

Método multi-resolução adaptativo para classificação simultânea de áreas rurais e urbanas

Letícia Figueiredo Sartorio¹
Daniel Capella Zanotta¹

¹ Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Sul - IFRS
Rua Eng. Alfredo Huch, 471 Rio Grande - RS, Brasil
leticia.sartorio@outlook.com, daniel.zanotta@riogrande.ifrs.edu.br

Abstract. The present work seeks to develop an adaptive classification method operating simultaneously with different rules in images including rural and urban areas. Traditional techniques are commonly based on the application of only one type of classification strategy. This assumption generally causes bad fitting of some areas if the image includes different kinds of targets. The aim is to obtain a more efficient thematic classification through the combined using of techniques and data of different resolutions, when compared with results achieved using a single approach. The proposed formulation is based on the premise that classification of rural and urban targets usually show large variations depending on how they are classified. Thus, traditional classifiers applied in environments that include rural and urban areas eventually end up benefiting one area over another. The first step of the suggested technique performs a prior automatic separation of urban and rural targets from the studied area, which will then be classified with different methods and input data. One experiment was performed using data with compatible resolution and classification techniques, according to the literature. Visual comparisons with classifications made only by means of one type of classification strategy leads us to visually verify the soundness of the suggested framework.

Palavras-chave: sensoriamento remoto, classificação de imagens, segmentação

1. Introdução

Com o desenvolvimento e disseminação de plataformas orbitais por meados da década de 60, se fez possível adquirir remotamente imagens da Terra vista do espaço, (LILLESAND *et al.*, 2014). O desenvolvimento dos sensores modernos representou grandes avanços na qualidade das imagens, principalmente em sua resolução espacial, melhorando os resultados de mapeamentos do uso e cobertura do solo (GHOLLOBI, KUMAR, 2015). Em função disso, os alvos terrestres são facilmente identificados e discriminados nas imagens, que podem ser classificadas automaticamente (CENTENO, 2004).

A classificação de imagens pode ser executada ao nível de pixel, quando cada pixel é analisado individualmente e recebe uma classe, ou objeto, quando um conjunto de pixels é analisado recebendo uma única classificação (MOOSAVI *et al.*, 2014). A classificação baseada em objetos é realizada a partir da segmentação da imagem, seguida da classificação dos segmentos resultantes (WHITESIDE *et al.*, 2011). A segmentação é uma técnica de agrupamento de pixels visando a formação de objetos que, além de possuírem características espectrais semelhantes, podem também serem analisados com base em suas características estatísticas ou de textura (DURO *et al.*, 2012).

A classificação baseada no pixel é normalmente aplicada de forma a utilizar unicamente o valor espectral do pixel individual para classificá-lo, não considerando aspectos de textura e contexto espacial entre os mesmos (WEIH; RIGGAN, 2008). Para imagens que apresentam uma alta resolução espacial e uma alta variação espectral, no caso de zonas urbanas, se faz importante utilizar a classificação baseada em objetos (ZHOU *et al.*, 2008), uma vez que os objetos presentes na cena costumam apresentar dimensões menores que o tamanho dos pixels. Entretanto, a classificação baseada no pixel mostra-se mais precisa quando aplicada em áreas que não sofrem grandes variações espectrais, que são mais homogêneas em sua composição, características que são facilmente encontradas em zonas rurais (AGUIRRE-GUTIÉRREZ *et*

al., 2012), o que normalmente ocorre quando as dimensões dos alvos presentes na cena supera o tamanho dos pixels.

O presente trabalho busca desenvolver uma abordagem adaptativa para classificar de forma mais precisa uma cena contendo ao mesmo tempo alvos rurais e urbanos a partir do uso simultâneo de duas imagens: uma de alta resolução espacial e outra, cobrindo a mesma área, de média resolução espacial. A técnica se baseia na pré-identificação de alvos urbanos e rurais, que após serão classificados com abordagens distintas: áreas urbanas utilizando imagens de alta resolução espacial seguindo abordagem baseada em objetos, e áreas rurais, utilizando imagens com média resolução espacial, que serão classificadas através da abordagem pixel-a-pixel.

A combinação das duas técnicas de classificação e imagens de resoluções espaciais distintas busca elevar a acurácia na classificação temática final, assim aprimorando os resultados e gerando uma ferramenta robusta para a classificação de imagens desse tipo.

2. Metodologia de Trabalho

A técnica de classificação híbrida a ser detalhada a seguir assume a existência de duas imagens cobrindo a mesma região. Uma de baixa resolução espacial, que será utilizada para classificar a parte rural da cena, e outra de alta resolução espacial para classificar a porção urbana da cena. Naturalmente, é necessário que as imagens que cobrem a área de estudo apresentam registro espacial e correções atmosféricas aceitáveis.

2.1 Pré-identificação da área Urbana e área Rural

O primeiro estágio da metodologia proposta subentende a separação da área rural e urbana a partir da imagem de baixa resolução espacial. Nesta etapa, o objetivo não é definir a classe definitiva dos alvos, mas sim identificar a porção rural e a porção urbana da cena. Para esse fim, a imagem de baixa resolução espacial é segmentada através de um processo de crescimento de regiões para agrupar os pixels mais similares, fazendo com que regiões naturais e áreas urbanas adquiram tonalidades características.

Após a segmentação, as médias de cada segmento são classificadas pelo método de máxima verossimilhança a fim de obter uma classificação para alvos primários, distinguindo a área urbana da rural. Os mesmos utilizaram para a classificação uma amostra da zona urbana, uma da zona rural, e uma de água. O resultado esperado para essa classificação é uma máscara separando zona rural e urbana, que será utilizada para orientar qual tipo de classificador será aplicado em cada área.

2.1 Classificação adaptativa

Como a literatura sugere, a zona urbana por conter alvos heterogêneos e com forma, textura e contexto bem definidos, deve ser classificada de forma não paramétrica, utilizando a abordagem baseada no objeto (TSO, MATHER, 2009). Uma abordagem que vem ganhando bastante espaço para esse tipo de aplicação é a classificação por árvore de decisão, uma vez que pode gerenciar a utilização de atributos diversos de acordo com a importância de cada um para o problema específico. Para o treinamento do classificador, amostras coletadas diretamente na imagem são utilizadas para produzir a árvore. Um algoritmo comumente utilizado para essa tarefa é o C4.5 (QUINLAN, 1986).

Por outro lado, a zona rural por conter alvos com maior homogeneidade e comportamento normalmente representado por uma distribuição probabilística padrão, pode ser classificada através de uma abordagem baseada no pixel, utilizando um classificador paramétrico como,

por exemplo, o classificador de máxima verossimilhança que utiliza o teorema de Bayes como ponto de partida. A função densidade de probabilidade das classes existentes no problema segue a distribuição Gaussiana (MATHER, TSO, 2009), que pode ser expressa pela seguinte expressão (Eq.1).


$$P(x_i | w_j) = \frac{1}{\sqrt{2\pi}^p \sqrt{|C_j|}} \exp\left(-\frac{1}{2} x(x_i - \mu_j)^t X C_j^{-1} X (x_i - \mu_j)\right) \quad (1)$$

Após a classificação separada de cada porção da imagem, as porções rural e urbana são unidas formando um mapeamento único, o qual se espera que apresente uma correspondência maior com a cobertura real do que métodos tradicionais que aplicam uma única regra ao longo de toda a cena, mesmo que esta contenha alvos de naturezas diversas.


3. Experimentos

Para fins de teste da metodologia sugerida neste trabalho foram utilizadas duas imagens de uma mesma região que apresentam níveis distintos de resolução espacial. A sequência de procedimentos foi realizado no *software Matlab*, onde a imagem foi calibrada radiometricamente e corrigida atmosféricamente. As imagens cobrem uma área do município da Cidade do Cabo, que se localiza na província de Western Cape / África do Sul, (coluna:175, linha:83), será utilizada uma cena do sensor *Landsat 8 OLI*, adquirida em 23 de setembro de 2015, e disponibilizada pelo *Earth Explorer*, do serviço geológico americano. A imagem do sensor *Landsat 8 OLI* apresenta 30 metros de resolução espacial para as bandas espectrais utilizadas (bandas 1,2,3,4,5 e 7). Neste experimento, a imagem de alta resolução espacial será do sensor *GeoEye-1*. A mesma apresenta 1,65 metros de resolução espacial nas bandas espectrais utilizadas (bandas: 1, 2,3 ,4).

A Figura 1a representa uma composição colorida da imagem do município da Cidade do Cabo – Western Cape / África do Sul, obtida pelo *Landsat 8 OLI*, enquanto a Figura 1b representa a região de da Cidade do Cabo – Western Cape / África do Sul, só que a mesma foi adquirida pelo satélite *Geoeye-1*.



(a)



(b)

Figura 1. Imagem de uma região da Cidade do Cabo – Western Cape / África do Sul, (a) *Landsat 8* e (b) *Geoeye-1*.

De acordo com a sequencia estabelecida para a metodologia proposta, a imagem *Landsat 8 OLI* foi segmentada pelo método de crescimento de regiões (Figura 2a). A segmentação teve por objetivo agrupar pixels com comportamentos espectrais similares a fim de obter tonalidades mais homogêneas e representativas de cada alvo primário. Após a segmentação, a imagem recebeu a classificação pelo método de máxima verossimilhança gaussiana (Figura 2b), a classificação buscou separar a zona urbana da zona rural, e com essa finalidade utilizou amostras de água, zona urbana e zona rural. A partir dessa classificação foi gerada uma máscara para cada classe, assim permitindo retirar o alvo de interesse de cada imagem.



Figura 2. Segmentação (a) e classificação (b) da imagem segmentada do sensor *Landsat 8 OLI*, em branco está representada a zona urbana, em cinza claro a zona rural e em preto a água.

Dando segmento à metodologia proposta, as áreas identificadas como urbana (regiões em branco) foram classificadas utilizando árvore de decisão enquanto as áreas rurais (regiões em cinza) foram classificadas pelo método de máxima verossimilhança gaussiana.

No procedimento de amostragem foram coletadas amostras de corpos d'água, telhados de barro, telhados de concreto, telhados de amianto, vias pavimentadas e vegetação. O treinamento do classificador por árvore de decisão foi realizado através do algoritmo C4.5 utilizando os 4 canais espectrais da imagem *Geoeye* com as amostras de corpos d'água (1), vegetação (2), ruas pavimentadas (3), telhados de concreto (4), barro (5) e amianto (6). A árvore de decisão produzida está ilustrada no diagrama da Figura 3.






Figura 3. Árvore de decisão produzida pelo algoritmo C4.5 para a porção urbana da imagem de alta resolução espacial.

A figura 4a representa a classificação da zona urbana do município, a mesma foi realizada pelo método de árvore de decisão utilizando a análise por objeto e atingiu uma acurácia global de 93,1%, segundo validação cruzada com as amostras de treinamento. A porção urbana da cena foi classificada utilizando o classificador de máxima verossimilhança gaussiana considerando-se amostras de apenas duas classes, vegetação e rocha, obtendo acurácia global de 94,5%(85,3). A Figura 4b apresenta a classificação da área rural do município em classes de vegetação e rocha.



(a)



(b)

Figura 4. Classificação parcial da cena selecionada para os experimentos. (a) Classificação da imagem de alta resolução espacial *Geoeye* e (b) classificação da imagem de baixa resolução espacial *Landsat*.

A seguir, os dois mapas de classificação são unidos dando origem ao mapa final da classificação. A figura 8 representa a união das duas classificações distintas, geradas por imagens que apresentam resoluções espaciais diferentes.




Figura 5. Mapa final da classificação produzido pela união das classificações anteriores.

Para fins de validação, a imagem classificada unicamente através da técnica por objetos foi produzida e visualmente comparada com o resultado da Figura 5. A comparação entre as duas imagens mostrou que nas porções inferiores da cena, majoritariamente ocupadas por vegetação nativa e rochas, a classificação partindo da imagem de alta resolução espacial considerou esse ambiente exclusivamente vegetação, conferindo ainda um aspecto mais heterogêneo a esse ambiente.




Figura 6. Mapa da classificação produzido unicamente pela técnica de árvore de decisão e imagem Geoeye.

4. Conclusões

Neste trabalho uma metodologia híbrida para classificação de imagens envolvendo alvos rurais e urbanos ao mesmo tempo foi proposta e testada. A metodologia prevê a utilização de imagens de diferentes resoluções espaciais, adaptando o modelo de classificação de acordo com o ambiente e tipo de alvo encontrado. A fim de separar previamente a região rural da região urbana, a imagem de baixa resolução espacial foi segmentada na tentativa de agrupar os alvos primários da cena. Após, um classificador simples de máxima verossimilhança gaussiana foi suficiente para discriminar áreas consideradas ocupadas por alvos rurais das áreas ocupadas por residências, vias, praças e demais alvos com características urbanas.

Após a etapa inicial de separação dos alvos, dois classificadores foram utilizados simultaneamente, mas agindo em áreas distintas da cena: um na área rural e o outro na área urbana. Os resultados da classificação híbrida proposta mostraram maior correspondência nos dois tipos de alvo. Na região ocupada por alvos rurais (rochas e vegetação nativa), o classificador paramétrico orientado ao pixel pôde estimar as classes desse ambiente com maior eficiência. Já na área urbana, o classificador hierárquico orientado à objeto foi mais bem sucedido, quando comparado com o classificador simplista da área rural. Por fim, a união dos mapas parcialmente produzidos para cada ambiente produziu um resultado otimizado, unindo as vantagens de ambos os métodos em uma única cena contendo alvos heterogêneos.

Um comparação do resultado gerado pela metodologia proposta com um resultado gerado unicamente por classificação hierárquica (por árvore de decisão) orientado à objeto mostrou que o mapa produzido pela abordagem proposta apresentou um resultado qualitativo mais aceitável, principalmente nas regiões onde naturalmente um classificador por objetos tende a falhar: regiões rurais compostas por alvos naturais. No entanto, análises mais quantitativas e com um maior número de experimentos são necessárias para comprovar a eficiência da metodologia proposta para outras aplicações.

Referências

- Aguirre-gutiérrez, Jesus; Seijmonsbergen, Arie C.; Duivenvoorden, Joost F. Optimizing land cover classification accuracy for change detection, a combined pixel-based and object-based approach in a mountainous area in Mexico. *Applied Geography*, v. 34, p. 29–37, 2012.
- Benz, Ursula C.; Hofmann, Peter; Willhauck, Gregor; Lingenfelder, Iris; Heynen, Markus. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. v. 58, p. 239–258, 2004.
- Centeno, J. A. S. Sensoriamento Remoto e Processamento de Imagens Digitais. **Curitiba: Curso de Pós-Graduação em Ciências Geodésicas/UFPR**, 2004. 209 p.
- Duro, Dennis C.; Franklin, Steven E.; Dubé, Monique G. A comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT-5 HRG imagery. *Remote Sensing of Environment*, v. 118, p. 259–272, 2012.
- Gholoobi, Mohsen; Kumar, Lalit. Using object-based hierarchical classification to extract land use land cover classes from high-resolution satellite imagery in a complex urban area. *Journal of Applied Remote Sensing*, v. 9, n. 1, p. 096052, 2015.
- Landgrebe, David A. *Signal Theory Methods in Multispectral Remote Sensing*. 1. ed. Hoboken, New Jersey.: John Wiley & Sons, 2003.
- Lillesand, Thomas; Kiefer, Ralph W.; Chipman, Jonathan. *Remote Sensing and Image Interpretation*. New York, NY: John Wiley & Sons, 2014.

Mather, Paul; Tso, Brandt. *Classification Methods for Remotely Sensed Data*. 2. ed. London: CRC Press, 2009.

Moosavi, Vahid; Talebi, Ali; Shirmohammadi, Bagher. Producing a landslide inventory map using pixel-based and object-oriented approaches optimized by Taguchi method. *Geomorphology*, v. 204, p. 646–656, 2014.

Weih, Robert C; Riggan, Norman D. Object-based Classification vs . Pixel-based Classification : Comparative Importance of Multi-Resolution Imagery. v. XXXVIII, 2008.

Whiteside, Timothy G.; Boggs, Guy S.; Maier, Stefan W. Comparing object-based and pixel-based classifications for mapping savannas. *International Journal of Applied Earth Observation and Geoinformation*, v. 13, n. 6, p. 884–893, 2011.

Zhou, Weiqi; Troy, Austin; Grove, Morgan. Object-based Land Cover Classification and Change Analysis in the Baltimore Metropolitan Area Using Multitemporal High Resolution Remote Sensing Data. p. 1613–1636, 2008.

Quinlan, J.R. (1986). Induction of Decision Trees. *Machine Learning* 1:1, 81–106.

.