estas mudanças podem ser desmatamentos nas matas ciliares ou diminuição do volume de água da represa ocasionada por uma estiagem.

Como desenvolvimentos futuros deste estudo, estão sendo investigados novas abordagens de detecção automática de mudanças de imagens obtidas por diferentes sensores, como por exemplo, Veículos Aéreos Não Tripulados (VANTs). Outro desenvolvimento futuro é combinar mais informações das imagens para classificar melhor as imagens com o objetivo de identificar melhor as mudanças nas imagens e obter a descrição sobre as mudanças.

Agradecimentos

Este trabalho é apoiado pelo CNPq (Comissão Nacional de Desenvolvimento Científico e Tecnológico) – número do processo: 560190/2010-7.

Referências Bibliográficas

- Alboody, A.; Sedes, F.; Inglada, J. Post-classification and spatial reasoning: new approach to change detection for updating GIS database. In: Information and Communication Technologies: From Theory to Applications (ICTTA), 3., 2008, Damascus.
- Afify, H. A. Evaluation of change detection techniques for monitoring land-cover changes: a case study in new Burg El-Arab area. **Alexandria Engineering Journal**, v. 50, n. 2, p. 187-195.
- Aghajari, E.; Lotfi, H.; Gharpure, D. Towards interpretation of self organizing map for image segmentation. In: International Conference on Informatics, Electronics and Vision (ICIEV), 2013, Dhaka.
- Bruzzone, L.; Bovolo, F. A novel framework for the design of change detection systems for very high resolution remote sensing images. **Proceedings of the IEEE**, v. 101, n. 3, p. 609-630, 2013.
- Bruzzone, L.; Prieto, D. F. Automatic analysis of the difference image for unsupervised change detection. **IEEE Transactions on Geoscience and Remote Sensing**, v. 38, n. 3, p. 1171-1182, 2000.
- Celik, T.; Ma, K. Unsupervised change detection for satellite images using dual-tree complex wavelet transform. **IEEE Transactions on Geoscience and Remote Sensing**, v. 48, n. 3, p. 1199-1210, 2010.
- Earth Explorer**. Disponível em: <<http://earthexplorer.usgs.gov/>>. Acesso em: 29 set. 2014.
- Hirota, Márcia. **Por que desmatar 79% da área de mananciais secou São Paulo**. Disponível em: <<http://epoca.globo.com/colunas-e-blogs/blog-do-planeta/noticia/2014/10/por-que-bdesmatar-79-da-area-de-mananciaisb-secou-sao-paulo.html>>. Acesso em: 27 out. 2014.
- Ghosh, A.; Subudhi, B. N.; Bruzzone, L. Integration of Gibbs Markov Random Field and Hopfield-Type neural networks for unsupervised change detection in remotely sensed multitemporal images. **IEEE Transactions on Image Processing**, v. 22, n. 8, p. 3087-3096, 2013.
- Gladstone, C. S.; Gardiner, A.; Holland, D. A semi-automatic method for detecting changes to ordnance survey topographic data in rural environments. In: GEOBIA, 4., 2012, Rio de Janeiro.
- Google Earth**. Localização da área de estudo, 2014.
- Grandi, G. D.; Lucas, R. M.; Kropacek, J. Analysis by wavelet frames of spatial statistics in SAR data for characterizing structural properties of forests. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 2, p. 494-507, 2009.
- Haralick, R. M.; Shanmugam, K.; Dinstein, I. Textural features for image classification. **IEEE Systems, Man and Cybernetics Transactions**, v. 3, n. 6, p. 610-621, 1973.
- Haykin, S. **Neural Networks and Learning Machines**. Upper Saddle River: Pearson, 2009. 906 p.
- Huang, X.; Zhang L.; Zhu, T. Building change detection from multitemporal high-resolution remotely sensed images based on morphological building index. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 7, n. 1, p. 105-115, 2014.
- Kiel, Roberto. **Deteção de mudanças no uso e na cobertura do solo em uma série temporal de imagens da região da Campanha do Rio Grande do Sul**. 2008. 203 p. Dissertação(Mestrado em Sensoriamento Remoto) – Universidade Federal do Rio Grande do Sul, Porto Alegre. 2008.
- Kohonen, Teuvo. Self-organized formation of topologically correct feature maps. **Biological Cybernetics**, v. 43, n. 1, p. 59-69, 1982.
- Moser, G.; Serpico, S. B. Automatic parameter optimization for support vector regression for land and sea surface temperature estimation from remote sensing data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 3, p. 909-921, 2009.
- Mota, R. L. M.; Ramos, A. C. B.; Shiguemori, E. H. Application of self-organizing maps at change detection in Amazon Forest. In: International Conference on Information Technology: New Generations (ITNG), 11., 2014, Las Vegas.

Mura, M. D.; Benediktsson J. A.; Bovolo, F.; Bruzzone L. An unsupervised technique based on morphological filters for change detection in very high resolution images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 5, n. 3, p. 433-437, 2008.

Oliveira, D. N.; Sousa, B. F. S.; Braga, A. P. S.; Silva, F. A. T. F.; Teixeira, A. S. Aplicação de Mapas de Kohonen em imagem de satélite do semi-árido e comparação com o método da máxima verossimilhança. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 14., 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. Artigos, p. 7877-7884. On-line. Disponível em: <<http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2008/11.17.13.56.38/doc/7877-7884.pdf>>. Acesso em: 27 out. 2014.

O Vale. **Represa de Paraibuna chega ao menor nível dos últimos dez anos**. Disponível em: <<http://www.ovale.com.br/represa-de-paraibuna-chega-ao-menor-nivel-dos-ultimos-10-anos-1.555538>>. Acesso em: 27 out. 2014.

Samaniego, L.; Bardossy, A.; Schulz, K. Supervised classification of remotely sensed imagery using a modified k-NN technique. **IEEE Transactions on Geoscience and Remote Sensing**, v. 46, n. 7, p. 2112-2125, 2008.

Santos, J. F.; Lingnau, C. Monitoramento em área de catástrofe ambiental através de técnica de detecção de mudanças. **CERNE**, v. 19, n. 1, p. 133-140, 2013.

Thakare, V. S.; Patil, N. N. Classification of texture using gray level co-occurrence matrix and self-organizing map. In: International Conference on Electronic Systems, Signal Processing and Computing Technologies (ICESC), 2014, Nagpur.

Thankachan, L. M.; Jose, J. Joint change detection and image registration method for multitemporal SAR images. **International Journal of Advances in Engineering and Technology (IJAET)**, v. 7, n. 3, p. 765-772, 2014.

CESP. **Usina Hidrelétrica Paraibuna**. Companhia Energética de São Paulo (CESP). Disponível em: <http://www.cesp.com.br/portalCesp/portal.nsf/V03.02/Empresa_UsinaParaibuna?OpenDocument>. Acesso em: 27 out. 2014.

Yousif, O.; Ban, Y. Improving urban change detection from multitemporal SAR images using PCA-NLM. **IEEE Transactions on Geoscience and Remote Sensing**, v. 51, n. 4/1, p. 2032-2041, 2013.