

CLASSIFICAÇÃO AUTOMÁTICA DA COLHEITA DA CANA-DE-AÇÚCAR UTILIZANDO MODELO LINEAR DE MISTURA ESPECTRAL

Automatic Classification of Sugarcane Harvest Using Spectral Linear Mixing Model

Marcio Pupin Mello¹
Bernardo Friedrich Theodor Rudorff¹
Carlos Antonio Oliveira Vieira²
Daniel Alves de Aguiar¹

¹ **Instituto Nacional de Pesquisas Espaciais – INPE**
Divisão de Sensoriamento Remoto – DSR
Caixa Postal 515 - 12245-970 - São José dos Campos - SP, Brasil
mello@dsr.inpe.br
bernardo@dsr.inpe.br
daniel@dsr.inpe.br

² **Universidade Federal de Viçosa – UFV**
Departamento de Engenharia Civil - DEC
Campus Universitário – 36570-000 - Viçosa - MG, Brasil
carlos.vieira@ufv.br

RESUMO

A cana-de-açúcar é atualmente a melhor opção para produção de etanol e pode contribuir de forma significativa na mitigação da intensificação do efeito estufa. Contudo, a prática da queima da palha na pré-colheita da cana ainda constitui um grande problema ambiental que precisa ser eliminado. O governo do Estado de São Paulo e o setor privado estabeleceram um protocolo visando extinguir gradualmente essa prática até 2014. As imagens de sensoriamento remoto possuem grande potencial no monitoramento do manejo da colheita da cana com e sem a queima da palha na pré-colheita. Atualmente esse monitoramento é realizado com um forte apoio na interpretação visual, que apesar de alcançar resultados de qualidade, é um trabalho moroso. Este artigo tem como principal objetivo propor uma metodologia de classificação automática, utilizando a técnica de Modelo Linear de Mistura Espectral, para identificar as áreas de cana-de-açúcar colhidas com e sem queima. Um mapa gerado por interpretação visual foi utilizado como referência na avaliação da qualidade da classificação automática, que apresentou um índice de exatidão global de 89,7%. A metodologia proposta apresentou-se como uma alternativa promissora na automatização do monitoramento da colheita da cana-de-açúcar com e sem queima da palha.

Palavras chaves: Sensoriamento remoto, Imagens Multitemporais, Queima, Monitoramento.

ABSTRACT

Sugarcane is currently the best option to produce ethanol which can significantly contribute in the mitigation of the greenhouse effect intensification. However, the sugarcane straw burning prior to harvest is still a critical environmental problem that has to be eliminated. The São Paulo State government together with the private sugarcane production sector established a protocol to gradually stop the sugarcane straw burning by 2014. Remote sensing images have a great potential to monitor the harvest management procedure with and without straw burning prior to harvest. Currently, this monitoring is carried out using visual interpretation which provides high quality results but is a quite tedious work. The present article has the objective to propose an automated classification procedure based on Spectral Linear Mixing Model technique to identify sugarcane fields that were harvested with and without burning. A visual interpreted reference map was used to assess the automated classification map accuracy which showed an overall index of 89.7%. The proposed methodology showed to be a promising alternative to automate the monitoring of sugarcane harvested with and without straw burning.

Keywords: Remote Sensing, Multitemporal Images, Burning, Monitoring.

1. INTRODUÇÃO

A cana-de-açúcar tem recebido cada vez mais destaque no cenário mundial por ser matéria prima de grande eficiência na produção de biocombustíveis e conseqüente mitigação da intensificação do efeito estufa (ZUURBIER e VAN DE VOOREN, 2008). Segundo o Instituto Brasileiro de Geografia e Estatística (IBGE, 2009) o Estado de São Paulo foi responsável por quase 56% da área de cana-de-açúcar cultivada no Brasil na safra 2009. Entretanto, apesar do elevado nível tecnológico adotado no cultivo dessa cultura, a colheita ainda é efetuada, em grande parte, de forma manual, requerendo que seja feita a queima da palha na pré-colheita, o que contribui com o aumento da poluição atmosférica e conseqüentes prejuízos à saúde pública (KIRCHHOFF *et al.*, 1991; URIARTE *et al.*, 2009).

Visando antecipar a extinção da prática da queima na pré-colheita, que por força da lei deve cessar em 2031, 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 chamado “Protocolo Verde” para extinguir as queimadas em áreas mecanizáveis (declividade $\leq 12\%$), até 2014. O protocolo também estabelece metas para que pelo menos 70% da área cultivada seja colhida sem o uso do fogo até 2010, e que as lavouras de cana-de-açúcar que entram em produção pela primeira vez na safra 2009/10, não podem mais ser colhidas com queima (UNICA, 2009; SMA-SP, 2009). 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.

Atualmente, o Instituto Nacional de Pesquisas Espaciais (INPE) em parceria com a SMA-SP e UNICA vêm monitorando a colheita da cana-de-açúcar no Estado de São Paulo, por meio de imagens de média resolução espacial dos sensores Thematic Mapper (TM) e CCD a bordo dos satélites Landsat-5 e CBERS-2B, respectivamente (RUDORFF *et al.*, 2005; AGUIAR *et al.*, 2009; CANASAT, 2009). O atual processo de mapeamento é apoiado na interpretação visual, que fornece resultados precisos, mas demanda um tempo razoavelmente grande considerando a extensão do cultivo da cana-de-açúcar no Estado.

As imagens de satélites de sensoriamento remoto são obtidas sistematicamente em diversas faixas do espectro eletromagnético, possibilitando diferenciar os alvos da superfície terrestre em função da sua resposta espectral (JENSEN, 2006), constituindo assim peça fundamental no monitoramento e fiscalização do procedimento de colheita da cana-de-açúcar (AGUIAR, 2007). Estas imagens são compostas por inúmeros *pixels*, gerados por meio da resposta espectral integrada dos elementos que estão contidos no campo de visada instantânea (IFOV: *Instantaneous Field-Of-View*) de cada detector que compõe o sensor (JENSEN, 2006).

Assim, um único *pixel* em uma imagem pode conter uma proporção de vários componentes como, por exemplo, vegetação, solo e sombra (SHIMABUKURO e SMITH, 1991; KESHAVA e MUSTARD, 2002).

Com o objetivo de quantificar as proporções de cada componente dentro de cada *pixel*, Shimabukuro e Smith (1991) propuseram uma modelagem linear por ajuste de mínimos quadrados com restrições. A idéia é estimar a proporção dos componentes em cada *pixel* utilizando o chamado Modelo Linear de Mistura Espectral (MLME), e informações espectrais de amostras de *pixels* que contenham apenas um dos componentes a ser estimado. São os chamados *pixels* puros ou *endmembers* (TOMPKINS *et al.*, 1997).

Recentemente alguns trabalhos têm sido realizados utilizando o MLME de uma forma alternativa. Os trabalhos de Mello *et al.* (2008) e posteriormente de Machado *et al.* (2008) utilizaram imagens-fração derivadas da aplicação do MLME como elementos do vetor de atributos da classificação de máxima verossimilhança.

Nesse contexto, o presente trabalho teve por objetivo utilizar a técnica de Modelo Linear de Mistura Espectral para classificar as áreas de cana-de-açúcar colhidas com e sem a queima da palha, visando apresentar uma metodologia alternativa para automatizar o procedimento de interpretação visual inerente ao atual monitoramento da colheita da cana por meio de imagens orbitais.

2. MATERIAIS E MÉTODOS

2.1 Área de Estudo

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 km², que corresponde a um recorte de 500 x 500 *pixels* em uma imagem de resolução espacial de 30 x 30 m. Trata-se de uma região onde predomina o cultivo da cana-de-açúcar.

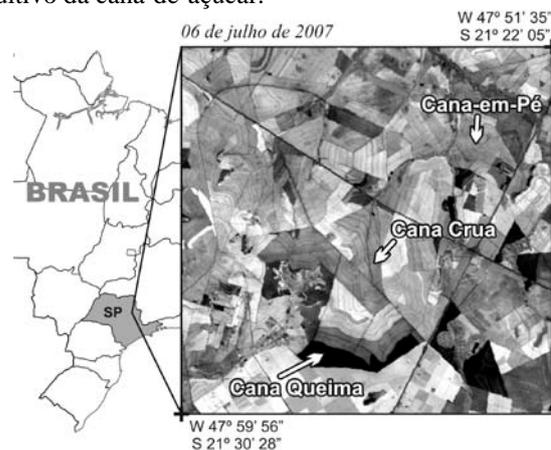


Fig. 1 – Imagem de 06 de julho de 2007 da área de estudo obtida pelo sensor TM/Landsat-5 na banda espectral do infravermelho próximo (coordenadas geográficas/SAD69).

2.2 Pré-processamento das imagens

Foram utilizadas seis imagens do ano de 2007 obtidas pelo sensor TM. 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-de-açúcar do Estado de São Paulo e não apresentarem cobertura de nuvens. As imagens foram registradas utilizando polinômios de primeiro e segundo grau e interpolação por vizinho mais próximo, com base em uma imagem previamente georreferenciada, apresentando, em todos os registros, um erro médio quadrático (RMS: *Root Mean Square*) inferior a 0,5 *pixel* (DAI e KHORRAM, 1998).

Em sequência a imagem de 06 de julho, por estar aproximadamente no “centro” da série temporal, foi corrigida radiometricamente de valor digital para reflectância aparente, com base nos parâmetros propostos por Chander *et al.* (2007) e para reflectância de superfície utilizando o algoritmo 6S (VERMOTE *et al.*, 1997). Como recomendado por Schroeder *et al.* (2006) todas as outras imagens da série temporal foram normalizadas radiometricamente tendo como base a imagem supracitada, previamente corrigida, utilizando o procedimento automático *Iteratively Re-weighted Multivariate Alteration Detection* (IR-MAD), descrito detalhadamente 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.

Uma das etapas do projeto Canasat de monitoramento da cana-de-açúcar envolve o mapeamento, por interpretação visual, das áreas de cana da safra corrente (RUDORFF *et al.*, 2005). Essa informação foi utilizada para gerar uma máscara que exclua todas as áreas que não são de cana para colheita.

2.3 Modelo Linear de Mistura Espectral

De posse da série temporal de imagens pré-processadas, aplicou-se a técnica de Modelo Linear de Mistura Espectral (MLME) por mínimos quadrados restritos (SHIMABUKURO e SMITH, 1991). Entendendo que, com a utilização da máscara, os elementos predominantes na cena são Vegetação, Palha (em decorrência da colheita da cana) e Cinza (em decorrência da colheita com o uso do fogo), o MLME utilizado (Equação 1) contempla as componentes Vegetação (V), Palha (P) e Cinza (C).

$$r_i = a_{1i} \cdot V + a_{2i} \cdot P + a_{3i} \cdot C + e_i \quad (1)$$

Em que:

- r_i : resposta espectral do *pixel* na *i*-ésima banda;
- a_{1i} : resposta do *endmember* V na *i*-ésima banda;
- a_{2i} : resposta do *endmember* P na *i*-ésima banda;
- a_{3i} : resposta do *endmember* C na *i*-ésima banda;
- V: proporção estimada do componente V no *pixel*;
- P: proporção estimada do componente P no *pixel*;
- C: proporção estimada do componente C no *pixel*;
- e_i : erro associado à *i*-ésima banda espectral no *pixel*.

O modelo foi então aplicado a cada imagem da série temporal utilizando as seis bandas espectrais do TM (todas, exceto a banda 6, correspondente ao infravermelho termal) e *endmembers* selecionados na própria imagem. Como resultado tem-se três imagens-fração em cada data, totalizando 18 imagens-fração ao longo da série temporal. Essas imagens-fração são então utilizadas como elementos do vetor de atributos da classificação de máxima verossimilhança (MaxVer). A Figura 2 ilustra a metodologia.

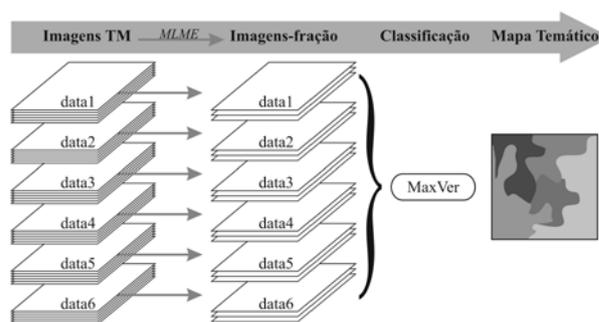


Fig. 2 – Metodologia utilizada para a classificação.

2.4 Classificação

As amostras de treinamento da classificação MaxVer são coletadas com base nas classes de interesse: Cana Crua (CC), que corresponde à cana-de-açúcar colhida sem o uso do fogo; Cana Queima (CQ), correspondendo à cana colhida com a queima da palha na pré-colheita; e Cana-em-Pé (CP), que corresponde a cana que não foi colhida.

Uma vez que o comportamento de determinado elemento da imagem (*pixel*) está intimamente ligado à data da colheita, foi necessário treinar 12 classes, sendo: seis classes de Cana Crua (CC1 a CC6, para Cana Crua colhida nas datas 1 a 6, respectivamente); cinco classes de Cana Queima (CQ1 a CQ4 e CQ6, para Cana Queima colhida nas datas 1 a 4 e 6, respectivamente – a classe CQ5 não apresentou número significativo de *pixels* para amostragem); e uma classe de Cana-em-Pé (CP). Isso foi necessário porque um *pixel* de Cana Queima colhida na primeira imagem (03 de maio), por exemplo, tem comportamento espectral-temporal totalmente deslocado no eixo do tempo em relação a um *pixel* de Cana Queima colhida na última imagem (08 de setembro), o que dificultaria a análise e incurriria em erros de classificação.

Foram amostrados de forma aleatória e independente 200 *pixels* por classe, totalizando 2400 *pixels* nas 12 classes treinadas. Como resultado da classificação MaxVer obteve-se um mapa temático, chamado de “mapa detalhado”, contendo as 12 classes treinadas. De posse desse mapa detalhado, as seis classes de Cana Queima foram agrupadas, assim como as cinco classes de Cana Crua, resultando num mapa temático, chamado de “mapa geral”, com as três classes de interesse: Cana Crua (CC), Cana Queima (CQ) e Cana-em-Pé (CP).

2.5 Avaliação da qualidade da classificação

A qualidade da classificação foi avaliada utilizando como referência um mapa obtido por interpretação visual das mesmas seis imagens utilizadas na classificação. O objetivo foi realizar uma comparação direta entre a interpretação visual e o método automático baseado no MLME.

A avaliação quantitativa da classificação foi realizada por meio dos índices de Exatidão Global (EG) e *Kappa* (κ) (CONGALTON e GREEN, 1999). Já a avaliação qualitativa foi realizada com base na idéia de erro binário, onde se obtêm um mapa representando os *pixels* classificados de forma discordante à referência. É importante lembrar que o mapa de referência, por se tratar de uma interpretação visual, não expressa fielmente a realidade de campo. Assim, quando uma discordância entre a classificação e a referência for tratada como “erro”, é fundamental o entendimento da subjetividade do termo.

3. RESULTADOS E DISCUSSÃO

Para cada uma das seis imagens da série temporal, procedeu-se um MLME específico, tendo como componentes do modelo as frações V, P e C. A Figura 3 ilustra o comportamento espectral dos *endmembers* selecionados para o MLME aplicado à segunda imagem (data) da série temporal.

Na aplicação do MLME, cada componente dá origem a uma imagem-fração. Assim, utilizando as seis imagens da série temporal, obteve-se 18 imagens-fração, sendo três (V, P e C) para cada data. A Figura 4 mostra as três imagens-fração resultantes da aplicação do MLME para a data 2. As imagens-fração resultantes da aplicação do modelo nas outras imagens da série temporal possuem o mesmo padrão das apresentadas na Figura 4, apesar que os talhões colhidos não são os mesmos.

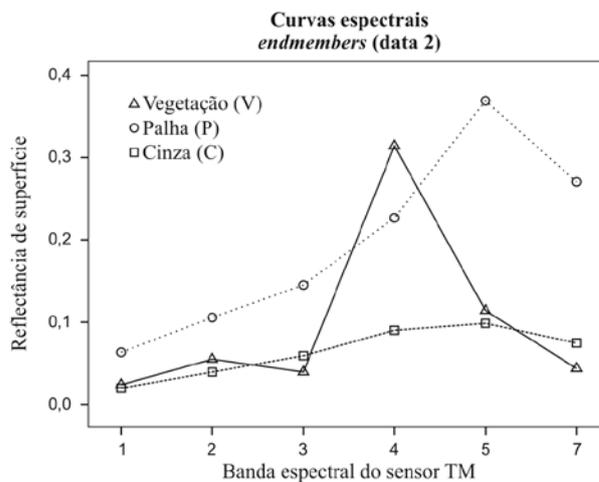


Fig. 3 – Comportamento espectral dos *endmembers* selecionados para o MLME aplicado à segunda imagem da série temporal.

Analisando a Figura 4 percebe-se que o Modelo Linear de Mistura Espectral é útil em distinguir as feições, delimitando os talhões correspondentes a cada classe que compõe o modelo. Apesar da fração C e P não se delimitarem tão bem quanto a V, a aplicação do MLME é útil no sentido de sintetizar os dados, reduzindo sua dimensionalidade, de seis bandas espectrais para três frações, em cada imagem da série temporal. Essa redução no vetor de atributos de 36 (6 datas x 6 bandas) para 18 (6 datas x 3 imagens-fração) elementos é válida na aplicação da classificação MaxVer no sentido de minimizar o problema conhecido como “maldição da dimensionalidade” ou “fenômeno de Hughes” (HUGHES, 1968; ABEND *et al.*, 1969). A classificação MaxVer teve as 18 imagens-fração como elementos do vetor de atributos, com base nas amostras de treinamento. O resultado é um mapa temático contento as 12 classes treinadas (Figura 5a).

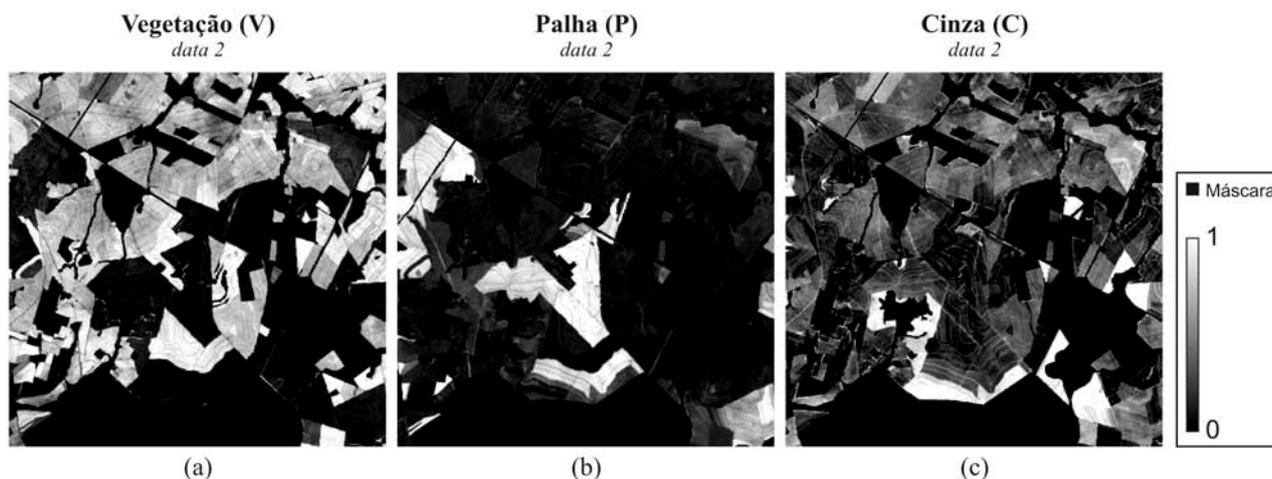


Fig. 4 – Imagens-fração resultantes da aplicação do MLME na segunda imagem (data 2) da série temporal. Frações: a) Vegetação, b) Palha; e c) Cinza.

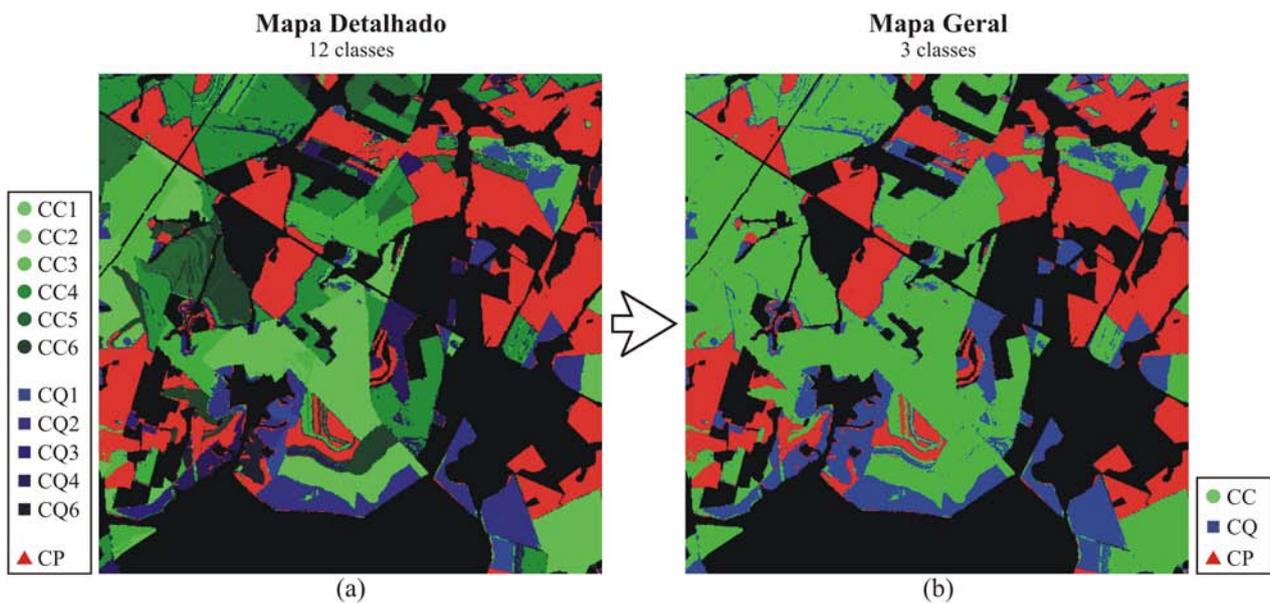


Fig. 5 – a) Mapa detalhado contendo as 12 classes treinadas: Cana Crua, representadas em verde (variando de verde mais claro para CC1 a verde mais escuro para CC6); Cana Queima, representadas em azul (azul claro para CQ1 até azul escuro para CQ6); e Cana-em-Pé (CP), em vermelho; e b) Mapa geral, onde as 12 classes foram agrupadas nas três classes de interesse: Cana Crua (CC), Cana Queima (CQ) e Cana-em-Pé (CP).

A análise quantitativa da precisão do mapa geral, resultante da classificação, foi realizada tomando como referência o mapa obtido por interpretação visual. Segundo Tso e Mather (2009), os dados de referência nem sempre refletem a verdade absoluta de campo, sendo a amostragem fortemente indicada para a avaliação da exatidão da classificação. Assim, foi selecionado aleatoriamente e independentemente um total de 1.500 *pixels*, sendo 500 para cada uma das três classes investigadas. Dessa avaliação resulta a matriz de confusão apresentada na Tabela 1, que também apresenta os valores dos índices de Exatidão Global (*EG*) e *Kappa* (κ) da classificação.

TABELA 1 – MATRIZ DE CONFUSÃO E VALORES DOS ÍNDICES *EG* e κ .

MaxVer	Referência			TOTAL	Índices	
	CC	CQ	CP		<i>EG</i>	κ
CC	454	52	7	513	89,7%	0,845
CQ	31	413	15	459		
CP	15	35	478	528		
TOTAL	500	500	500	1.500		

Tanto o valor do índice *EG* de 89,7% quanto o valor do índice κ de 0,845 são considerados excelentes (FOODY, 2002; LANDIS e KOCH, 1977). A maior confusão aconteceu em erros de omissão à classe CQ, quando o classificador classificou de maneira divergente à referência 10,4% (52/500) e 7,0% (35/500) do total de *pixels* da classe CQ como pertencentes às classes CC e CP, respectivamente.

Em complemento à análise quantitativa, gerou-se um mapa de discordâncias (Figura 6). Trata-se de um mapa temático contendo os *pixels* que o classificador

rotulou a uma classe diferente daquela atribuída pelo intérprete no mapa de referência.

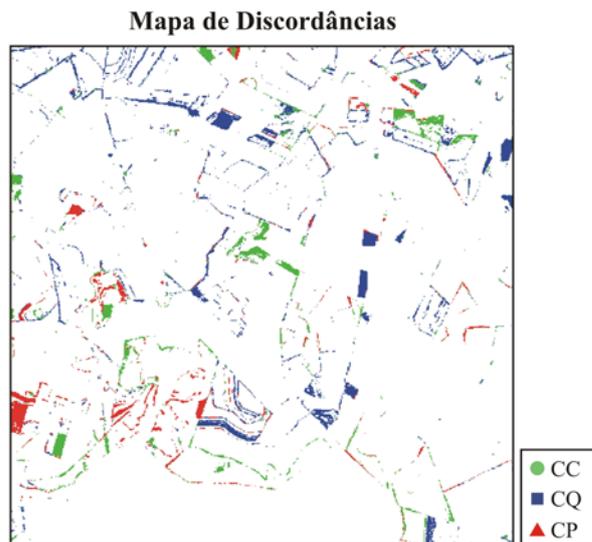


Fig. 6 – Mapa de discordâncias entre o mapa geral da classificação MaxVer e o mapa de referência. Os pontos do mapa representam os *pixels* classificados em classes diferentes da sua classe de referência.

O mapa de discordâncias apresentou um total de 14.286 *pixels*. Sendo: 26,7% (3.809) correspondendo a *pixels* “indevidamente” atribuídos à classe CC; 49,1% (7.014) à CQ; e 24,2% (3.463) à CP. A maior confusão ocorreu com os *pixels* que foram classificados como CQ quando pertenciam à classe CC na referência (5.442).

Apesar do modelo de mistura ter a “habilidade” de discriminar a mistura espectral dos *pixels*, percebe-se, inspecionando a Figura 6, que as

divergências se concentram massivamente nas bordas dos talhões, uma vez que, além da mistura espectral inerente desses *pixels* de bordas, existem as imperfeições do processo de registro das imagens. Uma discussão importante é que, em geral, as bordas estão associadas a erros de atribuição à classe CQ, justificando em parte o maior percentual de divergências supracitado (49,1%) relacionado a essa classe.

Outros erros em talhões de cana-de-açúcar colhida (CC e CQ) são decorrentes do seguinte fato: por convenção adotada no projeto Canasat, as classes de CC ou CQ são rotuladas de acordo com a primeira percepção visual diferente da cana em pé. Por exemplo, quando o intérprete vê que a cana-de-açúcar de um talhão foi colhida crua, ele mapeia como CC, 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 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 CQ.

A classe CC foi principalmente confundida com a CQ. Essas divergências relacionadas à atribuição “indevida” de *pixels* à classe CC 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 o modo de colheita. Esta dificuldade também ocorre na interpretação visual fazendo com que o dado de referência esteja sujeito a erros, mesmo que o intérprete tenha a sua disposição mais informações do que o classificador, que não leva em consideração, por exemplo, o formato e a textura dos talhões, linhas de colheita, proximidade dos talhões às áreas de mata e histórico de colheita do talhão. Por fim, algumas discordâncias relacionadas aos *pixels* atribuídos à classe CP podem ocorrer para talhões colhidos bem no início da safra (seja com ou sem queima) e que têm uma rebrota rápida (ou que sejam re-plantados), fazendo com que o classificador “entenda” que o padrão espectro-temporal destes talhões se assemelhe aos de CP.

De maneira geral os resultados mostraram-se excelentes. Entretanto, os procedimentos de modelagem e aplicação do MLME, apesar de já implementados em aplicativos como, por exemplo, o SPRING (CÂMARA *et al.*, 1996), exigem conhecimentos específicos sobre o comportamento espectral dos *endmembers*.

4. CONSIDERAÇÕES FINAIS

Os resultados deste trabalho mostraram que é possível utilizar a classificação automática multitemporal de imagens digitais e obter elevados graus de precisão e confiabilidade, quando do mapeamento de áreas da colheita de cana-de-açúcar

(com e sem a queima da palha) por imagens de satélites de sensoriamento remoto.

A técnica de Modelos Lineares de Mistura Espectral (MLME), apesar de demandar um tempo razoável na preparação do vetor de atributos da classificação, encontrou resultados satisfatórios, mas exige que o usuário conheça o comportamento espectral dos *endmembers* utilizados no modelo. Recomenda-se que sejam testados métodos automatizados de seleção dos *endmembers* (TOMPKINS *et al.*, 1997), o que tornaria o procedimento mais rápido e menos subjetivo.

AGRADECIMENTOS

Os autores agradecem ao Dr. Morton J. Canty, do *Jülich Research Center*, em Jülich, Alemanha, pela ajuda com a normalização radiométrica IR-MAD; e aos Drs Camilo D. Renno e Yosio E. Shimabukuro, do INPE, pela ajuda com o Modelo Linear de Mistura Espectral. O primeiro autor agradece à CAPES pelo apoio financeiro em forma de bolsa.

REFERÊNCIAS BIBLIOGRÁFICAS

ABEND, K.; HARLEY, T.; CHANDRASEKARAN, B.; HUGHES, G. Comments on 'On the mean accuracy of statistical pattern recognizers' by Hughes, G. F. **IEEE Transactions on Information Theory**, v. 15, n. 3, p. 420-423, 1969.

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

AGUIAR, D. A.; RUDORFF, B. F. T.; SILVA, W. F.; CARVALHO, M. A.; AULICINO, T. L. I. N.; BRANDÃO, D.; GOLTZ, E.; ADAMI, M.; SUGAWARA, L. M. **Mapeamento da colheita da cana-de-açúcar no estado de São Paulo - ano safra 2007/2008**. São José dos Campos-SP: INPE, 2009. 65p. (INPE-15724-RPQ/821).

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**. 2009. Disponível em: <<http://www.dsr.inpe.br/mapdsr/>>. Acesso em: 07 abr. 2009.

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.
- CHANDER, G.; MARKHAM, B. L.; BARSÍ, J. A. Revised Landsat-5 Thematic Mapper radiometric calibration. **IEEE Geoscience and Remote Sensing Letters**, v. 4, n. 3, p. 490-494, 2007.
- CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. Boca Raton, Florida, EUA: Lewis Publishers, 1999. 137 p.
- 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.
- HUGHES, G. On the mean accuracy of statistical pattern recognizers. **IEEE Transactions on Information Theory**, v. 14, n. 1, p. 55-63, 1968.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Levantamento sistemático da produção agrícola - Dezembro de 2009**. v. 21, n. 12, Rio de Janeiro-RJ: IBGE, 2009. 80p. (ISSN 0103-443X). Disponível em: <ftp://ftp.ibge.gov.br/Producao_Agricola/Levantamento_Sistematico_da_Producao_Agricola_%5Bmensal%5D/Fasciculo/lspa_200912.zip>. Acesso em: 01 fev. 2010.
- 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).
- KESHAVA, N.; MUSTARD, J. F. Spectral unmixing. **IEEE Signal Processing Magazine**, v. 19, n. 1, p. 44-57, 2002.
- KIRCHHOFF, V. W. J. H.; MARINHO, E. V. A.; DIAS, P. L. S.; PEREIRA, E. B.; CALHEIROS, R.; ANDRÉ, R.; VOLPE, C. Enhancements of CO and O3 from burnings in sugar cane fields. **Journal of Atmospheric Chemistry**, v. 12, n. 1, p. 87-102, 1991.
- LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, n. 1, p. 159-174, 1977.
- MACHADO, K. J.; SOARES, E. G. S.; CARVALHO, L. T.; MELLO, M. P.; VIEIRA, C. A. O. Avaliação do uso do modelo linear de mistura espectral na classificação de imagem ALOS. In: II Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação, Recife-PE, 2008. **Anais**. (CD-ROM). Disponível em: <http://mtc-m18.sid.inpe.br:80/rep-/sid.inpe.br/mtc-m18@80/2008/10.10.21.06>. Acesso em: 11 out. 2008.
- MELLO, M. P.; SILVA, G. B. S.; PEREIRA, G.; PRADO, B. R.; SHIMABUKURO, Y. E.; RUDORFF, B. F. T.; VIEIRA, C. A. O.; PETERNELLI, L. A. Avaliação do uso do modelo linear de mistura espectral na discriminação de fitofisionomias do Cerrado. In: IX Simpósio Nacional do Cerrado e II Simpósio Internacional de Savanas Tropicais, Brasília-DF, 2008. **Anais**. (CD-ROM). Disponível em: <http://mtc-m18.sid.inpe.br:80/rep-/sid.inpe.br/mtc-m18@80/2008/10.17.00.51>. Acesso em: 16 out. 2008.
- RUDORFF, B. F. T.; BERKA, L. M. S.; MOREIRA, M. A.; DUARTE, V.; XAVIER, A. C.; ROSA, V. G. C.; SHIMABUKURO, Y. E. Imagens de satélite no mapeamento e estimativa de área de cana-de-açúcar em São Paulo: ano-safra 2003/2004. **Agricultura em São Paulo**, v. 52, n. 1, p. 21-39, 2005. Disponível em: <http://www.iea.sp.gov.br/out/publicacoes/pdf/asp-1-05-2.pdf>. Acesso em: 03 jan. 2008.
- SCHROEDER, T. A.; COHEN, W. B.; SONG, C.; CANTY, M. J.; YANG, Z. Radiometric correction of multi-temporal Landsat data for characterization of early successional forest patterns in western Oregon. **Remote Sensing of Environment**, v. 103, n. 1, p. 16-26, 2006.
- SECRETARIA DE MEIO AMBIENTE DO ESTADO DE SÃO PAULO (SMA-SP). **Eliminação gradativa da queima da palha da cana-de-açúcar**. São Paulo-SP: SMA, 2009. Disponível em: <http://www.sigam.ambiente.sp.gov.br/sigam2/default.aspx?idPagina=123>. Acesso em: 15 mai. 2009.
- SHIMABUKURO, Y. E.; SMITH, J. A. The least-squares mixing models to generate fraction images derived from remote sensing multispectral data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 29, n. 1, p. 16-20, 1991.
- TOMPKINS, S.; MUSTARD, J. F.; PIETERS, C. M.; FORSYTH, D. W. Optimization of endmembers for spectral mixture analysis. **Remote Sensing of Environment**, v. 59, n. 3, p. 472-489, 1997.
- TSO B.; MATHER, P. M. **Classification methods for remotely sensed data**. 2 ed. Boca Raton, FL, USA: CRC, 2009. 356 p.
- UNIÃO DAS INDÚSTRIAS DE CANA-DE-AÇÚCAR (UNICA). **Cresce a mecanização na colheita de cana-de-açúcar em São Paulo**. 2009. Disponível em: <http://unica.com.br/noticias/show.asp?nwsCode=9C31>

6670-3A8A-4908-B41A-CEDC6E8B1088>. Acesso em: 12 mai. 2009.

URIARTE, M.; YACKULIC, C. B.; COOPER, T.; FLYNN, D.; CORTES, M.; CRK, T.; CULLMAN, G.; MCGINTY, M.; SIRCELY, J. Expansion of sugarcane production in São Paulo, Brazil: implications for fire occurrence and respiratory health. **Agriculture, Ecosystems & Environment**, v. 132, n. 1-2, p. 48-56, 2009.

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.

ZUURBIER, P.; VAN DE VOOREN, J., (Eds.). **Sugarcane ethanol: contributions to climate change mitigation and the environment**. Wageningen, Netherlands: Wageningen Academic Publishers, 2008. 256 p.