

Análise dos dados do satélite WorldView-2 para a discriminação de alvos urbanos semelhantes com base em algoritmos de seleção de atributos

Tessio Novack ¹
Bárbara Maria Giacom Ribeiro ¹
Hermann Johann Heinrich Kux ¹

¹ Instituto Nacional de Pesquisas Espaciais - INPE
Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil
{tessio, barbara, hermann}@dsr.inpe.br

Abstract. Feature selection methods have recently become very attractive to remote sensing research as new object-based image analysis systems have made available tens or even hundreds of spectral, textural and geometrical features to be used in classification routines. The aim of this study is to investigate, based on different feature selection algorithms, whether the additional bands of the WorldView-II sensor are indeed helpful for the discrimination of similar urban targets.

Palavras-chave: urban remote sensing, feature selection, data mining, WorldView-II, sensoriamento remoto urbano, seleção de atributos, mineração de dados, WorldView-II.

1. Introdução

Métodos de seleção de atributos tornaram-se muito atraentes para pesquisas na área de sensoriamento remoto na medida em que dezenas, e até centenas, de atributos espectrais, de textura e geométricos podem ser utilizadas em rotinas de classificação por análise orientada a objeto. Achar os atributos mais adequados para a discriminação de duas ou mais classes não é uma tarefa fácil quando uma análise exploratória convencional é executada (por exemplo, plotagem de espalhamento bidimensional, histogramas, visualização de atributos em níveis de cinza, etc.).

O sistema sensor óptico multiespectral WorldView-II, lançado em 2009, revolucionou a área de sensoriamento remoto urbano. Trata-se do primeiro satélite de alta resolução dispondo de 8 bandas espectrais estreitas, alcançando da faixa do azul até o infravermelho próximo. Portanto, se um procedimento de segmentação for executado com estas imagens, um grande número de atributos dos segmentos podem ser criados e explorados para a definição de regras de classificação. O objetivo deste estudo é analisar se bandas adicionais do sensor WorldView-II são de fato úteis para a discriminação de diferentes classes urbanas, com base em diferentes algoritmos de seleção de atributos.

2. Metodologia

2.1 Dados de Entrada

Os dados de entrada para este trabalho correspondem a duas imagens do sensor WorldView-II: uma imagem pancromática (resolução espacial de 0,5 m) e uma imagem multiespectral com oito bandas espectrais: *Coastal*, *Blue*, *Green*, *Yellow*, *Red*, *Red-Edge*, *Near Infra-Red 1 (NIR-1)* e *Near Infra-Red 2 (NIR-2)* (resolução espacial de 2,0 m). As imagens são do tipo *OrthoRectified3*, obtidas em 6 de dezembro de 2009, com ângulo *off-nadir* 22,2° e resolução radiométrica de 11 *bits*. A Figura 1 mostra as curvas espectrais das bandas do WorldView-II.

2.2. Área de Estudo

As amostras das classes de cobertura da terra consideradas foram obtidas na cidade de São Paulo. Sua área urbana apresenta grande diversidade de telhados de cimento, passeios de concreto e ruas de pavimentação asfáltica em diferentes estados de conservação. A disposição

especial das amostras coletadas para este trabalho não obedeceu a nenhuma regra, o que diminui a eficiência no uso de atributos geométricos ou regras de contexto para a discriminação destes alvos.




Figura 1 – Curvas espectrais: respostas espectrais normalizadas das bandas do sensor WorldView-II (adaptado de DIGITAL GLOBE, 2010).

2.3. Procedimentos

Este trabalho desenvolveu-se nas seguintes etapas: pré-processamento das imagens; análise exploratória e caracterização das classes; elaboração da rede semântica; classificação e avaliação dos resultados.

Primeiramente, as imagens foram fusionadas para combinar a informação espectral das 8 bandas do sensor WorldView-II com a banda pancromática de resolução espacial mais alta (0,5 m). A fusão de imagens utilizou o algoritmo de Principais Componentes (WELCH e EHLERS, 1987), com o método de re-amostragem por convolução cúbica.

A seguir, as imagens foram segmentadas usando o algoritmo de segmentação multi-resolução, disponível no *Definiens Developer System*. Foram utilizados os valores 0.1 e 0.5 para os parâmetros '*Shape*' (Forma) e '*Compactness*' (Compacidade) respectivamente, e o parâmetro '*Scale*' (Escala) ajustado em 40. Somente as bandas do azul, verde e vermelho foram usadas no passo de segmentação. Estes parâmetros forneceram previamente bons resultados quando aplicados em imagens do sensor QuickBird-II (NOVACK e KUX, 2010).

Após a segmentação, foram coletadas 1140 amostras de segmentos de diferentes classes de cobertura da terra, exportados com 588 atributos espectrais e de textura disponíveis no sistema *Definiens Developer*. As amostras das classes foram então organizadas em quatro grupos, e a Figura 2 mostra exemplos de objetos de cada grupo.

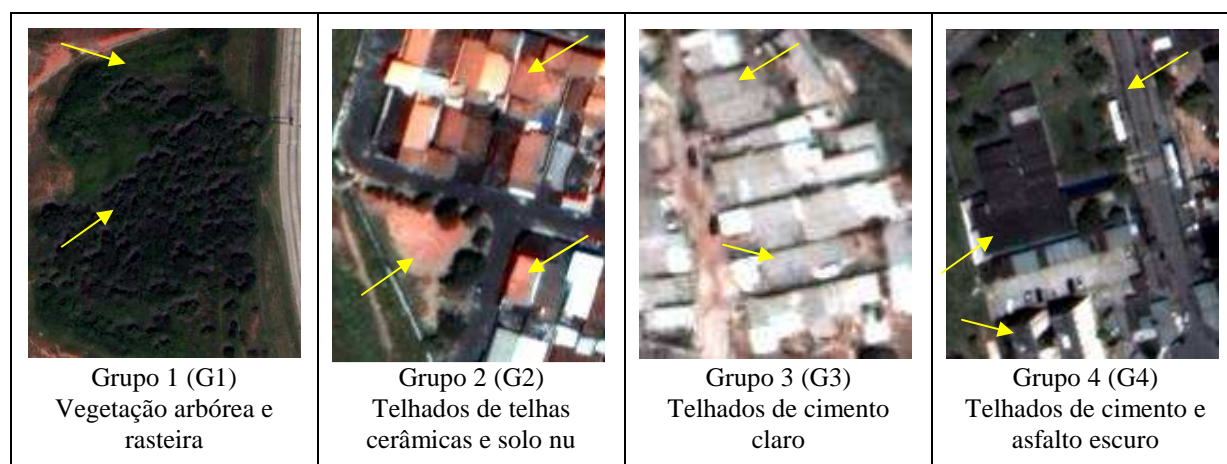


Figura 2 – Exemplos de objetos de cada grupo de análise (imagem WorldView-II, composição: R(5) G(3) B(2)).

Cada grupo contém classes que freqüentemente se confundem entre si, causando classificações errôneas de cobertura do solo (KUX e ARAÚJO, 2008; NOVACK e KUX, 2010; RIBEIRO, 2010).

Após agrupar as amostras, foram aplicados algoritmos de seleção de atributos para cada grupo, para verificar quais os atributos mais adequados para a discriminação das classes em cada grupo. Os algoritmos de seleção de atributos usados nesta análise foram: (1) *Infogain* (TSO e MATHER, 2009), que computa o ganho de informação baseado na medida de entropia para avaliar a relevância de um atributo com relação às classes; (2) *Relief-F* (KONONENKO, 1994), que avalia o valor de um atributo através de uma amostragem repetitiva de instâncias e considerando o valor de uma cada atributo para a(s) instância(s) mais próxima(s) da mesma e de outras classes; (3) *Fast Correlation-Based Filter (FCBF)* (YU e LIU, 2003), que se baseia numa medida de correlação e numa análise de relevância/redundância – este algoritmo deve ser usado em conjunto com um avaliador de atributos, que neste caso é a Incerteza Simétrica (*Symmetrical Uncertainty*) (YU e LIU, 2003); e (4) o algoritmo de Floresta Randômica (*Random Forest*) (SMITH, 2010), que também fornece uma gradação da relevância dos atributos.

No caso do algoritmo *Relief-F*, foram considerados dez vizinhos mais próximos ponderados pelas suas distâncias às amostras selecionadas aleatoriamente, para se obter as distâncias entre as classes. Para o cálculo da relevância dos atributos a partir do algoritmo Floresta Randômica, 100 árvores foram criadas. Os algoritmos *InfoGain*, *FCBF* e *Relief-F* estão disponíveis em todas as versões do sistema WEKA (2010), um *software* de livre acesso e de código aberto para tarefas de mineração de dados. O trabalho de Livingston (2005) fornece o *link* para o acesso à extensão do WEKA contendo o algoritmo *Random Forest*.

Somente algoritmos que fornecem uma gradação dos atributos foram utilizados nas análises, visto que a intenção deste trabalho é descobrir a ordem de relevância dos atributos e se os atributos disponíveis exclusivamente no sistema sensor WorldView-II são de fato de grande ajuda para diminuir classificações errôneas dentre estas classes.

4. Resultados e Discussão

Os resultados obtidos na mineração de dados com cada algoritmo são apresentados nas Tabelas 1 a 4. Encontram-se relacionados apenas os primeiros cinco atributos com maiores valores de relevância, ou seja, os mais "indicados" para identificação de cada grupo de objetos.

Primeiramente, com relação ao desempenho em termos de tempo de processamento, é necessário realçar que os algoritmos *InfoGain*, *FCBF* e *Relief-F* fornecem os resultados quase que instantaneamente, enquanto o *Random Forest* levou em média 10 minutos para processar os resultados. Certamente, isto depende do número de árvores do *RandomForest*, assim como o *Relief-F* depende do número de vizinhos mais próximos considerados. De qualquer forma, custos computacionais serão considerados nesta análise, visto que foi usado um computador comum nas análises.

A partir da análise das Tabelas 1 a 4, verifica-se que os atributos selecionados pelos quatro algoritmos, cuja heurística de pesquisa são completamente distintas, são os mesmos, em muitos casos, para cada grupo de classes. Em cada um destes grupos, o algoritmo *FCBF* selecionou atributos não aparecem nas demais seleções. Isto deve-se ao *FCBF* não considerar somente a relevância dos atributos, mas também a redundância entre os mesmos.

No que se refere aos valores de relevância dos atributos selecionados, há uma tendência de que as classes do grupo G1 sejam melhor separáveis, ou seja, possuem distinção mais fácil, seguidas por aquelas dos grupos G2 e G3/G4. Em todos os casos, a maioria dos atributos selecionados são simples operações matemáticas de bandas (ao todo, 68) ao invés de feições de textura (somente 12).

Tabela 1: Seleção de atributos para as classes do Grupo 1.

<i>InfoGain</i>			<i>Relief-F</i>		
Rank	Nome do atributo	Valor de relevância	Rank	Nome do atributo	Valor de relevância
1	Média - banda 3	0.824	1	Média - banda 3	0.309
2	Valor do <i>pixel</i> - banda 3	0.787	2	Menor valor de <i>pixel</i> - banda 3	0.272
3	Menor valor de <i>pixel</i> - banda 4	0.728	3	Média - banda 4	0.244
4	Média - banda 4	0.728	4	Menor valor de <i>pixel</i> - banda 4	0.221
5	Menor valor de <i>pixel</i> - banda 5	0.661	5	Razão - banda 2 / bandas 2, 3, 5, 7 ^a	0.198

<i>FCBF</i>			<i>Random Forest</i>		
Rank	Nome do atributo	Valor de relevância	Rank	Nome do atributo	Valor de relevância
1	Média - banda 3	0.906	1	Menor valor de <i>pixel</i> - banda 3	2.86
2	Menor valor de <i>pixel</i> - banda 4	0.706	2	Média - banda 3	2.83
3	Momento Angular de Segunda Ordem GLDV ^b - banda 1 (135°)	0.473	3	Menor valor de <i>pixel</i> - banda 2	2.55
4	Brilho - bandas 2, 3, 5, 7 ^a	0.411	4	Brilho	2.14
5	Contraste GLDV - banda 4 (135°)	0.211	5	Maior valor de <i>pixel</i> - banda 3	2.14

^a As bandas 2, 3, 5 e 7 são equivalentes, respectivamente, às bandas 1, 2, 3 e 4 do sensor QuickBird-II.

^b GLDV: *Gray-Level Difference Vector* (Vetor de Diferença de Nível de Cinza).

Tabela 2: Seleção de atributos para as classes do Grupo 2.

<i>InfoGain</i>			<i>Relief-F</i>		
Rank	Nome do atributo	Valor de relevância	Rank	Nome do atributo	Valor de relevância
1	Menor valor de <i>pixel</i> - banda 2	0.401	1	Desvio padrão - banda 7	0.106
2	Desvio padrão - banda 7	0.384	2	Menor valor de <i>pixel</i> - banda 2	0.104
3	Menor valor de <i>pixel</i> - banda 3	0.379	3	Menor valor de <i>pixel</i> - banda 3	0.103
4	Momento Angular de Segunda Ordem GLDV ^b (0°)	0.359	4	Média - banda 3	0.102
5	Menor valor de <i>pixel</i> - banda 1	0.354	5	Desvio padrão - banda 6	0.099

<i>FCBF</i>			<i>Random Forest</i>		
Rank	Nome do atributo	Valor de relevância	Rank	Nome do atributo	Valor de relevância
1	Entropia GLDV - banda 7 (90°)	0.317	1	Menor valor de <i>pixel</i> - banda 3	1.24
2	Desvio padrão - banda 7	0.302	2	Média - banda 3	1.01
3	Momento Angular de Segunda Ordem GLDV ^b (0°)	0.282	3	Momento Angular de 2ª Ordem GLDV - banda 8 (todas direções)	0.88
4	Menor valor de <i>pixel</i> - banda 2	0.272	4	Entropia GLDV - (0°)	0.73
5	Razão - banda 3	0.228	5	Menor valor de <i>pixel</i> - banda 1	0.71

^b GLDV: *Gray-Level Difference Vector* (Vetor de Diferença de Nível de Cinza).

Tabela 3: Seleção de atributos para as classes do Grupo 3.

<i>InfoGain</i>			<i>Relief-F</i>		
Rank	Nome do atributo	Valor de relevância	Rank	Nome do atributo	Valor de relevância
1	Razão - banda 3	0.311	1	Razão - banda 8	0.136
2	Razão - banda 2 / bandas 2, 3, 5, 7 ^a	0.302	2	Razão - banda 2	0.132
3	Razão - banda 4 / bandas 2, 3, 5, 7 ^a	0.293	3	Razão - banda 7	0.126
4	Razão - banda 8	0.293	4	Razão - banda 4 / bandas 2, 3, 5, 7 ^a	0.125
5	Razão - banda 7	0.293	5	Razão - banda 1 / bandas 2, 3, 5, 7 ^a	0.124

<i>FCBF</i>			<i>Random Forest</i>		
Rank	Nome do atributo	Valor de relevância	Rank	Nome do atributo	Valor de relevância
1	Razão - banda 3	0.413	1	Razão - banda 6	1.76
2	Média - banda 1	0.159	2	Razão - banda 3	1.32
3	Desvio padrão GLCM ^c - banda 6 (135°)	0.128	3	Razão - banda 2	1.29
4	Correlação GLCM ^c - banda 7 (135°)	0.118	4	Razão - banda 7	1.27
5	Entropia GLDV ^b - banda 4 (45°)	0.082	5	Razão - banda 8	1.25

^a As bandas 2, 3, 5 e 7 são equivalentes, respectivamente, às bandas 1, 2, 3 e 4 do sensor QuickBird-II.

^b GLDV: *Gray-Level Difference Vector* (Vetor de Diferença de Nível de Cinza).

^c GLCM: *Gray-Level Co-occurrence Matrix* (Matriz de Co-ocorrência de Níveis de Cinza).

Tabela 4: Seleção de atributos para as classes do Grupo 4.

<i>InfoGain</i>			<i>Relief-F</i>		
Rank	Nome do atributo	Valor de relevância	Rank	Nome do atributo	Valor de relevância
1	Razão - banda 3	0.536	1	Razão - banda 8	0.269
2	Razão - banda 2 / bandas 2, 3, 5, 7 ^a	0.514	2	Razão - banda 3	0.209
3	Razão - banda 8	0.503	3	Razão - banda 2 / bandas 2, 3, 5, 7 ^a	0.181
4	Diferença Máxima ^b	0.385	4	Razão - banda 4 / bandas 2, 3, 5, 7 ^a	0.137
5	Razão - banda 4 / bandas 2, 3, 5, 7 ^a	0.358	5	Razão - banda 4	0.132

<i>FCBF</i>			<i>Random Forest</i>		
Rank	Nome do atributo	Valor de relevância	Rank	Nome do atributo	Valor de relevância
1	Razão - banda 3	0.543	1	Razão - banda 2 / bandas 2, 3, 5, 7 ^a	0.48
2	Diferença Máxima ^b	0.385	2	Média - banda 8	0.47
3	Maior valor de <i>pixel</i> - banda 8	0.289	3	Razão - banda 4 / bandas 2, 3, 5, 7 ^a	0.35
4	Dissimilaridade GLCM ^c - (90°)	0.223	4	Razão - banda 4	0.31
5	Dissimilaridade GLCM ^c - banda 8 (0°)	0.155	5	Diferença Máxima ^b	0.29

^a As bandas 2, 3, 5 e 7 são equivalentes, respectivamente, às bandas 1, 2, 3 e 4 do sensor QuickBird-II.

^b Atributo no qual subtrai-se a média dos pixels da banda de maior brilho da média dos *pixels* da banda de menor brilho. Em seguida, o resultado é dividido pelo brilho geral do segmento.

^c GLCM: *Gray-Level Co-occurrence Matrix* (Matriz de Co-ocorrência de Níveis de Cinza).

No grupo G1, a banda amarela (banda 4), aparentemente mostrou potencial para a discriminação dos tipos de vegetação (somente o algoritmo *Random Forest* não selecionou uma feição desta banda), bem como a banda 1 (*Coastal blue*). Não obstante, a maioria dos atributos é calculada a partir das bandas azul, verde e vermelha. No grupo G2, as bandas 1, 6, 7 e 8 também apareceram entre os atributos selecionados, especialmente algumas feições da banda 7, que apareceram em primeiro lugar nos algoritmos *Relief-F* e *FCBF*. Considerando a Tabela 3, dois aspectos são evidentes: (1º) os atributos de razão de bandas são os mais apropriados para a separação de classes no grupo G3; e (2º) as bandas 1, 6 e especialmente 7 e 8 são adequadas para discriminar pavimentos de concreto e telhados de cimento claro. Os atributos da banda 8 também foram selecionados para a distinção das classes pavimentos de asfalto e telhados de cimento escuro.

5. Conclusão e Trabalhos Futuros

Os resultados mostram que, na maioria dos casos, as bandas disponíveis nos sensores QuickBird-II e IKONOS, são as mais relevantes para a distinção de classes em cada grupo. Por outro lado, atributos de bandas presentes tão somente no sistema WorldView-II também foram selecionados na maioria das vezes (cada algoritmo em cada grupo), significando que eles podem ser usados em regras de classificação, possivelmente fornecendo resultados melhores.

Em trabalhos futuros, pretende-se verificar, através de classificação, se as bandas *Coastal Blue*, *Yellow*, *Red-Edge*, *NIR-1* e *NIR-2* desempenham um importante papel para a classificação e se o seu uso resulta num importante ganho de precisão temática da classificação.

Este artigo comunica os resultados da primeira análise exploratória de atributos, executada com amostras coletadas num ambiente urbano muito denso e complexo. A partir deste ponto, muito pode ser feito com mineração de dados (*data mining*) e análise de aprendizado de máquina, revelando a importância das bandas do WorldView-II para a discriminação de alvos urbanos similares.

Agradecimentos

Os autores agradecem à empresa Digital Globe, na pessoa do Dr. Kumar Navulur, pela cessão das imagens WorldView-II, à CAPES, Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, pela concessão de bolsa do Programa de Capacitação Institucional (PCI) através da OBT (Coordenação-Geral de Observação da Terra), INPE.

Referências Bibliográficas

DEVELOPER SYSTEM. Definiens Developer User Guide. Disponível em: <<http://www.definiensimaging.com/down/ecognition>>

DIGITAL GLOBE. **Spectral Response for Digital Globe WorldView 1 and WorldView 2 Earth Imaging Instruments**. 2010. Disponível em: <http://www.digitalglobe.com/downloads/spacecraft/WV1_WV2_Spectral_Response.pdf>

KONONENKO, I. Estimating attributes: Analysis and extension of RELIEF. In: European Conference on Machine Learning, 1994. **Proceedings...** Catania: Springer-Verlag, 1994. pp. 171-182.

KUX, H. J. H., ARAUJO, E. H. G. Object-based image analysis using QuickBird satellite image and GIS data, case study Belo Horizonte (Brazil). In: BLASCHKE, T.; LANG, S.; HAY, G. J. (Eds.) **Object-Based Image Analysis – Spatial Concepts for Knowledge-Driven Remote Sensing Applications**. Berlin: Springer-Verlag, 2008. 817 p. Cap. 6.1, p. 531-553.

LIVINGSTON, F. Implementation of Breiman's Random Forest Machine Learning Algorithm. **Machine Learning Journal Paper**, 2005. Disponível em: <<http://gogoshen.org/ml2005/Journal%20Paper/JournalPaperLivingston.pdf>>.

NOVACK, T., KUX, H. J. H. Urban land cover and land use classification of an informal settlement area using the open-source knowledge-based system InterIMAGE. **Journal of Spatial Science**, v. 55, n. 1, 2010, p. 23-41.

RIBEIRO, B. M. G. **Avaliação das imagens WorldView-II para o mapeamento da cobertura do solo urbano utilizando o sistema InterIMAGE**. 2010. 177 p. INPE-16761-TDI/1689. Dissertação (Mestrado em Sensoriamento Remoto). INPE - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2010. Disponível em: <<http://urlib.net/sid.inpe.br/mtc-19@80/2010/08.03.12.52.20>>

SMITH, A. Image segmentation scale parameter optimization and land cover classification using the Random Forest algorithm. **Journal of Spatial Science**. v. 55, n. 1, 2010, pp. 69-80.

TSO, B., MATHER, P. **Classification Methods for Remotely Sensed Data** (2^a ed.). London: CRC Press, 2009.

YU, L., LIU, H. Feature selection for high dimensional data: a fast correlation-based filter solution. In: XX International Conference on Machine Learning, 2003, Washington DC, EUA. **Proceedings...**

WEKA DATA MINING SOFTWARE IN JAVA. Disponível em: <<http://www.cs.waikato.ac.nz/ml/weka/>>. Acessado em 25 de Outubro de 2010

WELCH, R., EHLERS, W. Merging Multiresolution SPOT HRV and Landsat TM Data. **Photogrammetric Engineering & Remote Sensing**, v. 53, n. 3, 1987, p. 301-303.