

Análise de Imagem Orientada a Objeto e Mineração de Dados aplicadas ao mapeamento da cana-de-açúcar

Matheus Alves Vieira¹
Antônio Roberto Formaggio¹
Camilo Daleles Rennó¹

¹ Instituto Nacional de Pesquisas Espaciais - INPE
Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil
mvieira.sig@gmail.com

Abstract. The aim of this research was to develop a methodology that can automate the sugar cane mapping task when remote sensing data are used. For this, we tested the integration of two major approaches of Artificial Intelligence: Object Based Image Analysis (OBIA) and Data Mining (DM). The study area comprises the municipalities of Ipuã, Guará and São Joaquim da Barra, located in the northwestern of São Paulo state, which are well representatives of the conditions of agriculture in southern and southeastern regions of Brazil. OBIA was used to emulate the interpreter knowledge in the process of sugar cane mapping, and MD techniques were employed for automatic generation of knowledge model. MD algorithm used was C4.5, which generates decision trees (DT) from a previous prepared training set. A time series of Landsat images was acquired in order to represent the wide patterns variability within the sugar cane crop season. The objects were generated by application of multiresolution segmentation algorithm. Thereafter, the knowledge extraction process has begun, which ends with the acquisition of DT. Once properly trained, the DT was applied to the Landsat time series and then generated the thematic map. Classification accuracy was then assessed using error matrix analysis, Kappa statistics, and tests for statistical significance, indicating that the examined classification routines achieved an overall accuracy of 94% and Kappa of 0,87. The results shows that OBIA and MD are very efficient and promising in the direction of automating the sugar cane classification process.

Palavras-chave: Sugar cane mapping, Artificial Intelligence, Object-based Image Analysis, Data Mining, Landsat images

1. Introdução

A agricultura exerce um importante papel no cenário socioeconômico do Brasil, representando cerca de 11,35% do Produto Interno Bruto (PIB), se for levado em conta apenas o valor da produção e insumos, e 17,94% ao se considerar todo o complexo agroindustrial (CEPEA, 2009). Nesse próspero cenário encontra-se a cana-de-açúcar que é uma das principais culturas agrícolas, sendo o Brasil o maior produtor e exportador dos produtos dessa cultura (Rudorff et al., 2009). Impulsionada pela crescente demanda mundial por biocombustíveis, a área cultivada com cana-de-açúcar cresceu 94,3% desde o ano 2000, ocupando hoje cerca de 9,4 milhões de hectares (IBGE, 2008).

Dada a importância da cana-de-açúcar para a economia brasileira, o setor sucroenergético precisa ser amparado por ferramentas capazes de fornecer informações confiáveis e constantes sobre a produção, crescimento da área cultivada, localização das áreas de expansão e informações sobre o procedimento de colheita da cana ao longo da safra (Rudorff et al., 2009). Tais informações podem ser obtidas por meio de imagens orbitais de sensoriamento remoto (SR), em função do caráter multispectral, sistemático e repetitivo que possibilita a distinção de diferentes objetos da superfície terrestre (Jensen, 2006).

Tradicionalmente, no Brasil, o mapeamento da cana-de-açúcar através de imagens de SR é feito via interpretação visual (Rudorff et al., 2009). Apesar de fornecer resultados precisos e consistentes, esse procedimento tem se demonstrado custoso em termos de tempo de processamento e número de pessoas envolvidas devido à grande extensão do cultivo da cana no país. Nesse sentido, torna-se evidente a necessidade de automação do processo de classificação das imagens de SR para o mapeamento da cana-de-açúcar, pois poderá garantir que a classificação seja um processo mais objetivo e reproduzível no processamento de grandes volumes de dados sobre paisagens diversas e complexas (DeFries e Chan, 2000).

Contudo, procedimentos convencionais de classificação digital encontram dificuldades no reconhecimento automático de padrões. Nesse contexto, desponta como promissora a Análise de Imagem Baseada em Objeto, do inglês *Object-Based Image Analysis* (OBIA). Segundo Cohen e Shoshany (2005), enquanto os sistemas convencionais realizam processamentos algorítmicos guiados apenas pelas variáveis estatísticas dos dados, OBIA são sistemas computacionais que se baseiam em conhecimento e têm a capacidade de emular ou replicar o raciocínio humano.

A aplicação do modelo OBIA na classificação de imagens considera a análise do “objeto no espaço” em vez de “pixel no espaço” (Navulur, 2007). A abordagem mais comum usada na geração de tais objetos é a segmentação de imagens. Para cada objeto criado a partir do processo de segmentação, são gerados atributos espectrais, texturais, morfológicos e contextuais, dentre outros que podem ser empregados em análise de imagem (Blaschke, 2010).

Em OBIA o armazenamento e replicação do conhecimento do especialista são feitos através da estruturação de redes semânticas (RS). As RS são um formalismo de representação do conhecimento que reúnem um conjunto de nodos conectados por um conjunto de arcos (Bittencourt, 2006). De um modo geral, os nodos representam os objetos e os arcos as relações entre esses.

A construção da rede semântica, ou modelo de conhecimento, é a fase mais importante e muitas vezes de difícil realização, uma vez que, num primeiro momento, o especialista (detentor do conhecimento) pode não ter noção exata de quais os melhores atributos descritores dos objetos a serem classificados (Witten e Frank, 2005). Uma solução interessante e potencial é a adoção de técnicas de Mineração de Dados (MD) para a geração automática da estrutura de conhecimento.

Amplamente utilizadas em tarefas de MD, as Árvores de Decisão (AD) são representações simples do conhecimento e um meio eficiente de construir classificadores que predizem ou revelam classes ou informações úteis baseadas nos valores de atributos de um conjunto de dados (Quinlan, 1993).

Desta forma, diante da necessidade de obtenção de informações para cana-de-açúcar em áreas extensas, e considerando o potencial das abordagens computacionais supracitadas, o objetivo do presente trabalho foi verificar a possibilidade de integração entre Análise de Imagem Baseada em Objeto e Mineração de Dados, visando o mapeamento de áreas cultivadas com cana-de-açúcar disponíveis para colheita, a partir de uma série temporal de imagens Landsat. Em termos gerais, pode-se dizer que, enquanto a MD ocupa-se da descoberta do conhecimento, a OBIA é responsável pela representação do conhecimento adquirido.

2. Metodologia

2.1. Área de Estudo

A área de estudo utilizada nessa pesquisa compreendeu três municípios localizados ao norte do Estado de São Paulo (Figura 1), Ipuã, São Joaquim da Barra e Guará, os quais possuem área conjunta de 124.100 ha (IBGE, 2008). Essa região representa bem as condições de grande parte das regiões sudeste e sul brasileiras e tem como principais culturas o algodão, o amendoim, o arroz, a cana-de-açúcar, o feijão, a mandioca, o milho, a soja, o sorgo, o tomate, a banana, o café e a laranja, havendo um predomínio de culturas temporárias (anuais e semi-perenes) sobre as culturas perenes. Entre as culturas temporárias citadas, as principais são a soja, a cana-de-açúcar e o milho, que ocupam a maior parte da área agrícola desta região (IBGE, 2008).

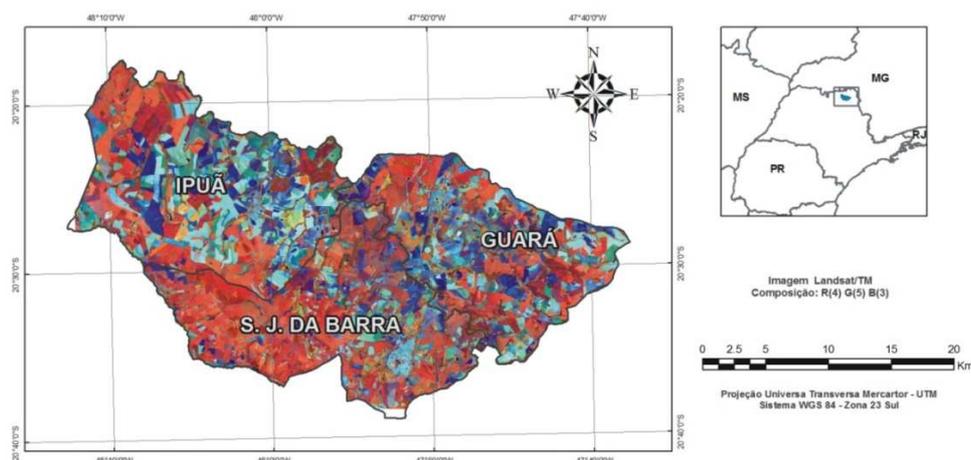


Figura 1. Localização da Área de Estudo com destaque para os municípios de Guará, Ipuã e São Joaquim da Barra.

2.2. Dados

Um dos primeiros aspectos a serem considerados no mapeamento da cana-de-açúcar é o fato de que esse processo é dinâmico e evolui ao longo do tempo. Desta forma, a análise de padrões da cana-de-açúcar e a tarefa de relacioná-los a processos de uso do solo implicam na utilização de séries temporais. Assim, foram utilizadas imagens que retratavam a paisagem em vários períodos respeitando a dinâmica temporal da cana-de-açúcar (Tabela 1).

Tabela 1. Imagens da Série Temporal

Sensor/Satélite	Data
TM/Landatsat-5	20 de setembro, 2000
TM/Landatsat-5	22 de outubro, 2000
ETM+/Landatsat-7	19 de fevereiro, 2001
ETM+/Landatsat-7	23 de março, 2001

2.3. Detalhamento da metodologia

A metodologia proposta compreende as etapas de: 1) Segmentação das Imagens; 2) Construção do Conjunto de Treinamento; 3) Mineração de Dados; 4) Classificação da Série Temporal. Nos tópicos seguintes é apresentada uma descrição mais detalhada de cada uma das etapas supracitadas.

2.3.1 Segmentação das Imagens

Na presente análise, as unidades básicas de processamento são objetos detectados nas imagens via algoritmo de segmentação. Para a geração dos referidos objetos foi utilizado o algoritmo de segmentação multiresolução proposto por Baatz e Schäpe (2000) e implementado na plataforma Definiens (Definiens, 2006).

Na segmentação multiresolução, a geração dos objetos é condicionado ao critério de heterogeneidade, que pode ser ajustado pela escolha do parâmetro de escala, dos pesos das bandas espectrais, do fator de cor e do fator de compacidade. O ajuste no parâmetro de escala, por exemplo, influencia diretamente o tamanho dos segmentos gerados. Com o objetivo de garantir a homogeneidade dos objetos nas quatro datas da série temporal, durante o processo de segmentação todas as imagens da série temporal foram processadas ao mesmo tempo.

2.3.2. Construção do Conjunto de Treinamento

Após a geração dos objetos, foram definidas as classes de interesse: 1) cana-de-açúcar e; 2) outros, sendo que a primeira representa as áreas cultivadas com cana-de-açúcar que estarão disponíveis para a colheita no respectivo ano-safra, enquanto que a classe “outros” engloba os demais tipos de usos do solo presentes na região de estudo.

Posteriormente selecionou-se um conjunto de objetos amostrais através de um processo de avaliação cognitiva feito por um especialista do domínio. Os objetos foram analisados e associados às classes de interesse definidas anteriormente. Ao todo foram selecionados 396 objetos, dos quais 184 representavam a classe cana-de-açúcar e os demais, a classe outros.

Finalizando a construção do conjunto de treinamento, procedeu-se a extração dos atributos definidos pela plataforma Definiens Developer® (Tabela 2).

Tabela 2. Listagem dos atributos extraídos da plataforma Definiens.

Espectral	<i>Mean</i> <i>Standard Deviation</i>	Espacial (cont.)	<i>Radius of smallest enclosing ellipse</i> <i>Rectangular Fit</i>
Espacial	<i>Area</i> <i>Asymmetry</i> <i>Border Index</i> <i>Border Length</i> <i>Compactness</i> <i>Density</i> <i>Elliptic Fit</i> <i>Length</i> <i>Length/Width</i> <i>Main direction</i> <i>Max. diff.</i> <i>Radius of largest enclosed ellipse</i>		<i>Roundness</i> <i>Shape index</i> <i>Width</i>
		Textural	<i>GLCM Homogeneity</i> <i>GLCM Contrast</i> <i>GLCM Dissimilarity</i> <i>GLCM Entropy</i> <i>GLCM Ang. 2nd moment</i>
		Customizado	<i>NDVI_set</i> <i>NDVI_out</i> <i>NDVI_fev</i> <i>NDVI_mar</i>

2.3.3. Mineração de Dados

A fase de MD envolve a escolha e a aplicação de técnicas inteligentes a fim de se extrair padrões de interesse para a efetiva produção do conhecimento (Fayyad, 1996). No presente trabalho, o algoritmo C4.5 desenvolvido por Quinlan (1993) foi escolhido para gerar o modelo de conhecimento. Este algoritmo gera Árvores de Decisão a partir de um conjunto de treinamento usando o conceito de entropia da informação (Quinlan, 1993). A cada nó da Árvore de Decisão, o C4.5 escolhe qual dos atributos definidos no conjunto de treinamento (Seção 2.3.2) melhor separa as amostras. Esse processo se repete até que todas as amostras do conjunto de treinamento sejam classificadas.

O programa C4.5 utilizado nesta pesquisa foi operado dentro do aplicativo WEKA (*Waikato Environment for Knowledge Analysis*) (Witten e Frank, 2005). O WEKA possui uma série de algoritmos de aprendizagem de máquina implementados, inclusive o classificador por árvore de decisão C4.5 (Quinlan, 1993), renomeado para J4.8.

2.3.4. Classificação da Série Temporal

A partir do modelo de conhecimento (Árvore de Decisão) treinado e explorando o potencial da plataforma Definiens na estruturação do conhecimento através de redes, procedeu-se à classificação da cana-de-açúcar. Nesse sentido, a AD foi replicada dentro do ambiente *Definiens Developer 7.0*. Esse processo é caracterizado como a etapa de representação do conhecimento onde o usuário tem um contato visual do resultado obtido pela MD. Essa fase configura a classificação das imagens da série temporal e tem como produto final o mapa temático com as áreas de cana-de-açúcar disponíveis para a colheita.

3. Resultados e Discussões

3.1. Segmentação das Imagens

A Figura 2 ilustra dois exemplos de segmentação multiresolução com configurações distintas, sendo a primeira segmentação (Figura 2-a) a que melhor representa a classe de interesse cana-de-açúcar e, portanto, a segmentação escolhida para classificação. Um resumo das variáveis e parâmetros utilizados para essa segmentação é apresentado na Tabela 3.

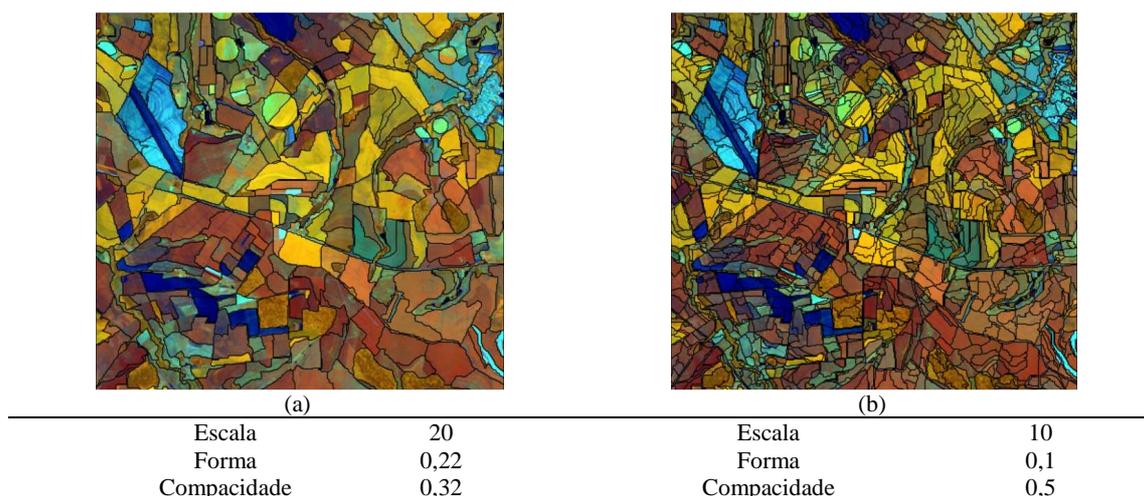


Figura 2. Exemplos de segmentação multiresolução em diferentes níveis de detalhamento. Imagens de fevereiro em composição R(4) G(5) B(3).

Tabela 3. Resumo das variáveis e parâmetros utilizados para a segmentação.

Variável Segmentada	
Imagem	Peso
<i>TM/Landsat-5 (b3, b4, b5) - 20/Set/2000</i>	1
<i>TM/Landsat-5 (b3, b4, b5) - 22/Out/2000</i>	1
<i>ETM+/Landsat-5 (b3, b4, b5) - 19/Fev/2001</i>	1
<i>ETM+/Landsat-5 (b3, b4, b5) - 23/Mar/2001</i>	1
Parâmetro de Escala	
Escala	20
Composição do Critério de Homogeneidade	
Forma	0,22
Compacidade	0,32

3.2. Mineração de Dados

O classificador estrutural C4.5, utilizando o conjunto de treinamento definido na Seção 2.3.2, gerou o modelo apresentado na Figura 3. A partir deste modelo, o classificador estrutural extraiu configurações espectro-temporais da cana-de-açúcar, sendo estes utilizados posteriormente para gerar o mapa temático a partir das imagens da série temporal. O treinamento do modelo foi realizado com metade das amostras (198) do conjunto de treinamento, enquanto o teste utilizou o restante das amostras. Verificou-se que a árvore de decisão obteve 96,97% de sucesso na classificação dos dados de teste, alcançando um índice Kappa de 0,94. Das 198 instâncias de teste, apenas 6 foram classificadas incorretamente. Desta forma, considerou-se que o treinamento da Árvore de Decisão foi satisfatório.

Tabela 4. Atributos minerados pelo algoritmo C4.5

Atributo	Tipo	Data	Banda espectral	Amplitude
NDVI	Índice de Vegetação	Mar., 2001	b3 e b4	-1 a 1
		Fev., 2001	b3 e b4	
		Set., 2000	b3 e b4	
Mean	Espectral	Fev., 2001	b3 (Ver.) e b5 (SWIR)	0 - 255
		Out., 2000	b5 (SWIR)	
GLCM Homogeneity	Textural	Set., 2000	b4 (IVP)	0 - 1
		Out., 2000	b5 (SWIR)	
		Fev., 2001	b4 (IVP)	

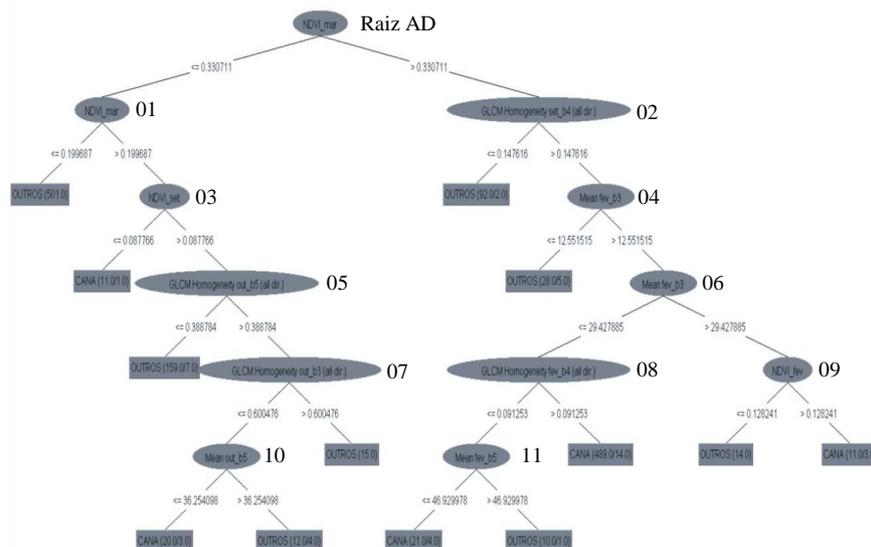


Figura 3. Árvore de Decisão

3.3. Classificação da série temporal

A Figura 4 apresenta o mapa temático final gerado a partir da aplicação do modelo de conhecimento gerado na fase de MD sobre as imagens da série temporal de imagens Landsat. O mapa apresenta as áreas de cana-de-açúcar disponíveis para a colheita no ano safra 2000/2001.



Figura 4. Mapa temático das áreas de cana-de-açúcar disponíveis para colheita.

3.5. Interpretando os padrões

Como exemplo da capacidade de detecção de padrões pelo algoritmo C4.5 avaliado nessa pesquisa, discorreremos a respeito da estratégia utilizada pelo algoritmo para a classificação da cana-de-açúcar. É importante salientar que diversos outros padrões foram identificados, como é caso, de matas ciliares, pastagem e soja. Contudo, discorreremos apenas a respeito da cana-de-açúcar, com o objetivo de ilustrar a capacidade do algoritmo C4.5 na identificação dos padrões espectrais, texturais e temporais dessa cultura.

A separação total da cana-de-açúcar das demais classes presentes na imagem, por exemplo, regiões de mata e pastagem, se deu através da combinação do atributo espectral *mean_fev_b3* (nó 06, Figura 3) seguido do atributo de textura *GLCM Homogeneity_fev_b4* (nó 08, Figura 3).

Primeiramente, o C 4.5 seleciona o atributo *mean_fev_b3*, onde os objetos com valores espectrais abaixo do limiar definido na AD são separados como possíveis talhões de cana. Dos conceitos de comportamento espectral de alvos, sabe-se que na região do visível – especificamente na banda 3 do sensor TM – a radiação eletromagnética incidente na

vegetação é absorvida pela clorofila foliar (Ponzoni; Shimabukuro, 2007). Em fevereiro a cana-de-açúcar está próxima do seu máximo vigor vegetativo, enquanto a soja e milho estão em avançado estado de senescência próximo da colheita, ou já colhidos. Isto faz com que as respostas espectrais dessas classes sejam superiores aos da cana. Desta forma, a separação dessas classes através do atributo espectral *mean_fev_b3* fica bastante evidente.

Contudo, usando apenas o atributo de media espectral, não é possível a separação total das áreas com cana. Por exemplo, áreas de mata também apresentam alta biomassa e vigor verde. Desta forma, na sequência o classificador seleciona o atributo de textura *GLCM Homogeneity_fev_b4* para, finalmente, classificar as áreas de cana (Figura 5). A textura uniforme dos talhões de cana, aliada à presença de estradas internas às lavouras, confere à cana-de-açúcar uma característica textural bastante peculiar (Figura 5-c) que a diferencia das outras classes presentes na imagem. Assim a ação combinada dos atributos *mean_fev_b3* e *GLCM Homogeneity_fev_b4* permitiu a identificação de praticamente todas as áreas com cultivo de cana-de-açúcar na região de estudo.

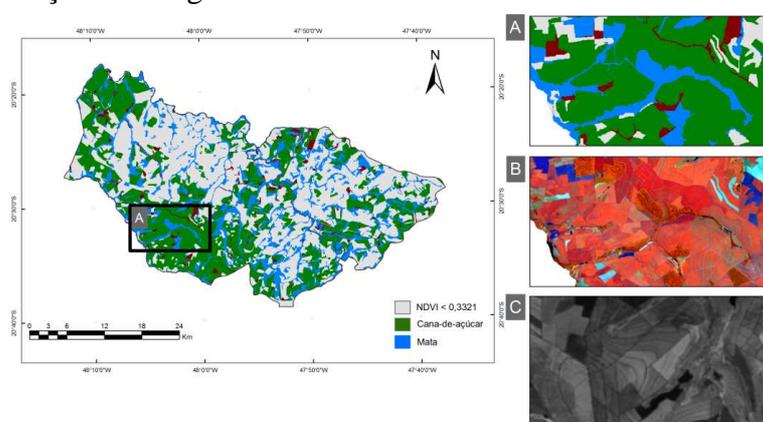


Figura 5. Identificação das áreas de cana-de-açúcar. (a) detalhamento da classificação. (b) imagem do mês de março em composição R(4) G(5) B(3). (c) imagem da banda 3 do sensor TM.

3.6. Avaliação Estatística

A classificação obteve um mapa temático cujos índices de Exatidão Global (EG) e kappa (k) foram 94% e 0,87 (Valor- $p=0,0000$) respectivamente. O valor de coeficiente Kappa encontrado representa realmente a conformidade da classificação com o mapa de referência e isto foi confirmado estatisticamente pelo teste Z, em que se verificou que, para o nível de significância adotado ($\alpha=5\%$) existe concordância entre a classificação e a imagem de referência. Com relação ao índice de Exatidão Global, de acordo com Foody (2002), é desejável que uma classificação alcance índices de acerto superiores a 85%, situação também confirmada uma vez que a classificação obteve EG igual a 94% (Tabela 5). Os valores de Exatidão global e Kappa encontrados indicam a qualidade do mapa temático gerado.

Tabela 5. Matriz de confusão

Classes		Mapa de referência		Σ
		Cana-de-açúcar	Outros	
OBIA	Cana-de-açúcar	186	10	196
	Outros	20	283	303
	Σ	206	293	500

Coefficiente *kappa* = 0,87; Exatidão Global = 93,99%

4. Conclusão

O presente trabalho procurou investigar a viabilidade de integração entre OBIA e MD no mapeamento da cana-de-açúcar disponível para colheita, a partir de uma série temporal de imagens TM/Landsat-5 e ETM+/Landsat-7.

Foi observada a importância do conhecimento das especificidades da dinâmica fenológica das culturas agrícolas, assim como ficou evidenciado a capacidade da integração entre OBIA

e MD para emular o conhecimento do especialista humano, uma vez que a AD obtida foi capaz de diferenciar cana-de-açúcar de culturas agrícolas de verão, pastagem e mata, utilizando os atributos espectrais e texturais. Além disso, a AD foi capaz de explorar os benefícios de se dispor de uma série temporal, levando em consideração as dinâmicas temporais das fenologias das culturas estudadas. Em função do número de atributos que o C4.5 consegue trabalhar e da forma como ele consegue selecionar os atributos pode-se dizer que a metodologia proposta elimina a subjetividade minimizando erros humanos de interpretação.

A utilização de diferentes atributos foi decisiva para o bom desempenho da metodologia. Por exemplo, os atributos de textura foram importantes quando áreas de cana de alta biomassa se confundiam com áreas de mata que também apresentam alta biomassa. Nesse situação o classificador estrutural foi capaz de encontrar atributos de textura que possibilitaram a desejada separação dessas classes. Algoritmos convencionais, baseados apenas em atributos estatísticos, não conseguiriam usar tais artifícios. Explorando os potenciais de MD e OBIA, a presente pesquisa traz uma contribuição importante na busca pela automação do processo de classificação de imagens de sensoriamento remoto voltado para o mapeamento agrícola.

Agradecimentos

Agradecemos à Fundação de Auxílio a Pesquisa do Estado de São Paulo (FAPESP), o auxílio financeiro para a aquisição do software Definiens Developer, bem como os equipamentos que foram fundamentais para o desenvolvimento desta pesquisa.

Referências Bibliográficas

- Blaschke, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, p 2-16, 2010.
- Baatz, M.; Schäpe, A. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. In: XII Angewandte Geographische Informationsverarbeitung, Wichmann-Verlag, Heidelberg, 2000.
- Bittencourt, G. **Inteligência artificial: ferramentas e teorias**. Florianópolis/SC: Editora da UFSC, 2006. 371 p.
- Centro de estudos avançados em economia aplicada (CEPEA). PIB do Agronegócio – Dados de 1994 a 2008. 2009.
- Cohen, Y.; Shoshany, M. Analysis of convergent evidence in an evidential reasoning knowledge-based classification. **Remote Sensing of Environment**, v. 96, p. 518-528, 2005.
- Congalton, R. G.; Green, K. Assessing the accuracy of remotely sensed data: Principles and practices (pp. 11 – 70). Boca Raton: Lewis Publishers, 1999.
- Definiens. **Definiens professional 5**: reference book. Munich: Definiens (The Imaging Intelligence Company), 2006. 122 p
- DeFries, R. S., & Chan, J. (2000). Multiple criteria for evaluating machine learning algorithms for land-cover classification from satellite data. *Remote Sensing of Environment*, 74, 503–515.
- Fayyad, U.; Piatetsky-shapiro, G.; Smyth, P.; Uthurusamy, R. **Advances in knowledge discovery and data mining**. Cambridge: MIT Press, 1996. 560 p.
- Foody, G. M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, v. 80, n. 1, p. 185-201, 2002.
- Good, P. I. **Resampling methods: a practical guide to data analysis**. Berlin: Birkhauser Verlag AG 2001. 256 p.
- Instituto Brasileiro de Geografia e Estatística (IBGE). **Levantamento sistemático da produção agrícola** - dezembro de 2008. Rio de Janeiro-RJ: IBGE, 2008. 80 p.
- Jensen, J. R. **Remote sensing of the environment: an Earth Resource perspective**. 2 ed. Upper Saddle River, NJ, USA: Pearson Prentice Hall, 2006. 608 p. (Prentice Hall series in geographic information science).
- Navulur, K. **Multispectral Image Analysis Using the Object-Oriented Paradigm**. Boca Raton, FL: Taylor & Francis Group, 2007, 206p. ISBN-13: 978-1-4200-4306-8.
- Ponzoni, F. J.; Shimabukuro, Y. E. **Sensoriamento remoto no estudo da vegetação**. 1 ed. São José dos Campos, SP: Parêntese Editora, 2007. 144 p.
- Quinlan, R. **C4.5: programs for machine learning**. San Francisco: Morgan Kaufmann, 1993. 316p.
- Rudorff, B. F. T.; Sugawara, L. M.; Aguiar, D. A.; Silva, W. F.; Goltz, E.; Aulicino, T. L. I. N.; Carvalho, M. A.; Arenas-Toledo, J. M.; Brandão, D. **Determinação da área cultivada com cana-de-açúcar na região centro-sul por meio de imagens de satélite de sensoriamento remoto - safras 2005/06 a 2008/09**. São José dos Campos: INPE, 2009. 151 p.
- Witten, I.; Frank, E. **Data Mining: Practical Machine Learning Tools and Techniques**. 2. Ed. San Francisco, CA: Morgan Kaufmann Publishers, 2005. 524 p.