

AVALIAÇÃO DE MÉTODOS DE ESTIMATIVA DE COERÊNCIA ESPECTRAL PARA SELEÇÃO DE MEMBROS DE REFERÊNCIA EM IMAGENS HIPERESPECTRAIS

Evaluation of spectral coherence estimation methods for endmembers selection in hyperspectral images

Marco Antonio Pizarro^{1,2}
David Fernandes²

¹**Instituto Nacional de Pesquisas Espaciais (INPE)**
Divisão de Eletrônica Aeroespacial
Caixa Postal 515, 12201-970, São José dos Campos, SP, Brasil
pizarro@dea.inpe.br

²**Instituto Tecnológico de Aeronáutica (ITA-CTA)**
Divisão de Engenharia Eletrônica
Praça Mal. Eduardo Gomes, 50, 1228-900, São José dos Campos, SP, Brasil
{pizarro, david}@ita.br

RESUMO

A escolha acertada de membros de referência (MR) em imagens hiperespectrais é uma etapa importante do processo de classificação de alvos. Entre outros modelos, que utilizam os membros de referência, está o modelo linear de mistura espectral (MLME) que tem sido usado extensivamente na estimativa das frações abundâncias associadas aos MR. Propõem-se neste trabalho dois métodos para a seleção semi-automática dos MR. Estes métodos baseiam-se no conceito de coerência espectral, derivado do coeficiente de correlação. Nas metodologias propostas escolhem-se, a priori, amostras espectrais associadas a classes de alvos. Estas amostras candidatas a serem escolhidas como MR, são comparadas entre si pela medida de coerência espectral. O subconjunto de amostras que apresentar menor coerência relativa será escolhido como MR. Os métodos são testados e comparados com imagens hiperespectrais obtidas pelo sensor AVIRIS (Airborne Visible/InfraRed Imaging Spectrometer).

Palavras-chave: análise de dados hiperespectrais, imagens hiperespectrais, membros de referência, coerência espectral.

ABSTRACT

The right endmembers choice is an important task in the hyperspectral image classification processes. Among several models that use the endmembers there is the Linear Spectral Mixture (LSM). This model has been extensively used in the fractional abundance images estimation. This work proposes two semi supervised methods for endmembers selection based in the spectral coherence selection, which is an extension of the correlation coefficient concept. Spectral samples associated to classes are choosed a priori. These candidate samples to endmembers are compared by its relative spectral coherence. A subset of samples with minimum relative coherence will be selected as final endmembers. AVIRIS (Airborne Visible/InfraRed Imaging Spectrometer) images are used to test and compare the proposed methods.

Keywords: hyperspectral data analysis, hyperspectral image, endmembers, spectral coherence.

1. INTRODUÇÃO

Com o surgimento da tecnologia hiperespectral foram criadas novas perspectivas de aplicações em sensoriamento remoto. Um dos mais importantes

espectrômetro imageador, com este tipo de tecnologia, é o AVIRIS que cobre a faixa espectral de 383 a 2.508nm, com uma resolução espectral nominal de 10nm (GREEN et al., 1998).

Uma das abordagens mais utilizadas para analisar e classificar as imagens hiperespectrais é o modelo linear de mistura espectral (MLME). Com este modelo é possível estimar os valores de abundância das imagens-fração relativas aos membros puros (*endmembers*) ou membros menos contaminados da cena. Os membros puros ou ainda membros de referência (MR), são representados pelos espectros menos contaminados de amostras espectrais de classes de alvos presentes na imagem da cena observada pelo sensor.

Dentre as diversas aplicações do MLME pode-se citar:

- a) a caracterização das variações da reflectância espectral com os diferentes componentes na cena, a distribuição espacial dos tipos de solos e a produção de mapas contendo a variabilidade química (GALVÃO et al., 2001);
- b) o mapeamento de tipos de vegetação (ROBERTS et al., 1998) e
- c) a comparação de três índices de vegetação para medir pequenas diferenças, em porcentagem de cobertura com vegetação verde, em áreas esparsas em ambiente árido (MCGWIRE et al., 2000).

A seleção dos MR para a estimação das abundâncias pode ser feita utilizando-se as próprias imagens, ou podem ser obtidos em medidas de campo, ou em medidas de laboratório. Como as medidas dos espectros dos MR feitas em campo, ou em laboratórios, não são feitas nas mesmas condições do imageamento do sensor hiperespectral estes espectros podem não associar facilmente as feições presentes com a cena e, portanto, acarretar erros (KESHAVA E MUSTARD, 2002).

A seleção adequada dos tipos de MR, bem como o seu número, para serem utilizados no modelo de mistura permite uma melhor acurácia na estimação das imagens-fração abundâncias (ROBERTS et al., 1998).

Dentre as principais abordagens existentes para a seleção dos MR para o MLME pode-se citar:

- a) o uso da Análise por Componentes Principais (ACP), onde os MR são escolhidos a partir dos *pixels* extremos do diagrama de espalhamento obtido entre CP1 e CP2 (PIZARRO et al., 2001);
- b) a ACP em conjunto com software de visualização multidimensional para selecionar os MR de maneira interativa (BATESON & CURTISS, 1996) e
- c) a seleção de MR através da função *Pixel Purity Index* (PPI) na qual se determina os *pixels* extremos dentro do espaço de atributos formado por uma imagem multiespectral, os quais correspondem aos elementos mais puros que compõem a cena, no conceito de mistura espectral (BOARDMAN et al., 1995).

Os métodos de seleção dos MR citados anteriormente são métodos supervisionados ou semi-supervisionados, dentre os métodos totalmente automáticos citam-se (BERMAN et al., 2004, PLAZA et al., 2004):

- a) o N-FINDR, método que encontra o conjunto de *pixels* que define o *simplex* com o volume máximo;

- b) o *iterative error analysis* (IEA) onde se inicia o processo com um dado espectro médio, candidato a membro de referência extraído dos dados e obtém-se a imagem erro. O processo é continuado até que um determinado número de MR é encontrado de tal forma a minimizar o erro na imagem erro e

- c) o AMEE que utiliza a abordagem morfológica, onde as informações espacial e espectral são igualmente empregadas para se obter os MR.

Neste trabalho propõem-se dois métodos semi-supervisionados para a seleção de MR, a partir das imagens hiperespectrais. Nestes métodos selecionam-se na cena classes de alvos e associa-se a cada uma destas classes amostras espectrais, que serão candidatas a serem escolhidas como MR, utilizando-se a medida de coerência espectral apresentada na seção dois e quatro.

Os métodos propostos combinam subjetividade e objetividade (semi-supervisionado). A subjetividade está associada a escolha das classes de alvos e das amostras espectrais candidatas a MR. Esta escolha pode ser realizada observando-se as diferentes classes de alvos presentes na imagem e mais refinadamente analisando-se os espectros das amostras destas classes. Para o bom desempenho do processo de seleção de MR deve-se superestimar o número de classes e amostras candidatas a MR, propiciando ao método maior liberdade de escolha. A objetividade do método está associada ao critério matemático de medida da coerência descrito na seção dois, e complementado na seção quatro, para a seleção dos MR dentre as amostras candidatas. Os métodos propostos eliminam o processo de tentativa e erro comum à maioria dos métodos supervisionados.

O desempenho da metodologia proposta foi avaliado em função do conhecimento a priori da área de estudo escolhida.

2. SELEÇÃO DOS MEMBROS DE REFERÊNCIA

Nesta seção apresenta-se o método principal para a seleção dos MR. Para melhor elucidar o procedimento proposto utilizou-se imagens hiperespectrais obtidas pelo sensor aerotransportado AVIRIS de uma área próxima da cidade de Campo Grande, MS, nas coordenadas 19°55'S e 53°30'W. Estas imagens foram adquiridas em 20 de agosto de 1995, praticamente no ápice da estação regional seca, em 224 faixas estreitas (~10 nm de largura), posicionadas na faixa espectral óptica de 383 a 2.508 nm e com resolução espacial nominal de 20 x 20 m. A subcena selecionada é formada por uma área retangular de 12 por 10 km (614 x 512 *pixels*), aproximadamente. Os dados, originalmente fornecidos em valores de radiancia, foram convertidos para valores de reflectância de superfície, pelo método de transferência radiativa baseado no MODTRAN (GREEN, 1991).

Na seção quatro apresenta-se um método alternativo ao proposto nesta seção. Este método alternativo é computacionalmente mais simples,

entretanto, tem um desempenho inferior ao método principal descrito nesta seção.

O conjunto de imagens hiperespectrais, com os valores de reflectância, é representado por $I_o(i, j, \lambda)$, onde (i, j) denota a localização do *pixel* na imagem e λ o comprimento de onda da banda espectral. Do conjunto de imagens testes foram excluídas as bandas de 1 a 7 por ausência de dados e 219 a 224 por estarem extremamente ruidosas. Nas bandas 78 a 85, 95 a 124 e 148 a 175 o MODTRAN introduziu correções excessivas, transformando as bandas de absorção causadas pelas respectivas influências do vapor d'água e do CO₂ em picos de reflectância. Os valores destas bandas foram suprimidos e novos valores foram estimados utilizando-se a função spline cúbica. O novo conjunto de imagens será representado por $I(i, j, n)$, onde $n = 1, 2, \dots, 211$ denota o número da banda, ou cada uma das imagens. O índice n foi utilizado em substituição a λ por simplicidade de notação e para enfatizar que para cada *pixel* da imagem tem-se um vetor discreto de amostras. Deste modo, os valores correspondentes ao comprimento de onda foram substituídos pelos respectivos valores do número da banda. No processo de interpolação considerou-se que os valores discretos dos espectros estão igualmente espaçados e correspondem todos a uma mesma largura de banda.

A metodologia proposta consiste em:

a) seleção de classes de alvos que possuem amostras espectrais candidatas a serem MR.

Na Fig. 1 salienta-se a localização destas classes de alvos nos dados AVIRIS tomados como exemplo. As classes são compostas por vegetação em diferentes estágios evolutivos e/ou diferentes espécies (VV, VV1, VV2, VV3, VV4), vegetação com pouca atividade fotossintética (VS), áreas com predomínio de Latossolo Vermelho Escuro (SLE, SLE1 e SLE2), Areia Quartzosa (SAQ e SAQ1) e pequenos corpos de água (A) situados ao longo da drenagem. Alvos contendo sombra não foram encontrados na cena.

Os critérios da escolha das classes de alvos bem como das amostras espectrais associadas a cada classe foram baseadas nas seguintes informações: no conhecimento prévio sobre as características da área de trabalho, advinda do estudo de PIZARRO (1999); do comportamento espectral de cada alvo e da composição colorida RGB, obtida com as bandas 24 (~677nm), 12 (~599nm) e 4 (~480nm), respectivamente, do sensor AVIRIS. Esta etapa caracteriza o caráter subjetivo ou supervisionado do método.

Seja o vetor espectro, $\vec{I}(i_k, j_k)$, definido por:

$$\vec{I}(i_k, j_k) = [I(i_k, j_k, 1) \ I(i_k, j_k, 2) \ I(i_k, j_k, 3) \ \dots \ I(i_k, j_k, 211)]^T \quad (1)$$

referente a amostra espectral k candidata a ser MR, onde $k = 1, 2, \dots, K$, K é o número total de amostras candidatas e T denota vetor transposto.

A dimensionalidade 211 refere-se aos espectros dos dados hiperespectrais utilizados como exemplo. Esta dimensionalidade dependerá do tipo do sensor imageador e das bandas efetivamente utilizáveis.




Fig. 1 – Imagem da banda 193 (2.270 nm), obtida pelo sensor AVIRIS da área de estudo, onde são apontadas as posições das classes de alvos selecionadas na qual foram extraídas as amostras espectrais.

b) derivada dos espectros.

Para cada amostra candidata seleciona-se uma pequena vizinhança $(M+1) \times (M+1)$, com M par, de onde são extraídos os $(M+1)^2$ espectros. Deriva-se, discretamente, cada um dos espectros obtendo-se a matriz tridimensional D_k , onde cada um dos seus elementos é o espectro derivado. Isto é feito com o intuito de se enfatizar as transições e eliminar o nível médio nos espectros originais das imagens (TSAI e PHILPOT, 2002; DEMETRIADES-SHAH et al., 1990):

$$D_k = \begin{bmatrix} \vec{I}_d(i_k - M/2, j_k - M/2) & \dots & \vec{I}_d(i_k - M/2, j_k + M/2) \\ \dots & \dots & \dots \\ \dots & \vec{I}_d(i_k, j_k) & \dots \\ \dots & \dots & \dots \\ \vec{I}_d(i_k + M/2, j_k - M/2) & \dots & \vec{I}_d(i_k + M/2, j_k + M/2) \end{bmatrix}_{(M+1) \times (M+1) \times 211} \quad (2)$$

onde: $\vec{I}_d(.,.)$ é o vetor espectro derivado.

c) coerência entre espectros derivados.

Utilizando-se o conceito de coeficiente de correlação entre dois conjuntos de dados (PAPOULIS, 1984) calcula-se a matriz coerência $C_{p,q}$, entre D_p e D_q com $p, q = 1, 2, \dots, K$:

$$C_{pq} = \begin{bmatrix} C_{pq(1,1)} & \dots & C_{pq(1,M+1)} \\ \dots & \dots & \dots \\ \dots & C_{pq(M/2,M/2)} & \dots \\ \dots & \dots & \dots \\ C_{pq(M+1,1)} & \dots & C_{pq(M+1,M+1)} \end{bmatrix}_{(M+1) \times (M+1)} \quad (3)$$

onde:

$$C_{p,q}(u,v) = \frac{\langle D_p(u,v) \bullet D_q(u,v) \rangle}{\sqrt{\langle D_p(u,v) \bullet D_p(u,v) \rangle \langle D_q(u,v) \bullet D_q(u,v) \rangle}} \quad (4)$$

sendo que: (u, v) identifica o vetor $\bar{I}_d(.,.)$ em D_p e D_q , com $u, v = 1, 2, \dots, M+1$, $0 \leq C_{p,q}(u,v) \leq 1$ e o símbolo \bullet representa uma multiplicação ponto a ponto entre os elementos de dois vetores e $\langle . \rangle$ representa a média amostral dos elementos do vetor.

A matriz coerência média é então calculada por:

$$C_K = \begin{bmatrix} \langle C_{1,1} \rangle & \langle C_{1,2} \rangle & \dots & \langle C_{1,K} \rangle \\ \langle C_{2,1} \rangle & \langle C_{2,2} \rangle & \dots & \langle C_{2,K} \rangle \\ \dots & \dots & \dots & \dots \\ \langle C_{K,1} \rangle & \langle C_{K,2} \rangle & \dots & \langle C_{K,K} \rangle \end{bmatrix}_{K \times K} \quad (5)$$

onde: $\langle C_{ij} \rangle = \langle C_{ji} \rangle$ com $i \neq j$ e $i, j = 1, 2, \dots, K$
e $\langle C_{ii} \rangle = 1$ para $i = 1, 2, \dots, K$.

d) determinação dos MR.

Faz-se a combinação das K amostras candidatas a MR em grupos de R amostras. R deve ser menor que o número de classes de alvos escolhidas no item a , do procedimento descrito. Além disso, no conjunto das R amostras não pode haver amostras de uma mesma classe. Esta combinação de amostras é disposta em forma matricial do seguinte modo:

$$C_R(e_1, e_2, \dots, e_R) = \begin{bmatrix} \langle C_{e_1, e_1} \rangle & \langle C_{e_1, e_2} \rangle & \dots & \langle C_{e_1, e_R} \rangle \\ \langle C_{e_2, e_1} \rangle & \langle C_{e_2, e_2} \rangle & \dots & \langle C_{e_2, e_R} \rangle \\ \dots & \dots & \dots & \dots \\ \langle C_{e_R, e_1} \rangle & \langle C_{e_R, e_2} \rangle & \dots & \langle C_{e_R, e_R} \rangle \end{bmatrix}_{R \times R} \quad (6)$$

onde: $e_1, e_2, \dots, e_R \in \{1, 2, \dots, K\}$ e $e_1 \neq e_2 \neq \dots \neq e_R$.

Calcula-se então a soma dos elementos fora e acima da diagonal principal de $C_R(e_1, e_2, \dots, e_R)$:

$$\Delta_R(e_1, e_2, \dots, e_R) = \sum_{p=1}^{R-1} \sum_{q=p+1}^R \langle C_{e_p, e_q} \rangle. \quad (7)$$

Enfatiza-se que as amostras espectrais correspondentes aos elementos (e_1, e_2, \dots, e_R) são pertencentes a classes candidatas distintas.

Se $\Delta_R(e_1, e_2, \dots, e_R) = 0$ tem-se que as amostras identificadas por (e_1, e_2, \dots, e_R) são ortogonais e, portanto bons MR.

O conjunto das R amostras escolhidas como MR é dada por (r_1, r_2, \dots, r_R) que minimiza $\Delta_R(e_1, e_2, \dots, e_R)$:

$$(r_1, r_2, \dots, r_R) = \arg \left[\min_{(e_1, e_2, \dots, e_R)} (\Delta_R(e_1, e_2, \dots, e_R)) \right]. \quad (8)$$

Como as amostras do conjunto (e_1, e_2, \dots, e_R) são de classes distintas garante-se que os MR identificados pelo conjunto (r_1, r_2, \dots, r_R) também o são.

e) número de MR a serem escolhidos.

Incrementa-se sucessivamente de uma unidade, a partir de dois, o valor de R , obtendo-se para cada R um conjunto de MR. A escolha do conjunto final de MR é feita analisando-se, a seqüência de classes relativas ao conjunto de MR escolhidos.

Nos dados hiperespectrais utilizados, como exemplo, escolheu-se 12 classes candidatas A, SLE, SLE1, VV, VV1, VV2, VV3, VV4, VS, SAQ, SAQ1, e SAQ2, mostradas na Fig. 1, e várias amostras espectrais por classe, tendo-se no total $K = 68$ amostras das 12 classes candidatas a MR. As amostras da classe SLE2, mostrada na Fig. 1, foram incluídas na classe SLE. O motivo da inclusão das amostras espectrais da classe de alvo SLE2 em SLE será discutido na próxima seção. Para a vizinhança das amostras selecionadas escolheu-se uma janela 5×5 , ou seja, $(M+1) = 5$. As classes relativas aos MR escolhidos para $2 \leq R \leq 8$ são mostradas na Tabela 1.

TABELA 1 – SEQÜÊNCIA DE CLASSES DE ALVOS RELATIVAS AOS MR ESCOLHIDOS EM FUNÇÃO DE R .

R	Classes escolhidas:
2	A e SLE
3	A, SLE e VV
4	A, SLE, VV e VS
5	A, SLE, VV, VS e SAQ
6	A, SLE, VV, VV3, VS e SAQ
7	A, SLE, VV, VV2, VS, SAQ e SLE1
8	A, SLE, VV, VV2, VV3, VS, SAQ e SLE1

VV, VV2 e VV3: vegetação em diferentes estágios evolutivos e/ou diferentes espécies; VS: vegetação com pouca atividade fotossintética; SLE e SLE1: áreas com predomínio de Latossolo Vermelho Escuro; SAQ: áreas com predomínio de Areia Quartzosa e A: pequenos corpos de água.

Observa-se na seqüência apresentada na Tabela 1 que para $R=6$ tem-se simultaneamente VV e VV3. Estas classes apesar de diferentes são classes correspondentes a vegetação. Para $R>6$ nota-se também

repetição de classes de um mesmo tipo (VV, VV2, VV3) e (SLE, SLE1). Este é um indício de que $R=5$ pode ser o número ideal de MR.

Observa-se, ainda, que as amostras espectrais selecionadas para as classes de alvos: A; SLE; VV; VS; e SAQ, se mantiveram inalteradas para $R=5, 6, 7$ e 8 . Isto indica certa robustez da metodologia proposta.

3. AVALIAÇÃO DO MÉTODO PROPOSTO

A área de estudo, que já foi parcialmente descrita na seção dois, é dominada pela presença de Inceptisols (Areia Quartzosa) e Oxisols (Latossolo Vermelho-Escuro) que representa uma transição química de baixo para médios teores de ferro, óxidos de titânio e fração argila (NOVAES et al., 1983). Também, é caracterizada por atividades agrícolas como pasto e alguns talhões de colheitas sazonais (por exemplo, milho e soja). A cobertura de vegetação natural está composta de pequenos bosques de cerrado. A chuva anual e a temperatura média são da ordem de 1.300 mm e 24°C, respectivamente, e a geologia regional é dominada pela presença de diferentes tipos de arenitos e basaltos (PIZARRO, 1999).

Define-se o vetor espectro médio $\bar{I}_m(i_k, j_k)$ para cada amostra k como a média amostral dos vetores espectros $\bar{I}(\dots)$ contidos na vizinhança $(M+1) \times (M+1)$ do *pixel* (i_k, j_k) :

$$\bar{I}_m(i_k, j_k) = \frac{1}{(M+1)^2} \sum_{p=i_k-M/2}^{i_k+M/2} \sum_{q=j_k-M/2}^{j_k+M/2} \bar{I}(p, q). \quad (9)$$

Os espectros médios de uma amostra de cada uma das 13 classes (A, SLE, SLE1, SLE2, VV, VV1, VV2, VV3, VV4, VS, SAQ, SAQ1 e SAQ2) da Fig.1 são mostrados na Fig. 2. Para o cálculo destes espectros médios também foi utilizado uma janela 5×5 , ou seja, $(M+1) = 5$.

Baseado no conhecimento adquirido no trabalho de campo na região em que foram coletadas as imagens e na análise de amostras espectrais das diversas classes presentes na cena, concluiu-se que os MR ideais deveriam pertencer a cinco classes: A, SLE, VV, VS e SAQ (PIZARRO, 1999). Este fato está em concordância com o resultado da seleção dos MR, para $R=5$, na Tabela 1.

Na Fig. 2c nota-se que os espectros médios representativos das classes SLE e SLE2 são muito semelhantes. Isto pode ser um indicativo de que essas duas classes, de fato, podem ser agrupadas em uma única classe. Este agrupamento, que foi realizado no exemplo mostrado na seção 2, levou a escolha dos MR considerados ideais.

Fazendo-se a seleção dos MR utilizando-se 13 classes, SLE2 separada de SLE, notou-se que a partir de $R=5$ o processo de seleção dos MR escolheu erradamente SLE2 no lugar de SAQ. Para $R=5$ a escolha dos MR foi: A, SLE, VV, VS e SLE2. Este

agrupamento, que poderá ser feito usando-se um procedimento análogo ao proposto para a seleção dos MR, minimizará o problema da escolha indevida de um MR, tal como aconteceu na escolha de SLE2 no lugar de SAQ. Após a identificação dos MR, pelo método proposto, os seus vetores espectros médios: $\bar{I}_m(i_{r_1}, j_{r_1})$, $\bar{I}_m(i_{r_2}, j_{r_2})$, ..., $\bar{I}_m(i_{r_n}, j_{r_n})$ foram utilizados no MLME

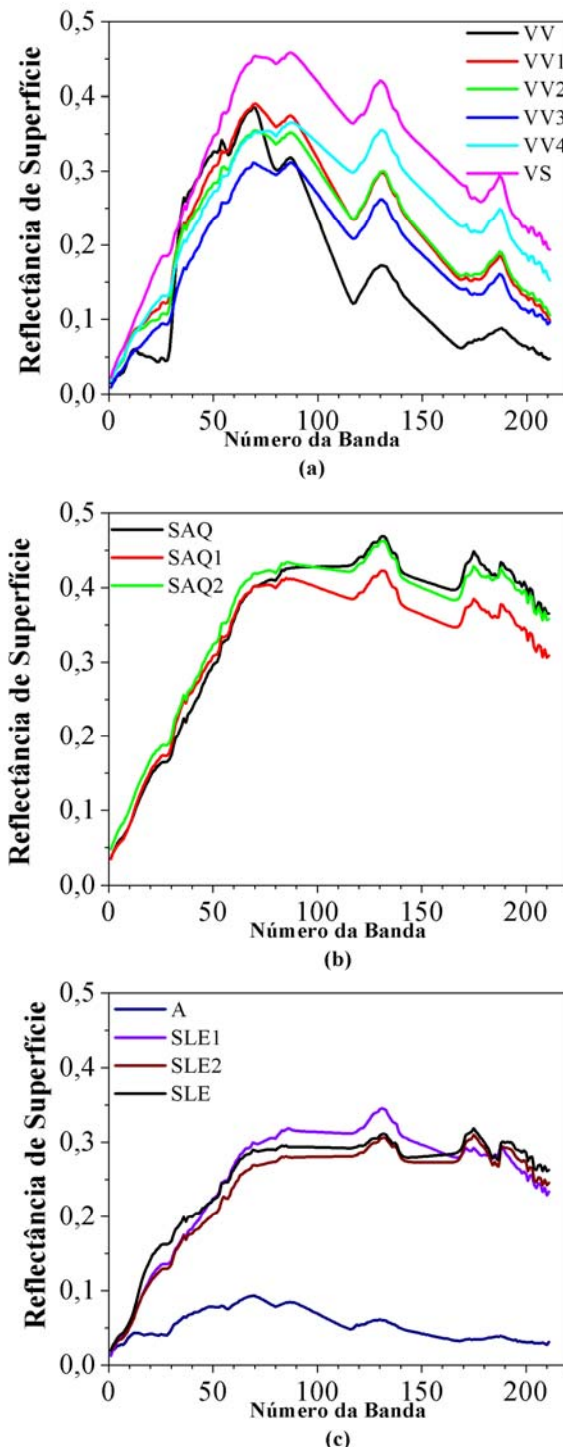


Fig. 2 - Espectros médios de amostras espectrais representativas das classes de alvos indicadas na Fig. 1.

para obtenção das imagens-fração abundâncias e da imagem-fração erro. Na Tabela 2 são mostrados a média (μ) e o desvio padrão (σ) da imagem-fração erro (512 x 614 pixels) para cada valor de R .

Observa-se na Tabela 2 forte influência da classe VS quando incorporada ao MLME. O valor de μ diminui cerca de 3,5 vezes a partir $R=4$ com a incorporação de VS. A partir de $R=5$ a variação do μ é pequena. Os valores mostrados na Tabela 2 são muito próximos aos obtidos em PIZARRO e FERNANDES (2003), onde foram selecionados cinco MR sobre um conjunto de imagens com dimensionalidade espectral reduzida e $K=40$.

TABELA 2 – VALORES DA MÉDIA (μ) E DESVIO PADRÃO (σ) DAS IMAGENS-FRAÇÃO ERRO.

R	μ	σ	Classes escolhidas:
2	25,26	5,61	A, SLE
3	23,29	5,66	A, SLE, VV
4	6,62	1,84	A, SLE, VV, VS
5	4,76	1,18	A, SLE, VV, VS, SAQ
6	4,50	1,21	A, SLE, VV, VV3, VS, SAQ
7	3,50	0,93	A, SLE, VV, VV2, VS, SAQ, SLE1
8	2,97	0,75	A, SLE, VV, VV2, VV3, VS, SAQ, SLE1

Utilizando-se para $R=5$ SLE2 no lugar de SAQ obtiveram-se $\mu=4,50$ e $\sigma=1,05$, valores melhores do que os mostrados na Tabela 2 para $R=5$. Entretanto, a escolha de SLE2 no lugar de SAQ não fornece uma boa imagem pós-classificada, adotando-se como critério de classificação valores de abundância superiores a 50% da somatória das frações. Este fato salienta que a melhor escolha é SAQ ao invés de SLE2.

4. PROCEDIMENTO ALTERNATIVO DE SELEÇÃO DOS MR

Alternativamente ao método apresentado na seção dois, define-se a coerência modificada. Esta coerência é calculada entre duas amostras espectrais candidatas a MR utilizando-se a derivada dos espectros médios destas amostras.

Sendo $\tilde{I}_{md}(i_k, j_k)$ a derivada discreta do espectro médio $\tilde{I}_m(i_k, j_k)$ da k -ésima amostra espectral, define-se a coerência modificada entre as amostras espectrais p e q com $p, q = 1, 2, \dots, K$ como:

$$C'_{p,q} = \frac{\langle \tilde{I}_{md}(i_p, j_p) \bullet \tilde{I}_{md}(i_q, j_q) \rangle}{\sqrt{\langle \tilde{I}_{md}(i_p, j_p) \bullet \tilde{I}_{md}(i_p, j_p) \rangle \langle \tilde{I}_{md}(i_q, j_q) \bullet \tilde{I}_{md}(i_q, j_q) \rangle}} \quad (10)$$

Em (10) se $\tilde{I}_{md}(i_p, j_p) = \tilde{I}_{md}(i_q, j_q)$ então $C'_{p,q} = 1$ além disso, $0 \leq C'_{p,q} \leq 1$.

Forma-se para todo conjunto de K amostras a matriz coerência modificada:

$$C'_K = \begin{bmatrix} C'_{1,1} & C'_{1,2} & \dots & C'_{1,K} \\ C'_{2,1} & C'_{2,2} & \dots & C'_{2,K} \\ \dots & \dots & \dots & \dots \\ C'_{K,1} & C'_{K,2} & \dots & C'_{K,K} \end{bmatrix}_{K \times K} \quad (11)$$

onde: $C'_{ij} = C'_{ji}$ com $i \neq j$ e $i, j = 1, 2, \dots, K$
e $C'_{ii} = 1$ para $i = 1, 2, \dots, K$.

Seguindo-se os mesmos passos descritos na seção dois, a partir do item d , faz-se a combinação das K amostras candidatas a membros de referência em grupos de R amostras, de classes de alvos diferentes, com os seus valores de coerência dispostos na matriz $C'_R(e_1, e_2, \dots, e_R)$.

$$C'_R(e_1, e_2, \dots, e_R) = \begin{bmatrix} C'_{e_1, e_1} & C'_{e_1, e_2} & \dots & C'_{e_1, e_R} \\ C'_{e_2, e_1} & C'_{e_2, e_2} & \dots & C'_{e_2, e_R} \\ \dots & \dots & \dots & \dots \\ C'_{e_R, e_1} & C'_{e_R, e_2} & \dots & C'_{e_R, e_R} \end{bmatrix}_{R \times R} \quad (6)$$

onde: $e_1, e_2, \dots, e_R \in \{1, 2, \dots, K\}$ e $e_1 \neq e_2 \neq \dots \neq e_R$.

Calcula-se então a soma dos elementos fora e acima da diagonal principal de $C'_R(e_1, e_2, \dots, e_R)$:

$$\Delta'_R(e_1, e_2, \dots, e_R) = \sum_{p=1}^{R-1} \sum_{q=p+1}^R C'_{e_p, e_q} \quad (7)$$

Enfatiza-se, como no método da seção dois, que as amostras espectrais correspondentes aos elementos (e_1, e_2, \dots, e_R) são pertencentes a classes candidatas distintas.

O conjunto das R amostras escolhidas como MR é dada por (r_1, r_2, \dots, r_R) que minimiza $\Delta'_R(e_1, e_2, \dots, e_R)$:

$$(r_1, r_2, \dots, r_R) = \arg \left[\min_{(e_1, e_2, \dots, e_R)} (\Delta'_R(e_1, e_2, \dots, e_R)) \right] \quad (8)$$

Como as amostras do conjunto (e_1, e_2, \dots, e_R) são de classes distintas garante-se que os MR identificados pelo conjunto (r_1, r_2, \dots, r_R) também o são.

O método apresentado é, computacionalmente, mais simples que o método apresentado na seção dois, pois o cálculo do espectro médio é mais simples que o cálculo da coerência média do primeiro método.

A Tabela 3 mostra o conjunto de classes relativas aos MR escolhidos em função de R . Neste caso, também foram escolhidas as mesmas 12 classes e amostras utilizadas anteriormente, com SLE2 incorporada a SLE.

TABELA 3 – VALORES DA MÉDIA (μ) E DESVIO PADRÃO (σ) DAS IMAGENS-FRAÇÃO ERRO, PELO MÉTODO ALTERNATIVO.

R	μ	σ	Classes escolhidas:
2	24,06	5,89	VV, SLE
3	23,29	5,66	VV, A, SLE
4	14,24	4,33	VV, A, SLE, SAQ
5	5,03	1,30	VV, A, SLE, SAQ, VS
6	3,97	0,96	VV, A, SLE, SLE1, SAQ, VS
7	3,59	0,96	VV, VV2, A, SLE, SLE1, SAQ, VS
8	3,34	0,88	VV, VV2, VV3, A, SLE, SLE1, SAQ, VS

Observa-se que para $R=5$ têm-se as mesmas classes da Tabela 2 relativa ao primeiro método proposto, entretanto, o erro médio calculado sobre a imagem fração erro é maior. O erro é maior em decorrência da alteração de escolha da amostra espectral pertencente à classe VS.

Seguindo-se o critério de escolha do número de MR que foi usado anteriormente e que consiste em evitar os MR que sejam de classes do mesmo tipo, chega-se também a $R=5$.

Se for incluída a décima terceira classe, ou seja, SLE2 separada de SLE, o número de MR que não tem classes do mesmo tipo é $R=3$.

Portanto, apesar deste segundo método ser mais eficiente computacionalmente ele é mais susceptível a erros por inclusão de uma classe indesejável no grupo dos MR, pois com $R=4$ aparecem classes do mesmo tipo quando SLE2 esta separado de SLE.

5. COMENTÁRIOS FINAIS

Foi proposta uma metodologia para a escolha de MR em imagens hiperespectrais baseada no cálculo da coerência média da derivada dos espectros de amostras de classes de alvos. Esta metodologia é semi-supervisionada, pois é necessário definir a priori as classes de alvos cujas amostras espectrais são candidatas a MR.

Foi proposto ainda um segundo método que utiliza o cálculo da coerência da derivada do espectro médio das amostras das classes de alvos. Este método apesar de ser, computacionalmente, mais simples apresentou um desempenho inferior ao primeiro método proposto.

Ambos os métodos foram testados com imagens hiperespectrais do sensor AVIRIS. Os resultados foram compatíveis com a seleção dos MR baseados em trabalho de campo e análise dos espectros dos alvos.

Foram feitas verificações utilizando-se o valor médio (μ) e desvio padrão (σ) da imagem-fração erro obtidas a partir do MLME. Estas verificações atestaram o bom funcionamento dos métodos. Verificou-se também a qualidade da imagem pós-classificada utilizando-se os MR selecionados. Notou-se que nem sempre baixos valores de (μ) levam a uma boa classificação, portanto, é de suma importância a análise da imagem pós-classificada.

Na metodologia apresentada não foi implementado o agrupamento automático entre classes similares. Foi verificado que este agrupamento pode melhorar a escolha dos MR que caracterizam melhor as variações espectrais na cena.

Deve-se, ainda, testar a consistência das amostras agrupadas em uma mesma classe. Este teste pode eliminar automaticamente erros de agrupamento.

Finalmente, salienta-se que na metodologia apresentada as amostras espectrais escolhidas como MR foram extraídas da própria imagem. Este fato pode permitir uma melhor caracterização da variabilidade espectral dos alvos presentes na cena.

AGRADECIMENTOS

Os autores agradecem: ao Laboratório de Tratamento de Imagens (LTID) do INPE, pela concessão das imagens do sensor AVIRIS utilizadas neste trabalho, à Divisão de Eletrônica Aeroespacial do INPE pelo apoio e ao Laboratório de Sistema de Vigilância (LASV-ITA) do Termo Aditivo I e III (ITA-ATECH-CCSIVAM) da Cooperação CTA-CCSIVAM pelo apoio computacional e aos revisores anônimos pelas sugestões feitas para a melhoria do texto.

REFERÊNCIAS BIBLIOGRÁFICAS

- BATESON, A.; CURTISS, B. A Method for Manual Endmember Selection and Spectral Unmixing. **Remote Sensing of Environment**, v. 55, n. 1, p. 229-243, Jan. 1996.
- BERMAN, M. et al. ICE: A Statistical Approach to Identifying Endmembers in Hyperspectral Images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 42, n.10, p. 2085-2095, Oct. 2004.
- BOARDMAN, J.W.; KRUSE, F.A.; GREEN, R.O. Mapping Target Signatures via Partial Unmixing of AVIRIS data. Annual JPL Airborne Geoscience Workshop, 5., Jan 23-26, 1995. **Proceedings**. Pasadena, NASA.JPL, Jan. 23, 1995. v.1, p. 11-14 (JPL Publication 95-1).
- DEMETRIADES-SHAH, T.H.; STEVEN, M.D.; CLARK, J.A. High resolution Derivative Spectra in Remote Sensing. **Remote Sensing of Environment**, v. 64, n. 1, p. 33-64, 1990.
- GALVÃO, L.S.; PIZARRO, M.A.; EPIPHANIO, J.C.N. Variations in Reflectance of Tropical Soils: Spectral-Chemical Composition Relationships from AVIRIS data. **Remote Sensing of Environment**, v. 75, n. 2, p. 245-255, Feb. 2001.
- GREEN, R.O. Retrieval of Reflectance from AVIRIS Measured Radiance Using a Radiative Transfer Code. In: Airborne Visible/Infrared Imaging Spectrometer (AVISIRIS) Workshop, 3., Pasadena, May 2021, 1991.

Proceedings. NASA.JPL, 1991. p.200-210. (JPL Publication 91-28).

GREEN, R.O., et al. Imaging spectroscopy and the Airborne Visible/Infrared Imaging Spectrometer (AVIRIS). **Remote Sensing of Environment**, v. 63, n. 3, p. 227-248, 1998.

KESHAHA, N.; MUSTARD, J.F. Spectral Unmixing. **IEEE Signal Processing Magazine**, v. 19, n. 1, p. 44-57, 2002.

MCGWIRE, K.; MINOR, T.; FENSTERMAKER, L. Hyperspectral Mixture Modeling for Quantifying Sparse Vegetation Cover in Arid Environments. **Remote Sensing of Environment**, v. 72, n. 3, p. 360-374, Jun. 2000.

NOVAES, A.S.S.; AMARAL FILHO, Z.P.; VIEIRA, P.C.; FRAGA, A.G.C. **Pedology**, Technical Report of the Radam Brasil Project, v. 31, Section SE.22, p. 413-576, 1983.

PAPOULIS, A. **Probability, Random Variables and Stochastic Processes**, MacGraw-Hill, 1986. 576p.

PIZARRO, M.A. **Sensoriamento remoto hiperespectral para a caracterização e identificação mineral em solos tropicais**. jun. 1999. 185 p. (INPE-7249-TDI/693). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 1999. Disponível na biblioteca digital URLib: <<http://iris.sid.inpe.br:1912/rep-/sid.inpe.br/deise/1999/10.22.17.45>>. Acesso em: 2004, Nov. 18.

PIZARRO, M.A.; EPIPHANIO, J.C.N; GALVÃO, L.S. Caracterização Mineralógica de Solos Tropicais por Sensoriamento Remoto Hiperespectral. **Pesquisa Agropecuária Brasileira**, v. 36, n. 10, p. 1277-1286, out. 2001.

PIZARRO, M.A.; FERNANDES, D. Aplicação da Medida de Divergência na Determinação de Membros de Referência em Imagens Hiperespectrais. In: Simpósio Brasileiro de Sensoriamento Remoto, 11., 5-10 abr. 2003, Belo Horizonte. **Anais...** São José dos Campos: INPE, 2003, p. 1083-1090. CD-ROM, Online. Publicado como: INPE--PRE/. Disponível na biblioteca digital URLib: <tid.inpe.br/sbsr/2002/11.18.21.19>. Acesso em: 27 out. 2004.

PLAZA, A.; MARTÍNEZ, P.; PÉREZ, R.; PLAZA, J. A Quantitative and Comparative Analysis of Endmember Extraction Algorithms from Hyperspectral Data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 42, n. 3, p. 650-662, Mar. 2004.

ROBERTS, D.A. et al. Mapping Chaparral in the Santa Monica Mountains Using Multiple Endmember Spectral Mixture Models. **Remote Sensing of Environment**, v. 65, n. 3, p. 267-279, Sept. 1998.

TSAL, F., PHILPOT, W.D. A Derivative-Aided Hyperspectral Image Analysis System for Land-Cover Classification. **IEEE Transactions on Geoscience and Remote Sensing**, v. 40, n. 2. p. 416-425, 2002.

Recebido em 04 de fevereiro de 2005 – Aceito para publicação em 11 de agosto de 2005.