

# Classificação de uso de solo baseada na análise orientada a objeto e mineração de dados utilizando imagens SPOT/HRG-5

Vagner Azarias Martins<sup>1</sup>  
Leila Maria Garcia Fonseca<sup>1</sup>

<sup>1</sup> Instituto Nacional de Pesquisas Espaciais – INPE  
Caixa Postal 515 – 12201-970 – São José dos Campos – SP, Brasil.  
vagner @dsr.inpe.br  
leila@dpi.inpe.br

**Abstract:** *The object oriented classification is commonly used in urban areas and its use in agricultural applications is still restricted. This paper aims to verify the potential of object oriented classification and data-mining techniques to process agricultural images. The methodology proposed here is tested on fused SPOT-5/HRG images in an area of Capinópolis, Minas Gerais. To project the structural classification, 57 attributes (spectral, shape, position and texture), extracted from fused image were analyzed and selected using a data mining system. A hierarchical tree was built using five attributes with Boolean logic (two spectral, two texture and one shape attributes). This technique significantly reduced the time for analysis and processing but also reduces the subjectivity in the process. The results showed a kappa index of 0.80, described as "good agreement. This result indicates the potential of object oriented classification and data-mining techniques agricultural to separate targets.*

**Palavras-chave:** agriculture, data-mining, hierarchical classification, agricultura, mineração de dados, classificação hierárquica.

## 1. Introdução

Em geral, a classificação de alvos agrícolas é realizada pautada nos atributos espectrais do alvo de cenas de sistemas sensores de média resolução. Embora os alvos agrícolas apresentem razoável homogeneidade, este método de classificação em alguns casos não é eficiente para a distinção dos alvos na cena. O emprego de métodos que utilizam outros atributos além dos espectrais pode ser uma alternativa para melhorar a classificação.

Comumente empregado em ambientes urbanos (Alves *et al.*, 2007; Pinho, 2006), a classificação orientada a objeto ainda é pouco utilizada em ambientes agrícolas (Blaschke *et al.*, 2000). Aliada a cenas de sensores de alta resolução (e.g. Ikonos e Quickbird), a técnica permite discriminar um maior número de alvos. Porém, devido à pequena faixa de imageamento dos sensores de alta resolução e a baixa resolução temporal, a identificação de alvos agrícolas é comprometida tanto pela extensão das áreas cultivadas, como pela constante alteração no uso do solo.

Quanto à classificação orientada a objeto, segundo Definiens (2008), a informação semântica necessária para a interpretação da imagem não está presente no pixel, mas nos objetos da imagem e nas relações entre eles. Tal fato eleva o número de atributos utilizados para a distinção dos diferentes alvos da cena. Para evitar que se utilizem atributos redundantes ou que não contribuam na classificação, o emprego de técnicas de mineração de dados pode ser uma boa alternativa para melhorar a classificação de uso de solo de alvos agrícolas em áreas heterogêneas.

Baseado nestas premissas, o principal objetivo deste trabalho consiste em utilizar técnicas de mineração de dados com o propósito de auxiliar a classificação orientada a objeto em uma região de atividade agrícola.

## 2. Materiais e métodos

A área do estudo (Figura 1) contempla a região de atividade agrícola localizada no município de Capinópolis (micro região de Ituiutaba - MG), perfazendo a região do Triângulo Mineiro. As coordenadas geográficas da área são: 18°40'55"S e 49°34'12"O.




Figura 1 - Localização da área de estudo

Neste estudo, utilizamos uma imagem SPOT-5/HRG datada de 5 de julho de 2003. As principais características da imagem e do sistema sensor são: resolução espacial de 10 m (bandas verde, vermelho e infravermelho próximo) e de 2,5 m para a pancromática, faixa de imageamento de 60 km e resolução temporal de 26 dias ao nadir (Spot Image, 2008). Esta configuração torna seu emprego propício ao sensoriamento remoto agrícola.

De uma forma resumida, a metodologia foi realizada nas seguintes etapas: i) recorte e fusão das imagens, ii) segmentação baseada em multiresolução e extração de atributos utilizando o aplicativo eCognition 5.0, iii) mineração dos atributos através do aplicativo WEKA 3.5 e, iv) classificação hierárquica utilizando aplicativo eCognition 5. A Figura 2 ilustra as etapas de cada processamento.

O sistema eCognition 5.0 (Definiens, 2007) é um software comercial muito utilizado para processamento de imagens de alta resolução. O aplicativo WEKA (Waykato, 2007) é um sistema de mineração de dados que possui ferramentas de pré-processamento de dados, classificação, regressão regras de clusterização, regras de associação e visualização. O sistema SPRING (Câmara *et al.*, 1996) é um sistema de informação geográfica, livre, desenvolvido pela Divisão de Processamento de Imagens do INPE.

O processo de fusão de imagens foi realizado por meio da combinação das bandas 2,3 e 4 com a banda PAN através do método de fusão de imagens IHS (Showengerdt, 1998). O resultado é a obtenção de uma imagem com resolução espacial de 2,5 m e com as cores da imagem multi-espectral.

A imagem fusionada foi segmentada por meio de um segmentador baseado em multi-resolução e crescimento de regiões. Neste segmentador, os limiares de similaridade e escala são definidos pelos parâmetros cor e forma, onde, a cor é formada pela soma ponderada dos valores dos desvios padrões de cada objeto, e a forma é a união dos parâmetros de compacidade e suavidade. O parâmetro compacidade é definido pela razão da área do objeto e o raio da circunferência abrangente. O parâmetro de suavidade expressa o limite entre objetos, onde, quanto mais fractal, maior o índice de forma (Definiens, 2008). Na geração de uma segmentação que separasse pertinentemente as variadas classes, foi necessário testar diversas configurações dos parâmetros.

Ao final da segmentação, elegeram-se pontos de coletas amostrais que foram separados em dois grupos: a) para treinamento, usado para gerar a árvore de decisão do classificador estrutural e, b) para a validação da classificação. As classes usadas na classificação foram: água; cultura; mata; pasto; solo exposto; solo preparado e; linhas de carregadores.

Para a coleta das amostras classificou-se a área com base apenas nos atributos espectrais da imagem. Ao final da classificação, as amostras foram selecionadas utilizando a ferramenta de edição matricial, onde os objetos da imagem foram classificados manualmente para corrigir alguns erros de classificação.

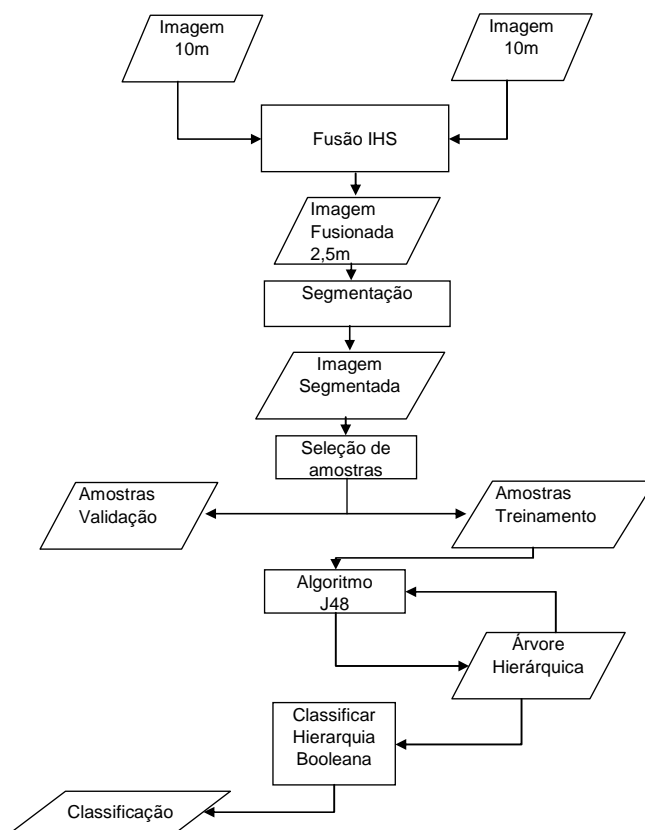


Figura 2 – Procedimento de classificação de alvos agrícolas

A classificação obtida com base nos atributos espectrais da imagem e com o uso da edição matricial usou as seguintes classes de uso do solo: cultura; mata; carreador; pasto; solo exposto; solo preparado e água. Amostras de 182 objetos divididos em dois grupos (91 amostras em cada grupo) foram selecionadas com base na interpretação do uso de solo. Um grupo de amostras foi utilizado para treinamento e outro para a validação da classificação.

Na etapa seguinte, um conjunto de atributos foi extraído e exportado para o sistema WEKA. Um total de 57 atributos espectrais, de forma, posição e textura, foram analisados e selecionados para gerar a rede semântica representada por uma árvore de decisão, que é usada para classificar os objetos.

O algoritmo de classificação por árvore de decisão utilizado foi o *J48*, implementado no WEKA. Segundo Goldschmidt e Passos (2005), uma árvore de decisão é uma estrutura em que cada nó interno da árvore representa uma decisão sobre um atributo que determina como os dados são particionados pelos seus nós filhos. Para classificar um objeto, começa-se pela raiz da árvore, faz-se o teste de decisão usando os atributos associados aquele nó e seleciona-se o ramo da árvore cujo teste foi positivo. O processo continua até encontrar uma folha que indica a classe a qual o objeto pertence.

Esta técnica foi útil nesta aplicação, porque as imagens obtidas por sensores orbitais possuem uma quantidade grande de informações que podem ser mais bem exploradas por meio de técnicas de mineração de dados. O processo de conhecimento destas informações não é trivial, mas, é possível reconhecer padrões que sejam válidos, novos (previamente

desconhecidos), potencialmente úteis e compreensíveis, auxiliando na elucidação do problema em questão (Fayyad *et al.*, 1996).

Com a árvore hierárquica gerada pelo algoritmo J48, a classificação hierárquica orientada a objeto seguindo a lógica booleana foi realizada. Para a validação dos resultados, o teste *supplied test set*, implementado no WEKA, foi utilizado. Os resultados da validação são apresentados por meio de matriz de confusão e estatística *Kappa*.

### 3. Resultados e Discussão

A Figura 3 mostra a imagem fusionada com a resolução espacial de 2,5 m, obtida na primeira fase de processamento. Pode-se observar, que diferentes classes de uso de solo, como pasto, cultivo, mata e solo preparado são facilmente identificáveis. Além disso, detalhes dos “carreadores” e a divisão de talhões nas lavouras, que são difíceis de serem identificados em imagens de sensores de média resolução tornaram-se mais evidentes.




Figura 3 - Área de estudo com resolução de 2,5m

Resultado do teste com diferentes valores de atributos, a segmentação multiresolução que apresentou melhor resultado, separando inclusive as áreas de “carreador”, apresentou os seguintes parâmetros de entrada: escala de 125; peso 1 para a banda do IVP e 0 para as bandas verde e vermelho; cor com 0,8 e; compacidade com 0,8. A imagem foi segmentada em 644 objetos como mostra a Figura 4.




Figura 4 - Segmentação baseada em multiresolução da área de estudo

O algoritmo de mineração de dados elegeu como os melhores atributos para a separação das classes de uso de solo, o brilho e a média da banda 3 (atributos espectrais), a compacidade (atributo de forma) e o GLCM das bandas 2 e 3 (atributos de textura). A árvore hierárquica gerada possui 3 ramos e pode ser visualizada na Figura 5. Observa-se nesta figura que, a classe “preparado” (solo preparado) aparece em dois nós da árvore. Em um nó apresenta-se em conjunto com a classe “pasto”, cujas classes estão separadas neste nível pelo atributo de textura da banda 2. No outro nó, a classe “preparado” apresenta-se em conjunto com a classe “exposto”, sendo separado pelo atributo de brilho. Tal fato deve-se possivelmente ao sistema de “gradagem” utilizado no preparo do solo. Como este sistema não é linear em todas as áreas, os objetos referentes a esta classe variam de tons mais claros a tons mais escuros.

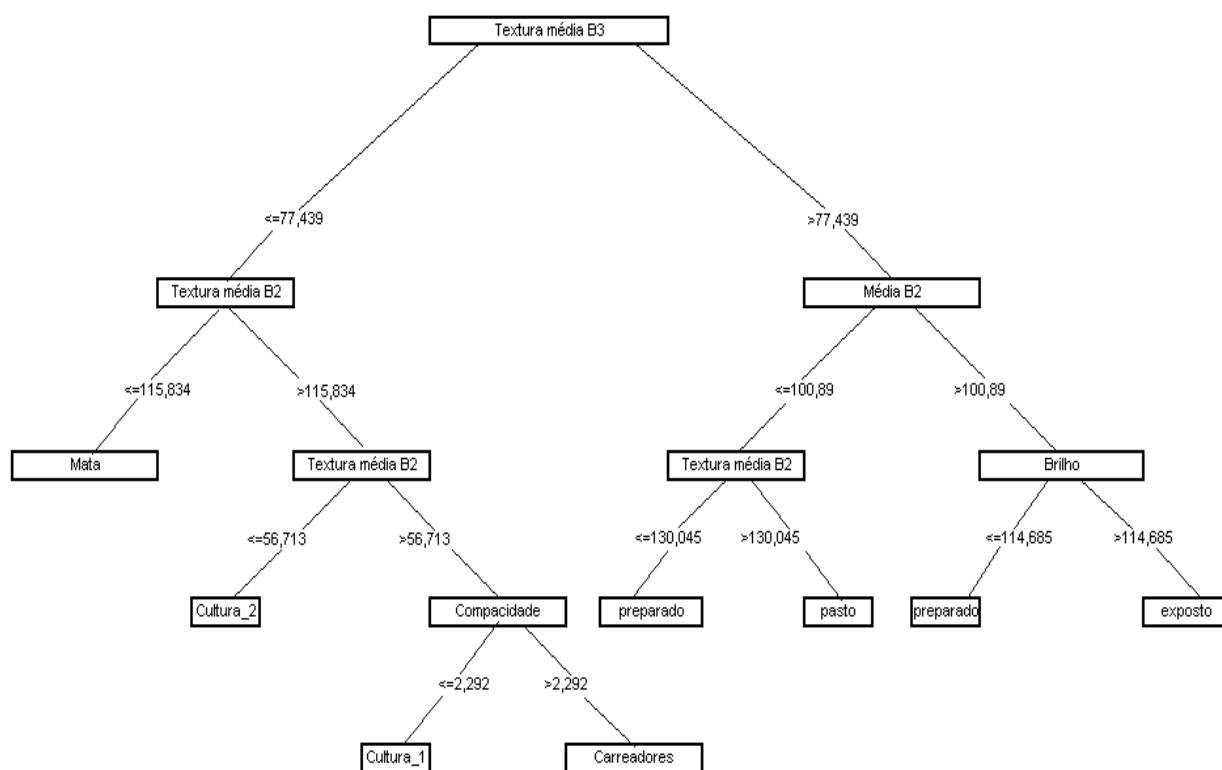


Figura 5 - Árvore hierárquica de 3 ramos para a classificação de uso de solo.

O grupo de 91 amostras foi utilizado para validar a classificação. Os resultados são apresentados através de estatísticas de concordância e da matriz de confusão nas Tabelas 2 e 3, respectivamente.

O resultado da classificação hierárquica orientada a objetos é apresentado na Figura 6. O índice kappa obtido pela classificação foi de 0,80. Segundo a avaliação do grau de concordância proposta por Galparoso e Fernández (2001), esse valor se situa na faixa de “boa concordância”. Verifica-se na Tabela 3, que não houve concordância na classe “água”, onde as duas amostras foram classificadas como “preparado”, que se refere a classe solo preparado. Possivelmente, esta confusão ocorreu devido ao número pequeno de amostras e, portanto, o algoritmo não incluiu a classe “água” na árvore hierárquica apresentada na Figura 5.



Tabela 2: Sumário dos resultados estatísticos da classificação

Objetos classificados corretamente	81,31
Objetos classificados incorretamente	18,69
Estatística Kappa	0,801
Erro médio absoluto	0,034
Erro médio relativo	16,88
Total de amostras	91

Tabela 3: Matriz de confusão da classificação por classes

A	B	C	D	E	F	G	H	Amostras	Classificado como
0	0	0	0	0	0	0	2	2	A = água
0	4	0	0	0	0	0	0	4	B = carreadores
0	1	12	2	0	0	0	0	15	C = cultura 2
0	4	2	4	0	0	0	0	10	D = cultura 1
0	0	0	0	13	0	1	1	15	E = exposto
0	0	0	0	0	15	0	0	15	F = mata
0	0	0	0	1	0	11	3	15	G = pasto
0	0	0	0	0	0	0	15	15	H = preparado

A classe “cultura” foi separada em dois grupos (1 e 2) já que apresentava diferentes estágios vegetativos. Mesmo com essa alternativa, houve confusão entre essas duas classes e entre a classe “carreadores”. A confusão com a classe “carreadores” possivelmente ocorreu devido a grande dificuldade de separar essas duas classes, porque as linhas de carreadores “cortam” e se misturam com as culturas, além de serem comumente estreitas e de difícil visualização até para uma resolução espacial de 2,5 m.

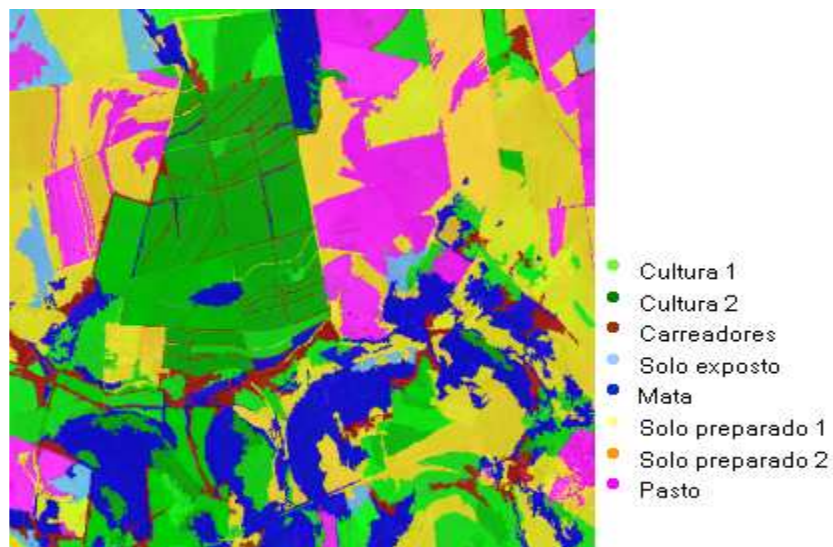


Figura 6 - Classificação hierárquica orientada a objeto

#### 4. Conclusões

Dado o elevado número de atributos (espectrais, de forma, de posição e textura) as técnicas de mineração de dados para a exploração da grande quantidade de informações mostraram-se imprescindíveis, pois, contribuíram para a determinação de quais seriam os melhores atributos e para a definição eficiente das regras de decisão.

Considerando que a lógica booleana segue o princípio de verdadeiro ou falso (0 e 1), e assim não considera o intervalo de variações dos atributos, sugerimos o uso da lógica *fuzzy* que cria um intervalo nas regiões de decisão menos rígido melhorando, por conseguinte, os resultados. Além disso, sugerimos a inclusão de outros atributos no projeto da rede semântica para melhorar a distinção das classes agrícolas.

De uma forma geral, o resultado obtido neste trabalho mostrou um grande potencial do uso de técnicas de mineração de dados para classificação de imagens agrícolas.

#### Agradecimentos

Aos doutorandos do INPE Carolina Moutinho Duque de Pinho pela orientação no uso do aplicativo eCognition 5.0 e Ericson Hideki Hayakawa pela revisão do texto e a bolsista do INPE Elizabeth Goltz pelas sugestões ao longo do trabalho.

#### Referências Bibliográficas

Alves, C. D.; Souza, I. M.; Pereira, M. N. Análise orientada a objeto para extração automática de áreas urbanizadas. **Anais XIII Simpósio Brasileiro de Sensoriamento Remoto**, Florianópolis, Brasil, 21-26 abril 2007. INPE, p.5187-5189.

Blaschke, T.; Lang S.; Larup, E.; Strobl, J.; Zeil, P. Object-oriented image processing in na integrated GIS/Remote Sensing environmnet and perspectives for environmental applications. In: Cremers, A.; Gerve, K. (eds.). **Environmental Information for Planning, Politics and the Public**. Metropolis-Verlag, Marburg, vol.2, p.555-570, 2000.

Câmara, G.; Souza, R. C. M.; Freitas, U. M.; Garrido, J. SPRING: integrating remote sensing and GIS by object-oriented data modeling. **Computers & Graphics**, v.20. n.3, p.395-403, maio/jun. 1996.

DEFINIENS. Ecognition: user guide 3. Germany. Disponível em <http://www.definiens-imaging.com/down/ecognition>. Acesso em janeiro de 2008.

DEFINIENS. Ecognition. Germany. Disponível em <<http://www.definiens-imaging.com/down/ecognition>>. Acesso em out. de 2007.

Fayyad, U. M.; Piatetsky-Shapiro, G.; Smyth, P. From data mining to knowledge discovery: An Overviem. In: **Advances in Knowledge Discovery and Data Mining**, AAAI Press, 1996.

Galparoso, L. U.; Fernández, S. P. **Medidas de concordância: el índice kappa**. 2001. Disponível em: <<http://www.fisterra.com/mbe/investiga/kappa/kappa.htm>>. Acesso em fev.2008.

Goldschmidt, R.; Passos, E. **Data Mining um guia prático**. Rio de Janeiro: Elsevier, 2005, 261p.

Pinho, C. M. D. **Análise orientada a objetos de imagens de satélite de alta resolução espacial aplicada á classificação de cobertura de solo no espaço intra-urbano: o caso de São José dos Campos – SP**. 2003. 160p. (INPE-14183-TDI/1095) Dissertação ( Mestrado em Sensoriamento Remoto)- Instituto Nacional de Pesquisas Espaciais, São José dos Campos.

WAYKATO. WEKA 3.5 – Machine Learning Software in Java. Disponível no site da University of Waykato <<http://www.cs.waykato.ac.nz/ml/weka>>. Acesso em out. de 2007.

Santos Silva, M. P. Mineração de dados – conceitos, aplicações e experimentos com WEKA. **Sociedade Brasileira de Computação**. Disponível em <<http://www.sbc.org.br/bibliotecadigital>>. Acesso em jan. de 2008.

Showengerdt, R. A. **Remote Sensing Models and Methods for Image Processing**. New York: Academic Press, 1997. 552p.

SPOT IMAGE. **Technical Information SPOT**. Disponível em <[http://www.spotimage.fr/automne\\_modules\\_files/standard/public/p.229\\_3alcd2cb59b76fc75e20286a6abb7efesatSPOT\\_E.pdf](http://www.spotimage.fr/automne_modules_files/standard/public/p.229_3alcd2cb59b76fc75e20286a6abb7efesatSPOT_E.pdf)>. Acesso em fevereiro de 2008.