

AVALIAÇÃO DOS MÉTODOS ORIENTADO A OBJETO E “PIXEL A PIXEL” NA CLASSIFICAÇÃO DO USO E OCUPAÇÃO DA TERRA EM IMAGEM RAPIDEYE

Carla Eva Prichoa ¹
Selma Regina Aranha Ribeiro ²
Pedro Molina Holgado ³

^{1,3} Universidad Autónoma de Madrid - UAM
Ciudad Universitaria de Cantoblanco C/ Francisco Tomás y Valiente, 1 - 28049 Madrid-España
cprichoa@yahoo.com.br; pedro.molina@uam.es

² Universidade Estadual de Ponta Grossa - UEPG
Av. General Carlos Cavalcanti, 4748 – Cep: 84030-900 Ponta Grossa/Paraná – Brasil
selmar.aranha@gmail.com

Resumo: A melhoria das resoluções espacial, espectral, temporal e radiométrica dos atuais sistemas de satélites mundiais dificulta a extração e processamento de dados pelos métodos tradicionais de análise, como a classificação “pixel a pixel”. Neste estudo utilizou-se imagem do sensor RapidEye/2013 alusivo a um segmento de paisagem do rio Pitangui/Ponta Grossa/Paraná/Brasil com o objetivo de avaliar o nível de abstração dos algoritmos de classificação por pixel e orientado a objeto utilizando o classificador *Support Vector Machine* - SVM – na separação das classes. O método orientado a objeto tem a vantagem de utilizar atributos espaciais, espectrais e texturais para a classificação o que se traduz em benefício ao abordar um espaço de uso heterogêneo e/em imagem de alta resolução. De acordo com os resultados de acuracidade *kappa* e teste "F" pareado, ambos métodos podem servir de apoio em estudos de uso e ocupação da terra, porém, a classificação orientada a objeto mostrou-se mais eficiente devido, principalmente, à sua capacidade de separar as diferentes classes dependendo menor tempo. Apesar da classificação “pixel a pixel” apresentar valor *kappa* considerado satisfatório (0,91) observou-se ocorrência de confusão espectral com as classes: área urbana, campo, cultura 1 e cultura 2.

Abstract: The improvement of spatial resolution, spectral, temporal, and radiometric of current systems of satellites world hinders the extraction and processing of data by traditional methods of analysis, such as the pixel based classification. In this study was used sensor image RapidEye/2013 alluding to a landscape segment of the river Pitangui/Ponta Grossa/Parana/Brazil aiming to evaluate the level of abstraction of the classification for pixel and object-based algorithms using the classifier Support Vector Machine - SVM – in the separation of classes. The object-oriented method has the advantage of using spatial, spectral and textural attributes for the classification which results in benefit to approach a heterogeneous space of use in high resolution image. The results of accuracy *kappa* and test "F" paired, showed that both methods can be used to support studies of use and occupation of the land, however, the object-oriented classification proved to be more efficient, mainly due to their ability to separate the different classes spending less time. Although the pixel-based classification presents *kappa* value considered satisfactory (0.91) it was observed the occurrence of spectral confusion with classes: urban area, field, culture 1 and culture 2.

Palavras-chave: pitangui river, remote sensing, image processing, rio Pitangui, sensoriamento remoto, processamento de imagens

1. Introdução

Considera-se as imagens orbitais de Sensoriamento Remoto como uma das fontes mais tradicionais para aquisição de informações sobre a superfície terrestre. Estas informações fornecem a base para grande número de aplicações, incluindo monitoramento local, regional e global dos recursos, da cobertura da terra e suas alterações, bem como outros estudos ambientais.

Os dados de imagens de sensoriamento remoto apresentam melhor relação custo-benefício em comparação com as fotografias aéreas, principalmente devido ao aumento da disponibilidade de dados de sensoriamento remoto por satélite, associado à elevada taxa de revisita dos sistemas de satélites, e devido às melhorias nas resoluções espaciais, espectrais e radiométricas dos dados de sensoriamento remoto orbital (Blaschke e Kux, 2007).

Tratando de técnicas de classificação de uso e cobertura do solo, torna-se necessário à utilização de técnicas que permitam a avaliação espaço-temporal de maneira otimizada das áreas. Dentre os métodos existentes no universo de geoprocessamento destaca-se a classificação digital das imagens de satélite. Seu processo se baseia na distinção e identificação de distintas classes que possuem comportamentos espectrais diferenciados, mediante algoritmos de classificação, originando uma nova imagem temática.

Dentre os algoritmos utilizados numa classificação destacam-se “pixel a pixel” e orientado a objeto. Classificadores “pixel a pixel” utilizam apenas a informação espectral, isoladamente, de cada pixel para encontrar a classe mais provável para o pixel. Para a classificação orientada a objeto, a análise é realizada sobre objetos ou segmentos na imagem e não apenas sobre pixels. Na imagem um objeto representa uma entidade que pode ser individualizada, tem atributos próprios e as mesmas propriedades da classe que lhe deu origem (Definiens, 2014).

O classificador SVM (*Support Vector Machine*) é um método não paramétrico que tem apresentado resultados superiores aos outros métodos de classificação, como Redes Neurais e Árvores de Decisão, para imagens de sensoriamento remoto (Huang et al., 2002; Foody e Mathur, 2004; Pal e Mather, 2005). O SVM consiste em uma técnica computacional de aprendizado para problemas de reconhecimento de padrão. Introduzida por meio da teoria estatística de aprendizagem por Vapnik (1995), essa classificação é baseada no princípio de separação ótima entre classes, tal que se as classes são separáveis, a solução é escolhida de forma a separar o máximo as classes.

Uma das vantagens do algoritmo SVM relaciona-se a teoria bem estabelecida dentro da matemática e estatística; possui robustez em dados de grandes dimensões como as imagens orbitais; ótima capacidade de generalização, ou seja, é eficaz para prever dados que não pertençam ao conjunto utilizado no treinamento. O classificador SVM utiliza superfície de decisão para separar classes linearmente separáveis, maximizando a margem de separação entre elas. Essa superfície é chamada de hiperplano ideal e os pontos próximos (amostragens de treinamento) à margem do hiperplano ideal são chamados de vetores de suporte (Blaschke e Kux, 2007).

Atualmente, uma grande revolução no processamento digital de dados de sensoriamento remoto vem ocorrendo, principalmente devido às elevadas resoluções espaciais, que exigem um novo tipo de processamento, além da observação dos pixels de forma unitária. Ao invés de classificar os pixels individualmente quanto às suas características espectrais, os novos procedimentos consideram a delimitação de objetos com características espectrais (ou radiométricas) homogêneas como base para o processamento posterior. A classificação passa a considerar informações extraídas desses objetos, como resposta espectral média, variância, dimensões, forma e textura (Blaschke e Kux, 2007). Em outra instância, a classificação passa a ser influenciada não apenas pelas características dos objetos outrora definidas, mas também pelo contexto. As informações contextuais descrevem como um objeto de interesse pode ser afetado pelos objetos vizinhos, associando-se informações do ambiente ao elemento (Hay e Castilla, 2008).

Atualmente a técnica GEOBIA - Análise Orientada a Objeto Geográfico - é amplamente empregada nos estudos da Ciência Geográfica e áreas afins com o intuito de otimizar os trabalhos exaustivos a campo e gerar resultados fidedignos. Autores como Venturieri e Santos, (1998); Shapiro e Stockman, (2001); Fan and Xia, (2001); Gonzales e Woods, (2002) utilizam a técnica por

ser amplamente usada em imagens de média e alta resolução a fim de otimizar a tradicional interpretação visual.

Objetivando a classificação de uso e cobertura do solo e de acordo com a disponibilidade de novos métodos na literatura, este artigo visa avaliar o nível de abstração dos algoritmos de classificação SVM por pixel e SVM Orientado a Objetos na separação de classes de um segmento fluvial do rio Pitangui/Paraná advindo do Satélite RapidEye/2013. O recorte de “paisagem fluvial” já foi objeto de estudo de pesquisa de mestrado e atualmente de doutorado. Por isso, além do objetivo supracitado, poder-se-á vincular os resultados desta análise com o método de investigação de “paisagens fluviais” desenvolvido na Europa e empregado na pesquisa de doutorado.

2. Material e métodos

A área de estudo está localizada na região centro-oeste do Estado do Paraná (Figura 1). O Rio Pitangui pertence à Bacia Hidrográfica do Rio Pitangui que possui uma área de 927,3 Km², situando-se entre as latitudes 25°46’40” e 25°49’06” S e as longitudes 49°46’40” e 50°17’38” W. Tem suas nascentes no Primeiro Planalto Paranaense, no município de Castro e percorre os municípios de Carambeí e Ponta Grossa no Segundo Planalto Paranaense, desembocando no rio Tibagi à oeste do estado.




Figura 1: Localização da área de estudo.

O desenvolvimento deste estudo foi efetuado nas seguintes etapas (Figura 2): preparação da imagem, coleta de amostras de treinamento, classificação “pixel a pixel” (SVM), segmentação, classificação orientada a objeto (SVM), validação com teste “F” e matriz de erros e avaliação dos resultados. A imagem do sensor RapidEye possui resolução espacial de 5 metros ortorretificada, radiométrica de 12 bits, 5 bandas espectrais (Red, Green, Blue, Red-Edge, Near IR) e tempo de revisita diária (off-nadir) e 5,5 dias (nadir).

A classificação “pixel a pixel” (SVM) foi realizada no software Envi 4.7 e a classificação orientada a objeto (SVM) no Envi EX. Foi realizado teste “F” no *software Past*, o qual utiliza uma distribuição “F” para avaliar se duas amostras foram extraídas de populações com variâncias iguais (TRIOLA, 1999).

Para as amostras de treinamento foram definidas 7 classes de usos, a saber: água (correspondente aos rios e represas), vegetação (representada pelos fragmentos florestais e matas

ciliares), urbano (áreas cobertas por edificações e vias asfálticas), cultura 1, cultura 2, e cultura 3 e campo (representadas por áreas cultivadas com plantações anuais ou temporárias) e não-classificados (não representam nenhuma das classes).

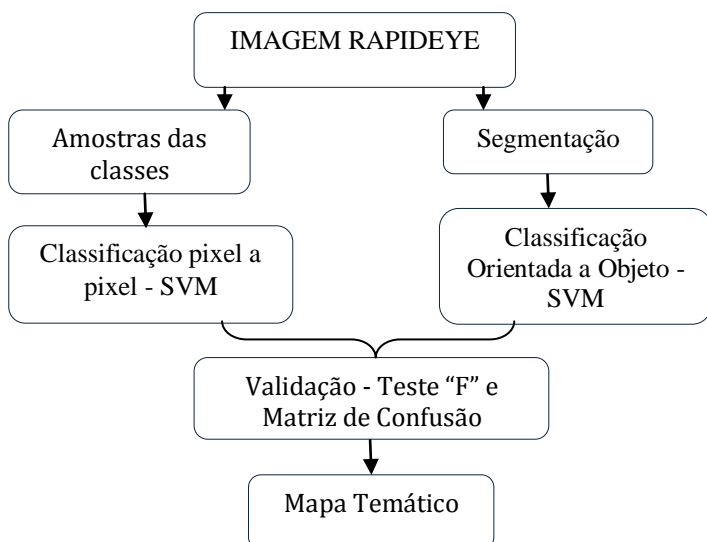


Figura 2: Sequência metodológica empregada no estudo

3. Resultados e discussão

A imagem RapidEye classificada mediante os métodos orientado a objeto e “pixel a pixel” utilizando algoritmo *Support Vector Machine* são apresentadas nas Figuras 3 e 4, respectivamente. Como descrito anteriormente a classificação originou 7 classes: água, vegetação, área urbana, cultura 1, cultura 2, cultura 3 e campo, e ainda, como existiram pixels que não foram classificados em nenhuma das classes, estes foram atribuídos à legenda como não classificados.

O método orientado a objeto (Figura 3) detectou melhor áreas de vegetação como florestas remanescentes e matas ciliares, áreas destinadas a agricultura em diversos estágios (cultura 1, cultura 2, cultura 3 e campo). Visualmente, nota-se que ocorreu comportamento espectral semelhante, principalmente, entre as classes: área urbana X cultura 2, água X vegetação.

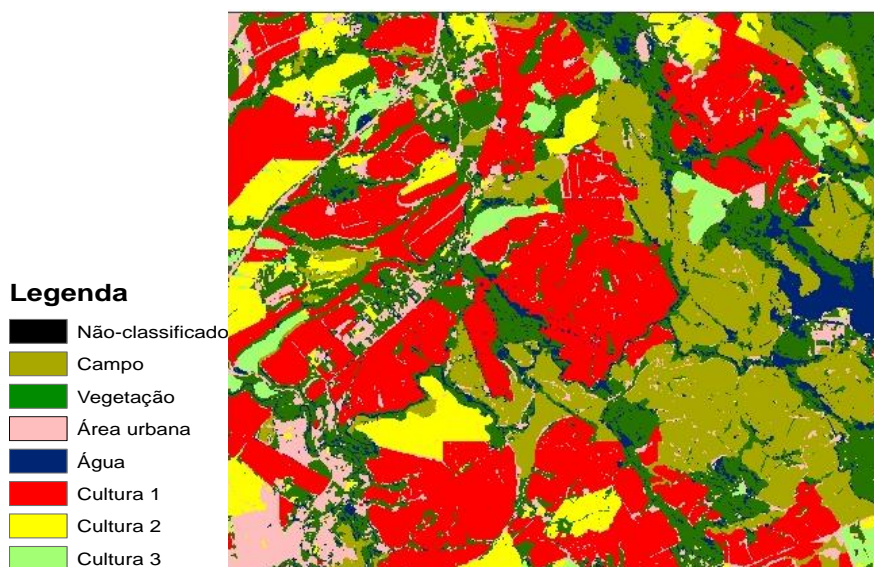


Figura 3 – Classificação orientada a objeto SVM

Para quantificar a variância entre as classes apresenta-se teste “F” (Tabela 1), comparando pares de amostras. O teste foi realizado entre classes dos dois métodos e observa-se que os valores das

classes “cultura 2” e “cultura 3” obtiveram disparidade na variação, ou seja, o total de área de cada classe resultou distinto para ambos os métodos.

Para as classes resultantes (campo, vegetação, área urbana, água e cultura 1), o teste “F” apresentou igualdade nas variações, denotando que a maioria destas classes foram distribuídas de maneira semelhante para ambas imagens temáticas e/ou métodos de classificação.

Tabela 1 – Teste “F” de duas amostras para variância.

CLASSIFICAÇÃO PIXEL A PIXEL X ORIENTADA A OBJETO		
Classes	Número de Amostras	F
Campo	5	54,703
Vegetação	5	60,313
Área Urbana	5	132,39
Água	5	86,827
Cultura 1	5	136,1
Cultura 2	5	2,9131
Cultura 3	5	2,8924

A classificação “pixel a pixel” apresentou índice *kappa* de 0,91, valor considerado satisfatório na representatividade da área, porém, observa-se, na imagem (Figura 4), e mediante matriz de erros (Tabela 2), que a classe “área urbana” apresentou confusão espectral com a classe “campo” e com a classe “cultura 1”, da mesma forma que a classe “cultura 2” se mescla com “campo”. Esta confusão espectral deve-se, principalmente, aos diferentes níveis digitais distribuídos, especialmente, sob as áreas destinadas a agricultura, porém, não abstêm-se desta análise o fato da imagem possuir alta resolução espacial, o que dificulta a análise “pixel a pixel” por apresentar elevado nível de detalhamento




Figura 4 – Classificação “pixel a pixel” SVM

Os índices altos de acuracidade da classificação “pixel a pixel” (Tabela 2) mostram que as classes foram classificadas de maneira confiável ou bastante próximas a realidade em campo. Os maiores índices de comissão e omissão ocorreram entre as classes “campo” (9,21% e 6,84%), “área urbana” (15,65% e 28,80%) e “cultura 2” (11,13% e 11,38%), respectivamente.

Tabela 2: Acuracidade e Matriz de erros.

Classes	Prod. Acc. %	User Acc. %
Campo	93.16	90.79

Vegetação	99.85	99.85
Área urbana	71.20	84.35
Água	100	97.34
Cultura 1	97,07	94.81
Cultura 2	88.62	88.87
Cultura 3	99,51	99,03
Classes	Comissão %	Omissão %
Campo	9.21	6.84
Vegetação	0.15	0.15
Área urbana	15.65	28.80
Água	2.66	0.00
Cultura 1	5.19	2.93
Cultura 2	11.13	11.38
Cultura 3	0.97	0.49

4. Considerações finais

Os resultados estatísticos como teste “F” pareado denota igualdade nas variâncias da maioria das classes, a saber: “campo”, “vegetação”, “área urbana”, “água” e “cultura 1”, porém resultou disparidade nas classes “cultura 2” e cultura 3”. A matriz de erros referente ao método “pixel a pixel”, apesar de obter índices de acuracidade e *kappa* satisfatórios resultou numa classificação espectralmente heterogênea, onde percebe-se confusão de *pixels*, principalmente, nas classes “campo”, “área urbana” e “cultura 2”.

Por isso, neste estudo, a comparação entre os métodos de classificação “pixel a pixel” e orientado a objetos utilizando algoritmo SVM em imagem de alta resolução RapidEye demonstrou que ambos os métodos forneceram dados confiáveis e/ou condizentes com a realidade em campo. No entanto, atribui-se melhor resultado à classificação orientada a objeto. Este método semiautomático preservou melhor as formas e tamanho dos alvos de interesses, pois, em sua análise além de informações espectrais inclui atributos espaciais e de textura que auxiliaram na identificação e separação das classes.

O método tradicional “pixel a pixel” classificou a área distribuindo as classes de maneira menos homogênea. Isso devido aos diferentes níveis digitais dos alvos de interesse e, sobretudo, pela alta resolução da imagem, a qual dificulta a coleta, além de, exigir máximo conhecimento do fotointérprete e maior tempo para a execução.

Neste sentido, conclui-se que em imagens de alta resolução como RapidEye, os métodos de análise carecem cada vez mais de atualizações, adaptando-se aos avanços tecnológicos dos modernos sistemas de sensores.

Referências Bibliográficas

Blaschke, T.; Kux, H. J. H., 2007. **Sensoriamento remoto e SIG avançados - novos sistemas sensores: métodos inovadores**. São Paulo: Oficina de Textos, 2ª ed.303 p.

DEFINIENS Imaging. **eCognition**: user guide. 2000, 468 p. Disponível em: <http://www.definiens-imaging.com/down/ecognition>. Acesso em: Dezembro, 2014.

- FAN, G.; XIA, X., 2001. **A Joint Multicontext and Multiscale Approach to Bayesian Image Segmentation**. IEEE Transaction on Geoscience and Remote Sensing. v. 39, n. 2, p. 2680-2688.
- FOODY, G. M.; MATHUR, A.; 2004. A Relative Evaluation of Multiclass Image Classification by Support Vector Machines. **IEEE Transactions on Geoscience and Remote Sensing**, v.42, n.6.
- GONZALES, R. C.; WOODS, R. E., 2002. **Digital Image Processing**. 2. Ed. New York: Prentice Hall. 793 p.
- HAY, G. J.; CASTILLA, G., 2008. Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline. In: T. Blaschke, S. Lang & G. Hay (eds.): **Object Based Image Analysis Spatial Concepts for Knowledge-Driven Remote Sensing Applications**. Lecture Notes in Geoinformation and cartography, 18. Springer-Verlag, Berlin, 75-89.
- HUANG, C.; DAVIS, L. S.; TOWNSHEND, J. R. G., 2002. An assessment of support vector machines for land cover classification. **International Journal of Remote Sensing**, v. 23, n. 4, p. 725-749.
- PAL, M.; MATHER, P. M., 2005. Support vector machines for classification in remote sensing. **International Journal of Remote Sensing**, v. 26, n. 5, p. 1007-1011.
- SHAPIRO, L. G.; STOCKMAN, G.C., 2001. **Computer Vision**. New Jersey: Prentice Hall.
- TRIOLA, M. F., 1999. **Introdução à Estatística**. 7th. Rio de Janeiro. Editora LTC.
- VAPNIK V. N., 1995. The Nature of Statistical Learning Theory. New York:Springer-Verlag, p. 188.
- VENTURIERI, A.; SANTOS, J.R., 1998, **Técnicas de classificação de imagens para análise de cobertura vegetal**. In: Assad, E. D.; Sano, E. E. (Ed.). Sistema de Informações Geográficas, Brasília: Embrapa-SPI/Embrapa-CPAC, Capítulo 18, p. 351-371.