

## Classificação da colheita da cana-de-açúcar por meio de imagens de satélite utilizando superfícies de resposta espectro-temporais

Márcio Pupin de Mello<sup>1</sup>  
Carlos Antonio Oliveira Vieira<sup>2</sup>  
Daniel Alves de Aguiar<sup>1</sup>  
Bernardo Friedrich Theodor Rudorff<sup>1</sup>

<sup>1</sup>Instituto Nacional de Pesquisas Espaciais - INPE  
Caixa Postal 515 - 12245-970 - São José dos Campos - SP, Brasil  
{pupin, daniel, bernardo}@dsr.inpe.br

<sup>2</sup>Universidade Federal de Viçosa - UFV  
Campus Universitário – 36570-000 - Viçosa - MG, Brasil  
carlos.vieira@ufv.br

**Abstract.** Environmental impacts related to sugarcane crop cultivation are becoming a worldwide issue due to the great potential that ethanol has to mitigate the emission of green house gases. However, the sugarcane straw burning prior to harvest is still a critical environmental problem that needs special attention. São Paulo State represents more than 60% of the Brazilian sugarcane production with 4.9 millions ha of cultivated area. The State government together with the private sugarcane production sector established in 2007 a protocol to gradually stop the sugarcane straw burning up to 2014. Remote sensing images have the potential to monitor the harvest management procedure identifying the fields that were harvested with and without straw burning prior to harvest. Currently, this identification and classification is carried out using visual interpretation which provides high quality results but is extremely tedious and time consuming. The present work has the objective to propose an automated classification procedure based on Spectral Temporal Response Surfaces (STRS) to classify the recent harvested sugarcane into burned and non-burned fields. This procedure is based on a pixel-by-pixel classification considering the spectral-temporal reflectance of each image pixel generating a thematic map. A visual interpreted reference map was used to assess the automated classification map accuracy which showed an overall index of 87.3%. The STRS classification procedure showed to be a promising alternative to automate the generation of thematic maps of harvested sugarcane with and without straw burning based on spectral-temporal remote sensing images.

**Palavras-chave:** remote sensing, multitemporal image classification, accuracy assessment, automatization, sensoriamento remoto, classificação multitemporal de imagens, avaliação da exatidão, automatização.

### 1. Introdução

A cana-de-açúcar vem recebendo cada vez mais destaque no cenário mundial por ser uma cultura de grande eficiência na produção de biocombustíveis e conseqüente mitigação da intensificação do efeito estufa. Segundo dados do Canasat (2008) o Estado de São Paulo teve quase 4,9 milhões de ha cultivados com cana-de-açúcar na safra 2008/2009. Isso corresponde a mais da metade da produção nacional, que chegou a cerca de 7,9 milhões de ha, segundo o Instituto Brasileiro de Geografia e Estatística - IBGE (2008). Mesmo gerando grandes divisas, o cultivo da cana-de-açúcar ainda enfrenta problemas de ordem socioeconômica e ambiental, como a prática da queima da palha por ocasião da colheita (Roseiro e Takayanagui, 2004). Visando antecipar a extinção dessa prática, a Secretaria do Meio Ambiente do Estado de São Paulo (SMA-SP) e a União da Indústria de Cana-de-Açúcar (UNICA) assinaram, em junho de 2007, um protocolo de intenções que visa findar as queimadas em áreas mecanizáveis até 2014. O protocolo também estabelece metas de que pelo menos 70% da área cultivada seja colhida sem o uso do fogo até 2010, e que as novas lavouras de cana, a partir de 2007, não podem mais ser colhidas com queima. Nesse contexto o monitoramento das lavouras de cana-de-açúcar com e sem a prática da queima da palha na pré-colheita torna-se importante, tanto

para avaliar a eficácia do protocolo, quanto para fiscalizar o andamento da queima da palha em lavouras autorizadas pela SMA-SP.

As imagens de sensoriamento remoto constituem peça fundamental para monitorar e fiscalizar o procedimento de colheita da cana-de-açúcar (Aguiar, 2007). Elas são obtidas de forma sistemática e repetitiva, em faixas do espectro eletromagnético, que permitem diferenciar os alvos da superfície terrestre em função da sua resposta espectral (Jensen, 2005). Em geral, as culturas agrícolas apresentam significativas alterações na resposta espectral ao longo do ciclo de crescimento e, portanto, precisam ser observadas com certa frequência temporal para que as alterações sejam devidamente registradas nas imagens e utilizadas na identificação dos alvos de interesse (Vieira et al., 2000). A escolha do sensor adequado em termos das resoluções espacial (Ozdogan e Woodcock, 2006), radiométrica (Rao et al., 2007) e espectral é importante (Teillet et al., 1997), mas a resolução temporal não pode ser menosprezada. O sensoriamento remoto óptico encontra uma barreira na cobertura de nuvens de tal forma que a resolução temporal do sensor não corresponde necessariamente ao número de vezes que a superfície terrestre é observada pelo sensor. Quanto maior for a resolução temporal, maior será a probabilidade de se obter uma imagem livre de cobertura de nuvens (Sano et al., 2007). O período de colheita da cana no Estado de São Paulo ocorre, tradicionalmente, entre abril e novembro, coincidindo com o período mais propenso à obtenção de imagens livres de nuvens, o que favorece o monitoramento da colheita da cana via imagens de sensoriamento remoto.

O Instituto Nacional de Pesquisas Espaciais (INPE) em parceria com a SMA-SP, UNICA e o Centro de Tecnologia Canavieira (CTC) vêm monitorando desde 2006, através de imagens de satélites de média resolução espacial (30 m para o Landsat5-TM e 20 m para o CBERS2-CCD), a colheita da cana-de-açúcar no Estado de São Paulo (Aguiar et al., 2007). Entretanto, o processo atual de mapeamento é fortemente apoiado na interpretação visual, o que demanda um tempo razoavelmente grande considerando a extensão do cultivo da cana no Estado.

No intuito de apresentar uma metodologia alternativa para automatizar grande parte do procedimento de interpretação visual, o presente trabalho teve por objetivo utilizar superfícies de resposta espectro-temporal para classificar as áreas de cana colhidas com e sem a queima da palha.

## 2. Material e Métodos

A área de estudo (Figura 1) localiza-se no Estado de São Paulo, aproximadamente entre os municípios de Ribeirão Preto e São Carlos, e possui área de 225 km<sup>2</sup>, que corresponde a um recorte de 500 x 500 *pixels* em uma imagem de resolução espacial de 30 m. Trata-se de uma região onde predomina o cultivo da cana-de-açúcar.

Foram usadas seis imagens do ano de 2007 obtidas pelo sensor *Thematic Mapper* (TM) a bordo do satélite Landsat 5. Elas são datadas de 03 de maio, 20 de junho, 06 de julho, 07 de agosto, 23 de agosto e 08 de setembro, e foram escolhidas por corresponderem ao período de colheita da cana e não apresentarem cobertura de nuvens. Elas foram registradas utilizando polinômios de primeiro e segundo grau e interpolação por vizinho mais próximo, com base em uma imagem previamente georreferenciada ao sistema de projeção Policônico e *datum* SAD69. Para todas as imagens obteve-se um erro médio quadrático (RMS: *Root Mean Square*) inferior a 0,5 *pixel* (Daí e Khorram, 1998). Em seguida a imagem de 06 de julho foi corrigida radiometricamente e convertida para reflectância de superfície utilizando o algoritmo 6S (Vermote et al., 1997) e todas as outras imagens foram normalizadas radiometricamente com base nesta, utilizando o procedimento automático *Iteratively Reweighted Multivariate Alteration Detection* (IR-MAD), descrito com detalhes em Canty et al. (2004) e Canty e Nielsen (2008), de modo que ao fim do processo, todas as imagens da série temporal apresentavam-se em reflectância de superfície.

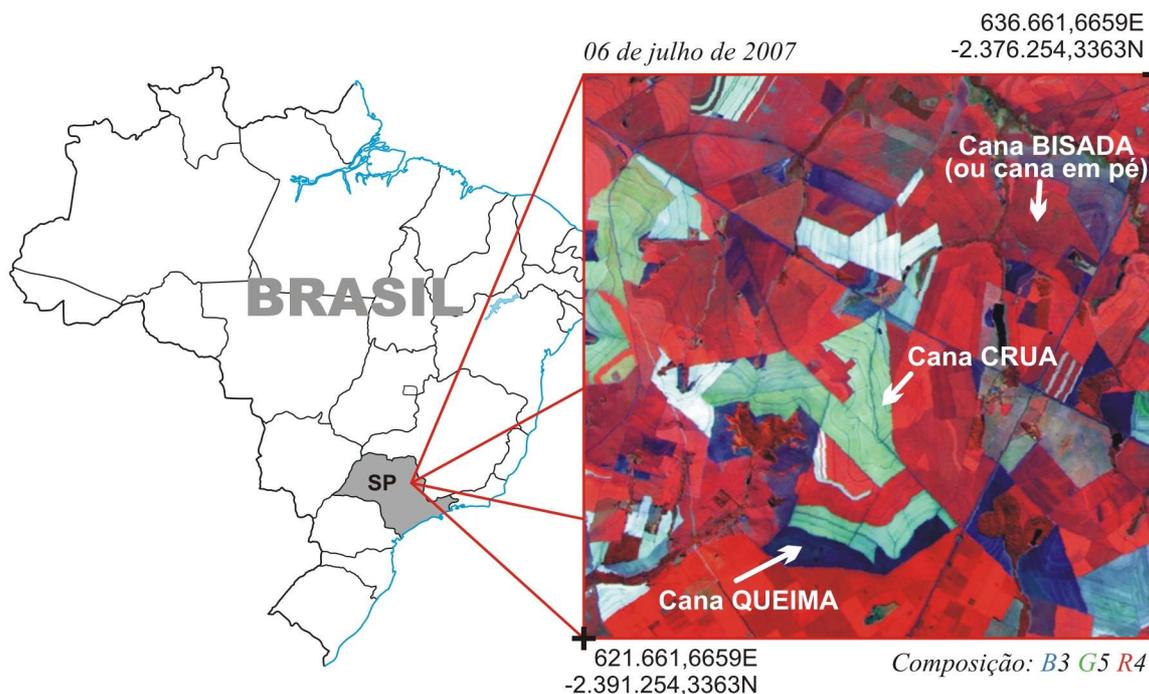


Figura 1. Imagem de 06 de julho de 2007 obtida pelo sensor TM/Landsat5 da área de estudo em composição falsa cor (B3G5R4). As coordenadas seguem o sistema de projeção Policônico, com meridiano de tangência em 54°W, e datum SAD69.

Após o pré-processamento das imagens foi realizada a classificação por superfície de resposta espectro temporal (STRS: *Spectral Temporal Response Surface*) desenvolvida por Vieira (2000). Esta classificação é feita *pixel-a-pixel* e leva em conta a “assinatura espectral” do *pixel* no tempo. O procedimento caracteriza-se por usar, para cada *pixel* da imagem, pontos de controle em três eixos cartesianos, sendo dois independentes ( $x$  e  $y$ ) e um dependente ( $z$ ). Estes eixos correspondem, respectivamente: a) ao tempo, de acordo com as datas das imagens, dado em dia Juliano; b) ao comprimento de onda médio das bandas espectrais do sensor, dado em micrometros; e c) aos valores das reflectâncias espectrais do *pixel* nas respectivas datas das imagens e bandas do sensor. Com as seis datas de aquisição das imagens pelo Landsat 5 nas seis bandas do sensor TM (todas exceto a banda 6), tem-se 36 pontos de controle (6 datas x 6 bandas) nesse sistema cartesiano, para cada *pixel*. A partir desses pontos de controle interpola-se uma superfície de tendência de grau  $d$  (que no caso desse estudo foi igual a cinco) utilizando regressão polinomial múltipla em algoritmo desenvolvido e implementado por Mello e Vieira (2006), segundo o modelo expresso na Equação 1.

$$\hat{z} = f(x, y) = a_0 + a_1x + a_2y + a_3x^2 + a_4xy + a_5y^2 + a_6x^3 + a_7x^2y + \dots + a_{\frac{(d+1)(d+2)-2}{2}}y^d \quad (1)$$

No caso do modelo de grau cinco, são 21 coeficientes ajustados (denotados por  $a_i$  – que vão do  $a_0$  ao  $a_{20}$ ). Tanto as informações dos eixos cartesianos dos pontos de controle, quanto os coeficientes paramétricos ajustados pelo modelo de superfície de tendência são normalizados em um intervalo fechado entre zero e um. O algoritmo treina o classificador utilizando amostras de referência e as superfícies são comparadas com base nos coeficientes ajustados. Posteriormente classifica-se toda a imagem utilizando o critério da Máxima Verossimilhança (MaxVer) para atribuir um rótulo a cada *pixel* investigado. O esquema exposto na Figura 2 ilustra a metodologia STRS empregada.

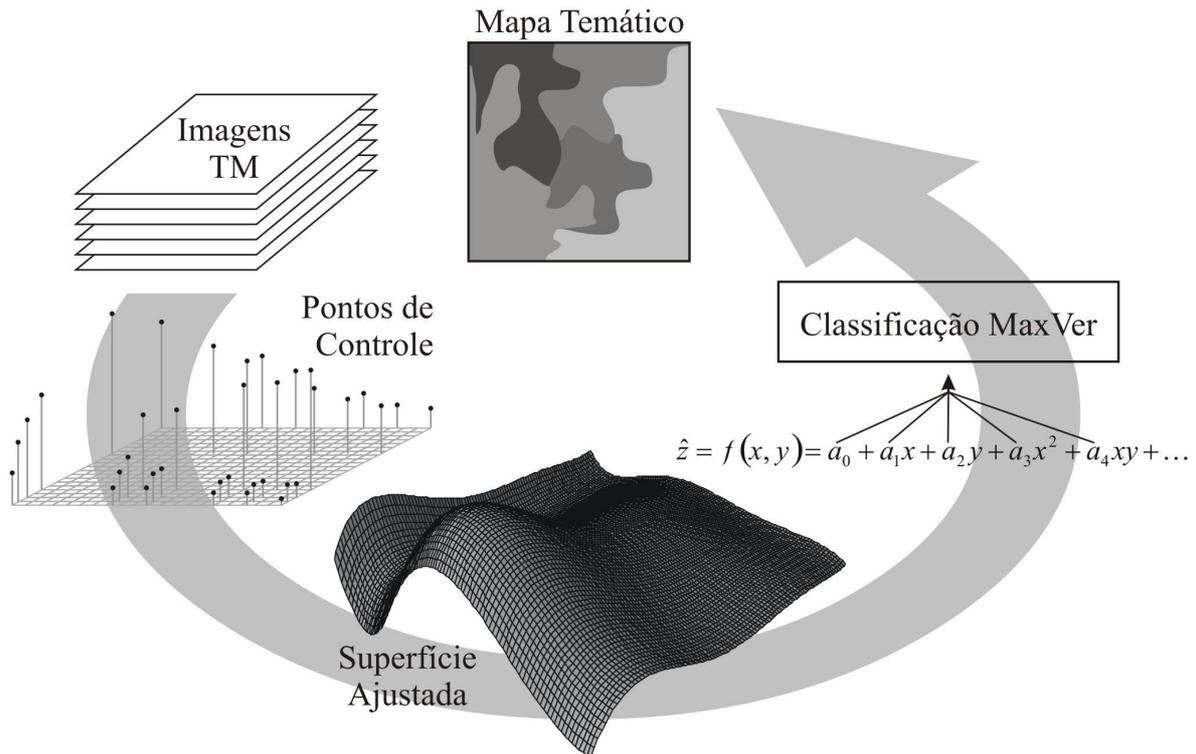


Figura 2. Esquema ilustrativo da metodologia empregada na geração do mapa temático utilizando a classificação STRS.

Foram coletadas aleatória e independentemente, para cada classe, 40 amostras de treinamento e 20 amostras de teste. O classificador foi treinado para 13 classes (seis classes de cana-crua, seis classes de cana-queima e uma classe de cana bisada): *CC-1* (cana-crua imagem 1), *CC-2*, *CC-3*, *CC-4*, *CC-5*, *CC-6*, *CQ-1* (cana-queima imagem 1), *CQ-2*, *CQ-3*, *CQ-4*, *CQ-5*, *CQ-6*, e *Cana Bisada*. Esta última corresponde à cana que não foi colhida até a última data analisada (08 de setembro).

O classificador compara a forma da superfície ajustada para um determinado *pixel* da imagem com a forma das superfícies para as quais ele foi treinado. Assim, um *pixel* de cana-queima colhida na primeira imagem (03 de maio), por exemplo, tem a superfície espectro-temporal totalmente deslocada no eixo do tempo em relação a um *pixel* de cana-queima colhida na última imagem (08 de setembro). Portanto, as superfícies espectro-temporais são ajustadas para as classes *Cana Crua* e *Cana Queima* em cada uma das seis imagens. No final da classificação, as seis classes de cana-crua (*CC*) foram agrupadas, assim como as seis classes de cana-queima (*CQ*), resultando num mapa geral com as classes: *Cana Crua*, *Cana Queima* e *Cana Bisada*. Esse mapa temático geral obtido pela classificação STRS foi então comparado com um mapa temático gerado por meio de interpretação visual utilizando as mesmas seis imagens TM. Em todos os casos foram consideradas apenas as áreas correspondentes ao cultivo de cana-de-açúcar com base no mapa temático do Canasat (2008).

A avaliação da metodologia foi feita com base nos resultados quantitativos e qualitativos do mapa temático resultante da classificação STRS. A análise quantitativa da confiabilidade da classificação foi feita através dos índices de exatidão global e *Kappa* (Congalton, 1991). Já a análise qualitativa foi realizada com base na distribuição e dispersão espacial dos erros da classificação.

Na execução deste trabalho foram utilizados os softwares: R 2.7.1 (R Development Core Team, 2008), SPRING 4.3.3 (Câmara et al., 1996), ENVI 4.5 (RSI, 2008) e KAPPA.EXE desenvolvido por Vieira (2000).

### 3. Resultados e Discussão

O resultado do procedimento de classificação gerou um mapa chamado “Mapa específico” (Figura 3a), contendo as 13 classes anteriormente definidas (*CC-1* a *CC-6* para cana-crua, *CQ-1* a *CQ-6* para cana-queima, e *Cana Bisada*). As classes *CC-1* a *CC-6* são representadas na Figura 3a em tons de verde, variando entre verde claro (*CC-1*) a verde escuro (*CC-6*), que posteriormente foram agrupadas em uma classe denominada *Cana Crua* representada na Figura 3b na cor verde. Da mesma forma as classes de *CQ-1* a *CQ-6* são representadas em tons de azul claro (*CQ-1*) a azul escuro (*CQ-6*; Figura 3a) e em seguida foram agrupadas em uma classe de *Cana Queima* na cor azul na Figura 3b. A classe *Cana Bisada* é representada pela cor vermelha nas Figuras 3a e 3b. A Figura 3b apresenta o mapa temático da classificação final, denominado “Mapa geral”.

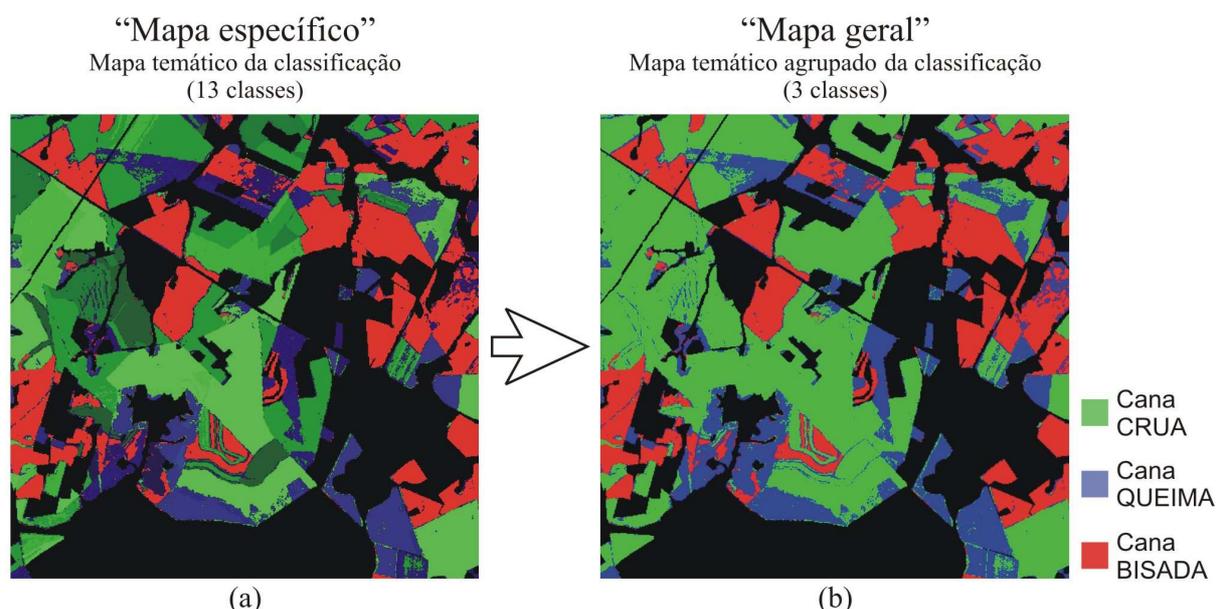


Figura 3. (a) Mapa específico contendo as 13 classes da classificação inicial: cana-crua representadas em verde (variando de verde mais claro para *CC-1* e verde mais escuro para *CC-6*); cana-queima representadas em azul (azul claro para *CQ-1* até azul escuro para *CQ-6*); e Cana Bisada, em vermelho e (b) Mapa geral, onde as classes do mapa específico foram agrupadas nas três classes de interesse: *Cana Crua*, *Cana Queima* e *Cana Bisada*.

A análise de precisão da classificação do “Mapa específico” considerando as 13 classes (20 amostras de teste para cada classe) forneceu um índice de exatidão global de 90,0%. Contudo, o que realmente interessa é a precisão da classificação do “Mapa geral” que tem apenas três classes, uma vez que a confusão entre classes “semelhantes” não constitui erro no “Mapa geral”. Dos 260 *pixels* testados apenas dois *pixels* foram erroneamente classificados no “Mapa geral”, computando assim uma exatidão global de 99,2% (258/260) para as amostras de teste.

A análise quantitativa da precisão da classificação do “Mapa geral” foi realizada tomando como referência o mapa temático elaborado por meio da interpretação visual (Figura 4a) que utilizou as mesmas seis imagens utilizadas na classificação STRS. A Tabela 1 mostra a matriz de confusão calculada para todos os *pixels* classificados no “Mapa geral” e no mapa temático de referência. Constatou-se que o índice de exatidão global foi igual a 87,3%, que segundo Foody (2002) é satisfatório. Já o índice *Kappa* foi igual a 0,79 que é considerado muito bom, segundo Landis e Koch (1977).

Tabela 1. Matriz de confusão gerada utilizando todos os *pixels* classificados do “Mapa geral”, tendo como referência o mapa de interpretação visual.

Classificado STRS	Referência (interpretação visual)			TOTAL
	Cana CRUA	Cana QUEIMA	Cana BISADA	
Cana CRUA	78.310	4.387	864	83.561
Cana QUEIMA	8.258	21.051	5.060	34.369
Cana BISADA	1.139	565	40.374	42.078
TOTAL	87.707	26.003	46.298	160.008

A análise qualitativa da precisão da classificação foi feita a partir da elaboração de um mapa de erros (Figura 4b), indicando os *pixels* classificados erroneamente como *Cana Crua* (verde), *Cana Queima* (azul) e *Cana Bisada* (vermelho).

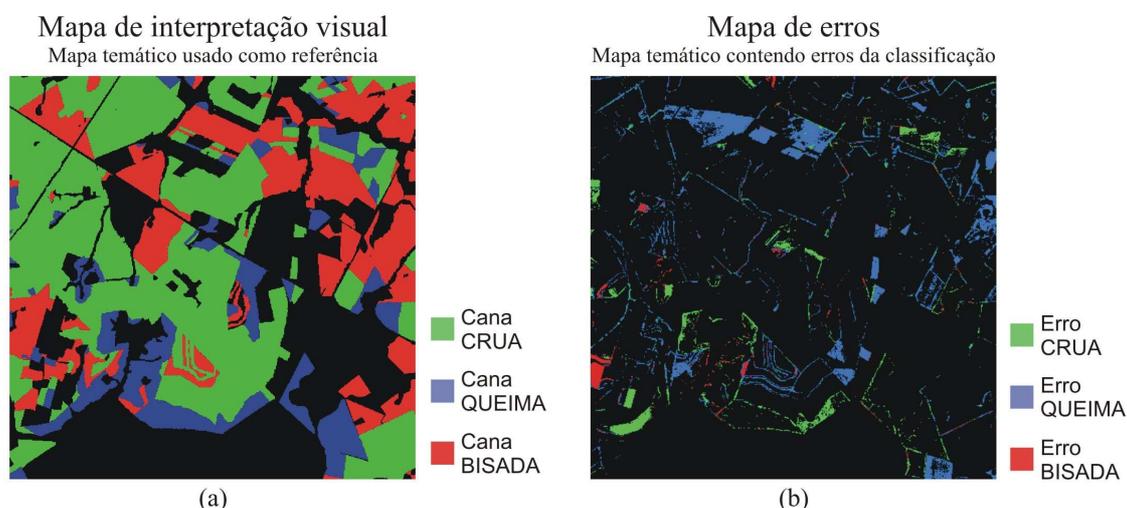


Figura 4. (a) Mapa obtido pela interpretação visual e utilizado como referência e (b) Mapa de erros, mostrando a distribuição espacial dos *pixels* erroneamente classificados.

Visualmente nota-se que a classe *Cana Queima* apresenta o maior erro de classificação (65,7% do total de erros) uma vez que ela foi frequentemente confundida com *Cana Crua*. Esse erro pode ser atribuído em boa parte ao seguinte fato: na interpretação visual as classes de *Cana Crua* ou *Cana Queima* são rotuladas de acordo com a primeira percepção diferente da cana-em-pé. Por exemplo, quando o intérprete vê que a cana de um talhão foi colhida crua, ele mapeia como *Cana Crua* independente se na imagem subsequente a palha da cana foi queimada, pois este talhão já foi rotulado e não passa mais por uma nova avaliação. Isso, para o classificador MaxVer é um dilema, pois ele tem que verificar, por verossimilhança, a qual padrão espectro-temporal aquele talhão (*pixels* do talhão) mais se assemelha. Se após a colheita da cana-crua o talhão passa por uma gradagem ou a palha é queimada o classificador provavelmente vai classificar aquele talhão como *Cana Queima*. Outra discussão importante é que as bordas de todos os talhões apresentam, de maneira geral, comportamento espectro-temporal bem verossímil à classe *Cana Queima*, justificando em parte o erro supracitado de 65,7% relacionado aos *pixels* erroneamente atribuídos a essa classe.

A classe *Cana Crua*, por sua vez, foi principalmente confundida com a *Cana Queima*. Esses erros relacionados à atribuição indevida de *pixels* à classe *Cana Crua* acontecem, em geral, quando o talhão foi colhido logo após uma passagem do satélite, fazendo com que a defasagem entre a data da colheita e a data da próxima imagem seja suficientemente grande para descaracterizar a cicatriz do modo de colheita. Esta dificuldade também ocorre na interpretação visual fazendo com que o dado de referência esteja sujeito a erros. Por fim,

alguns erros relacionados aos *pixels* atribuídos à classe *Cana Bisada* podem ocorrer para talhões colhidos bem no início da safra (seja com ou sem queima) e que têm uma rebrota rápida, fazendo com que o classificador “entenda” que o padrão espectro-temporal destes talhões se assemelhe aos de *Cana Bisada*.

#### 4. Considerações Finais

Os resultados indicaram que a metodologia de classificação por superfícies de resposta espectro-temporal mostrou-se promissora na automatização dos processos do monitoramento da colheita da cana-de-açúcar. Os índices de exatidão global de 87,3% e *Kappa* de 0,79 corroboram com o indicativo. No estudo da distribuição espacial dos erros pôde-se notar que um intérprete, por edição matricial do mapa gerado pela classificação STRS, gera um mapa final com grande confiabilidade, otimizando o tempo que seria gasto em relação à geração desse mesmo mapa por meio, apenas, de interpretação visual das imagens. Todo o procedimento usado, assim como os resultados encontrados, forneceu indícios de que essa metodologia pode ser expandida para o monitoramento da colheita da cana-de-açúcar de todo o Estado de São Paulo, sendo essa viabilidade dependente da otimização e operacionalização dos algoritmos, o que constitui, basicamente, um problema de engenharia de *software*.

Sugere-se que amostras maiores sejam utilizadas para o treinamento do classificador (Foody et al., 2006), em concomitância com um maior número de imagens, o que permitiria aumentar a precisão no resultado. Outra abordagem que pode melhorar o resultado consiste no uso de várias classificações: a primeira utilizando imagens adquiridas no início da colheita; a segunda utilizando estas imagens mais as novas imagens disponíveis e assim por diante. Concomitantemente a estas classificações deve-se usar uma máscara para excluir da classificação os *pixels* já classificados.

#### Agradecimentos

Os autores agradecem ao Dr. Morton J. Canty, do *Jülich Research Center*, em Jülich, Alemanha, pela ajuda com a normalização radiométrica IR-MAD.

#### Referências Bibliográficas

Aguiar, D. A. **Monitoramento da área colhida de cana-de-açúcar por meio de imagens do sensor MODIS**. 2007. 103 p. (INPE-14803-TDI/1246). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos-SP, 2007.

Aguiar, D. A.; Adami, M.; Rudorff, B. F. T.; Sánchez, G. A.; Barros, M. A.; Sugawara, L. M.; Shimabukuro, Y. E.; Moreira, M. A. **Mapeamento da colheita da cana-de-açúcar no estado de São Paulo: ano safra 2006/2007**. São José dos Campos-SP: INPE, 2007. 48p. (INPE-14788-RPE/811).

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

Canasat. **Mapeamento de cana via satélites de observação da Terra**. 2008. Disponível em: <<http://www.dsr.inpe.br/mapdsr/>>. Acesso em: 10 out. 2008.

Canty, M. J.; Nielsen, A. A. Automatic radiometric normalization of multitemporal satellite imagery with the iteratively re-weighted MAD transformation. **Remote Sensing of Environment**, v. 112, n. 3, p. 1025-1036, 2008.

Canty, M. J.; Nielsen, A. A.; Schmidt, M. Automatic radiometric normalization of multitemporal satellite imagery. **Remote Sensing of Environment**, v. 91, n. 3-4, p. 441-451, 2004.

Congalton, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v. 37, n. 1, p. 35-46, 1991.

Dai, X.; Khorram, S. The effects of image misregistration on the accuracy of remotely sensed change detection. **IEEE Transactions on Geoscience and Remote Sensing**, v. 36, n. 5, p. 1566-1577, 1998.

Foody, G. M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, v. 80, n. 1, p. 185-201, 2002.

Foody, G. M.; Mathur, A.; Sanchez-Hernandez, C.; Boyd, D. S. Training set size requirements for the classification of a specific class. **Remote Sensing of Environment**, v. 104, n. 1, p. 1-14, 2006.

Instituto Brasileiro de Geografia e Estatística (IBGE). **Levantamento sistemático da produção agrícola: setembro 2008**. 2008. Disponível em: <[http://www.ibge.gov.br/home/estatistica/indicadores/agropecuaria/lspa/lspa\\_200809\\_4.shtm](http://www.ibge.gov.br/home/estatistica/indicadores/agropecuaria/lspa/lspa_200809_4.shtm)>. Acesso em: 29 out. 2008.

Jensen, J. R. **Introductory digital image processing: a remote sensing perspective**. 3 ed. Upper Saddle River, NJ, USA: Pearson Prentice Hall, 2005. 526 p.

Landis, J. R.; Koch, G. G. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, n. 1, p. 159-174, 1977.

Mello, M. P.; Vieira, C. A. O. Modelagem de um interpolador “Polynomial Trend Surface” usando o software livre R para gerar superfícies de assinaturas espectrais multitemporais de culturas agrícolas. In: Simpósio de Iniciação Científica da Universidade Federal de Viçosa, 15., 2006, Viçosa, MG. **Resumos...** Viçosa: UFV, 2006. n. 897. CD-ROM. Disponível em: <<http://mtc-m17.sid.inpe.br:80/rep-/sid.inpe.br/mtc-m17@80/2008/04.29.02.11>>. Acesso em: 29 abr. 2008.

Ozdogan, M.; Woodcock, C. E. Resolution dependent errors in remote sensing of cultivated areas. **Remote Sensing of Environment**, v. 103, n. 2, p. 203-217, 2006.

R Development Core Team. **R - A language and environment for statistical computing**. ver. 2.7.1. Vienna, Austria: R Foundation for Statistical Computing. 2008. Disponível em: <[www.R-project.org](http://www.R-project.org)>. Acesso em: 06 ago. 2008.

Rao, N. R.; Garg, P. K.; Ghosh, S. K. Evaluation of radiometric resolution on land use/land cover mapping in an agricultural area. **International Journal of Remote Sensing**, v. 28, n. 2, p. 443-450, 2007.

Roseiro, M. N. V.; Takayanagui, A. M. M. Meio ambiente e poluição atmosférica: o caso da cana-de-açúcar. **Revista Saúde**, v. 30, n. 1-2, p. 76-83, 2004.

RSI. **Environment for Visualizing Images - ENVI**. ver. 4.5. Boulder, CO, USA: ITT Industries. 2008.

Sano, E. E.; Ferreira, L. G.; Asner, G. P.; Steinke, E. T. Spatial and temporal probabilities of obtaining cloud-free Landsat images over the Brazilian tropical savanna. **International Journal of Remote Sensing**, v. 28, n. 12, p. 2739-2752, 2007.

Teillet, P. M.; Staenz, K.; William, D. J. Effects of spectral, spatial, and radiometric characteristics on remote sensing vegetation indices of forested regions. **Remote Sensing of Environment**, v. 61, n. 1, p. 139-149, 1997.

Vermote, E. F.; Tanre, D.; Deuze, J. L.; Herman, M. A.; Morcette, J. J. A. Second simulation of the satellite signal in the solar spectrum, 6S: an overview. **IEEE Transactions on Geoscience and Remote Sensing**, v. 35, n. 3, p. 675-686, 1997.

Vieira, C. A. O. **Accuracy of remotely sensing classification of agricultural crops: a comparative study**. 2000. 323 p. Tese (Ph.D. em Geografia Física) - University of Nottingham, Nottingham, Inglaterra, 2000.

Vieira, C. A. O.; Mather, P. M.; McCullagh, M. The Spectral-Temporal Response Surface and its use in the multi-sensor, multitemporal classification of agricultural crops. In: Congress of the International Society for Photogrammetry and Remote Sensing (ISPRS), 33., 2000, Amsterdam. **Proceedings...** Amsterdam, Holanda: International Archive Photogrammetry and Remote Sensing, 2000. p. 16-23.