

Medida de coerência espectral na seleção de membros de referência em dados hiperespectrais

Marco Antonio Pizarro^{1,2}
David Fernandes²

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

²Instituto Tecnológico de Aeronáutica (ITA) – Centro Técnico Aeroespacial
Praça Mal. Eduardo Gomes, 50, 1228-900, São José dos Campos, SP, Brasil
{pizarro,david}@ita.br

Abstract. The linear mixture model (LMM) has been used extensively in the hyperspectral remote sensing community to estimate the abundances fractions of spectral signatures within mixed pixels. However, the task of defining every endmember can be difficult, as evident from the importance attributed to the topic in the recent literature. This paper proposes a methodology to select the endmembers based on the measurement of the coherence among of the derivative medium spectrum of spectral samples, which are candidates to become endmembers.

Palavras-chave: hyperspectral data analysis, derivative analysis, class separability, endmember.

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 (Airborne Visible/InfraRed Imaging Spectrometer) que cobre a faixa espectral de 380 a 2.500 nm, com uma resolução espectral nominal de 10 nm (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 ou menos contaminados da cena. Os membros puros, ou membros de referência, são representados pelos espectros de classes menos contaminados das classes presentes na imagem da cena observada pelo sensor.

A seleção dos membros de referência 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 membros de referência 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).

Neste trabalho propõe-se uma metodologia para a seleção de membros de referência a partir das imagens hiperespectrais da cena. Inicialmente, estabelece-se um conjunto de amostras de classes candidatas a serem membros e referência. Utilizando-se o critério matemático apresentado na seção três seleciona-se deste conjunto um subconjunto que formará os membros de referência.

O desempenho da metodologia proposta foi avaliado com êxito pelas imagens-fração erro obtido a partir do MLME, utilizando-se as imagens hiperespectrais do sensor AVIRIS, com 224 bandas, de uma região de Campo Grande.

2. Descrição da área teste

A área de estudo situa-se próximo à cidade de Campo Grande, MS, e nas coordenadas 19°55'S e 53°30'W. A área é dominada pela presença de Inceptisols (Areia Quartzosa) e Oxisols (Latosolo 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).

Os dados AVIRIS foram adquiridos 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 radiância, foram convertidos para valores de reflectância de superfície, por um método de transferência radiativa baseado no MODTRAN (Green, 1991).

O conjunto de imagens, com os valores de reflectância, é representado por $I_o(i, j, \lambda)$, onde (i, j) denota a localização do pixel e λ o comprimento de onda da banda espectral. Do conjunto de imagens excluem-se 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 suprimidas 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. 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.

Na composição colorida da **Figura 1** salienta-se a localização, aproximada, dos pixels de classes candidatas a serem escolhidas como membro de referência. 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 porque o terreno é predominantemente plano.

Seja o vetor espectro, $I^p(i_k, j_k)$, construído como

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

referente a amostra k candidata a ser membro de referência, onde $k = 1, 2, \dots, K$ e T denota vetor transposto.

Define-se o vetor espectro médio $I_m^p(i_k, j_k)$ para cada amostra k como a média amostral dos vetores espectros $I^p(p, q)$ contidos em uma vizinhança $(M+1) \times (M+1)$, com M par, do pixel (i_k, j_k) :

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

A **Figura 2** mostra os vetores espectros médios $\overset{r}{I}_m(i_k, j_k)$ para cada classe de alvo indicados na **Figura 1**.



Figura 1 – Composição colorida RGB, obtida com as bandas 24 (~677nm), 12 (~599nm) e 4 (~480nm), respectivamente, do sensor AVIRIS.

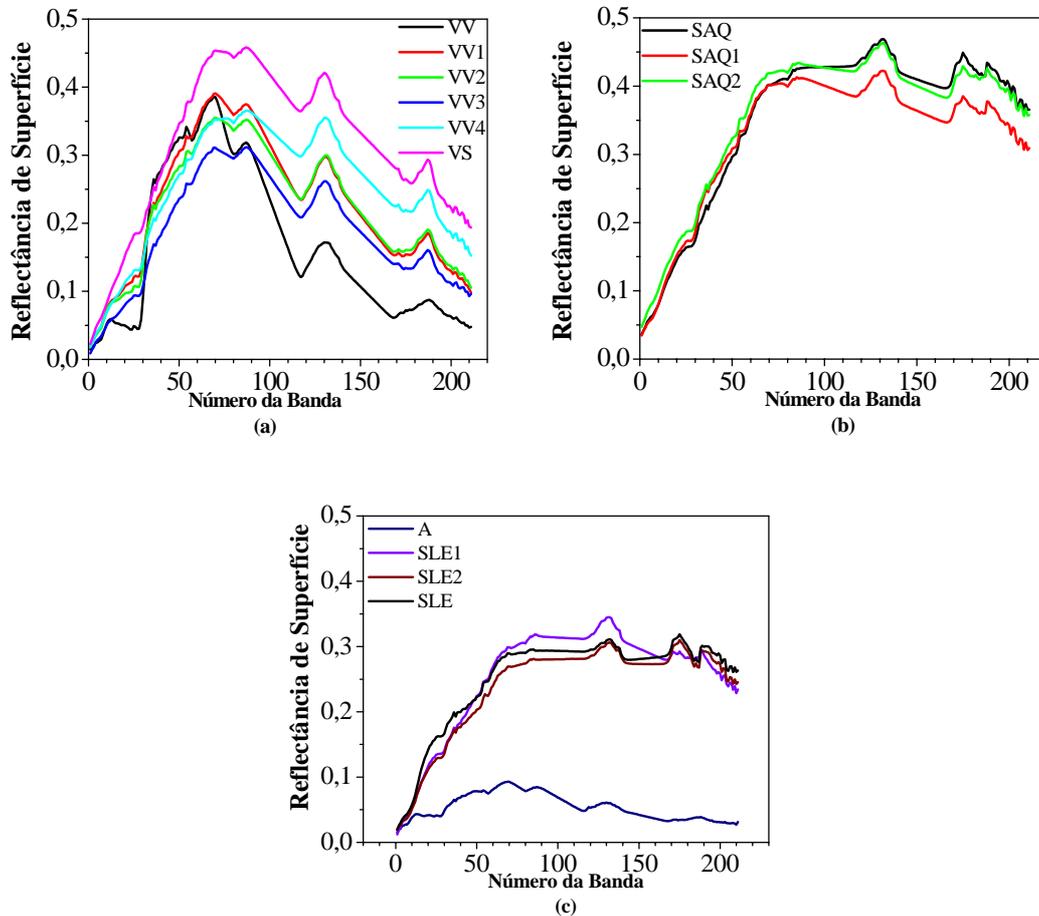


Figura 2 - Espectros ópticos médios obtidos para $M=4$ de amostras espectrais candidatas a membros de referência.

3. Seleção dos membros de referência

A metodologia proposta consiste em:

- escolher na imagem K amostras de classes candidatas a serem uma das R amostras pertencentes ao conjunto dos membros de referência ($R < K$);
- 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;
- estima-se o vetor espectro médio, utilizando-se (2) de cada uma das K amostras candidatas;

d) deriva-se, discretamente, o vetor espectro médio $\bar{Y}_m^p(i_k, j_k)$ para cada uma das amostras k com o intuito de se enfatizar as transições nos espectros originais (Tsai e Philpot, 2002; Demetriades-Shah et al., 1990). O vetor espectro médio derivado será representado por $\bar{Y}_{md}^p(i_k, j_k)$;

e) estima-se a coerência entre $\bar{Y}_{md}^p(i_k, j_k)$ de cada uma das amostras $k = 1, 2, \dots, K$ obtendo-se a matriz de coerência:

$$C_K = \begin{bmatrix} C_{1,1} & C_{1,2} & \dots & C_{1,K} \\ C_{2,1} & C_{2,2} & \dots & C_{2,K} \\ \dots & \dots & \dots & \dots \\ C_{K,1} & C_{K,2} & \dots & C_{K,K} \end{bmatrix} \quad (2)$$

onde a coerência $C_{p,q}$, $0 \leq C_{p,q} \leq 1$, entre dois espectros é definida para $p,q = 1,2,\dots,K$ por:

$$C_{p,q} = \frac{\left| \overset{r}{I}md(i_p, j_p) \bullet \overset{r}{I}md(i_q, j_q) \right|}{\left\| \overset{r}{I}md(i_p, j_p) \right\| \cdot \left\| \overset{r}{I}md(i_q, j_q) \right\|} \quad (3)$$

onde \bullet representa o produto escalar e $\| \cdot \|$ é a norma do vetor.

Em (3) se:

$$\overset{r}{I}md(i_p, j_p) = \overset{r}{I}md(i_q, j_q) \text{ então } C_{p,q} = 1.$$

f) Faz-se a combinação das K amostras candidatas a membros de referência em grupos de R amostras, com os seus valores de coerência dispostos na matriz $C_R(e_1, e_2, \dots, e_R)$:

$$C_R(e_1, e_2, \dots, e_R) = \begin{bmatrix} C_{e_1, e_1} & C_{e_1, e_2} & \dots & C_{e_1, e_R} \\ C_{e_2, e_1} & C_{e_2, e_2} & \dots & C_{e_2, e_R} \\ \dots & \dots & \dots & \dots \\ C_{e_R, e_1} & C_{e_R, e_2} & \dots & C_{e_R, e_R} \end{bmatrix} \quad (4)$$

onde $e_1, e_2, \dots, e_R = 1, 2, \dots, K$ e $e_1 \neq e_2 \neq \dots \neq e_R$;

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

$$\Delta_R(e_1, e_2, \dots, e_R) = \sum_{p=1}^{R-1} \sum_{q=p+1}^R C_{e_p, e_q} \quad (5)$$

Se a coerência cruzada entre os diversos vetores espectros (e_1, e_2, \dots, e_R) escolhidos for nula então $\Delta_R(e_1, e_2, \dots, e_R) = 0$ indicando que as amostras identificadas por (e_1, e_2, \dots, e_R) são ortogonais e portanto bons membros de referência;

h) o conjunto das R amostras escolhidas como membros de referência é dada pelo conjunto (r_1, r_2, \dots, r_R) com $r_1, r_2, \dots, r_R = 1, 2, \dots, K$ e $r_1 \neq r_2 \neq \dots \neq r_R$ que minimiza $\Delta_R(e_1, e_2, \dots, e_R)$:

$$(r_1, r_2, \dots, r_R) = \arg \left[\min_{(e_1, e_2, \dots, e_R)} (\Delta_R(e_1, e_2, \dots, e_R)) \right]; \quad (6)$$

i) na implementação desta metodologia agrupam-se as amostras candidatas a membros de referência em classes candidatas. A seleção dos membros de referência é feita de modo a não se

permitir que mais de uma amostra por classe candidata possa ser escolhida como membro de referência.

Após a identificação dos membros de referência, obrigatoriamente de classes diferentes, os seus vetores espectros médios: $\bar{I}_{md}(i_{r_1}, j_{r_1})$, $\bar{I}_{md}(i_{r_2}, j_{r_2})$, ..., $\bar{I}_{md}(i_{r_R}, j_{r_R})$ são utilizados para o cálculo do MLME e obtenção das imagens-fração abundâncias e da imagem-fração erro.

4. Avaliação do método proposto

Para o teste do método de seleção dos membros de referência escolheu-se 12 classes candidatas, mostradas na **Figura 1**, e várias amostras por classe tendo-se no total $K=68$ amostras de 12 classes candidatas a membros de referência. A amostra SLE2 foi incluída na classe SLE devido a grande proximidade dos seus espectros, como mostrado na **Figura 2**. O número de membros de referência escolhidos variou de 2 a 7 ($2 \leq R \leq 8$). As amostras candidatas foram selecionadas tendo-se por base a composição colorida da **Figura 1**, tomando-se o cuidado de não se misturar classes.

A implementação da metodologia de seleção dos membros de referência foi feita de tal modo que somente uma amostra de uma classe pudesse ser escolhida como membro de referência.

Aplicou-se a metodologia proposta na seção 3 para a seleção dos membros de referência. Na **Tabela 1** são mostrados os valores médios do erro (μ_{RMS}) RMS (root-mean-square) obtidos das imagens-fração erro.

Tabela 1 – Valores médios (μ_{RMS}) e desvio padrão (σ_{RMS}) das imagens-fração erro.

K	μ_{RMS} 314.368 pixels	σ_{RMS}	Classes escolhidas:
2	25,26	5,61	A e SLE
3	23,29	5,66	A, SLE e VV
4	6,62	1,84	A, SLE, VV e VS
5	4,76	1,18	A, SLE, VV, VS e SAQ
6	4,50	1,21	A, SLE, VV, VV3, VS e SAQ
7	3,50	0,93	A, SLE, VV, VV2, VS, SAQ e SLE1
8	2,97	0,75	A, SLE, VV, VV2, VV3, VS, SAQ e SLE1

Observa-se na **Tabela 2** a forte influência da classe VS quando incorporada ao MLME. O valor de μ_{RMS} diminui cerca de 4 vezes a partir $R=4$ com a incorporação de VS. A partir de $R=4$ a variação do μ_{RMS} é pequena. Os valores mostrados na **Tabela 1** são muito próximos aos obtidos em Pizarro e Fernandes (2003), onde foram selecionados cinco membros de referência sobre um conjunto de imagens dimensionalidade espectral reduzida e $K=40$. Outro fato interessante é 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 uma certa robustez da metodologia proposta.

Notou-se que com a inclusão da décima terceira classe SLE2 a partir de $R=5$ o processo de seleção dos membros de referência escolheu SLE2 no lugar de SAQ. Para $R=5$ a escolha dos membros de referência foi: A, SLE, VV, VS e SLE2. Com estes membros de referência obteve-se $\mu_{RMS}=4,50$ e $\sigma_{RMS}=1,05$, valores melhores do que os mostrados na **Tabela 1** 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.

Na **Figura 2** observa-se que as curvas espectrais das amostras SLE e SLE2 são bem similares indicando que estas duas classes podem pertencer ao mesmo tipo de solo. Na metodologia apresentada não foi implementado o agrupamento automático entre classes similares. Este procedimento poderia ter eliminado o resultado não satisfatório para $R=5$ da escolha simultânea de SLE e SLE2 como membros de referência.

A **Figura 4** mostra uma imagem pós-classificada com $K=5$ e os membros de referência A, SLE, VV, VS e SAQ. Observa-se que na parte inferior do lado direito da imagem há áreas mapeadas como A (água) em azul que na verdade são de outras classes. Este resultado mostra que há alguma contaminação da amostra espectral selecionada, pois os corpos de água são pequenos e como se utiliza uma janela de estimação espectral média 5×5 pode ocorrer contaminação da vegetação ribeirinha no espectro. Outro fator a ser considerado é sobre a adoção do MLME para a obtenção das imagens-fração, o resultado poderia ser melhor se fosse considerado o modelo não-linear, principalmente para o estudo da vegetação (Roberts et al., 1993).

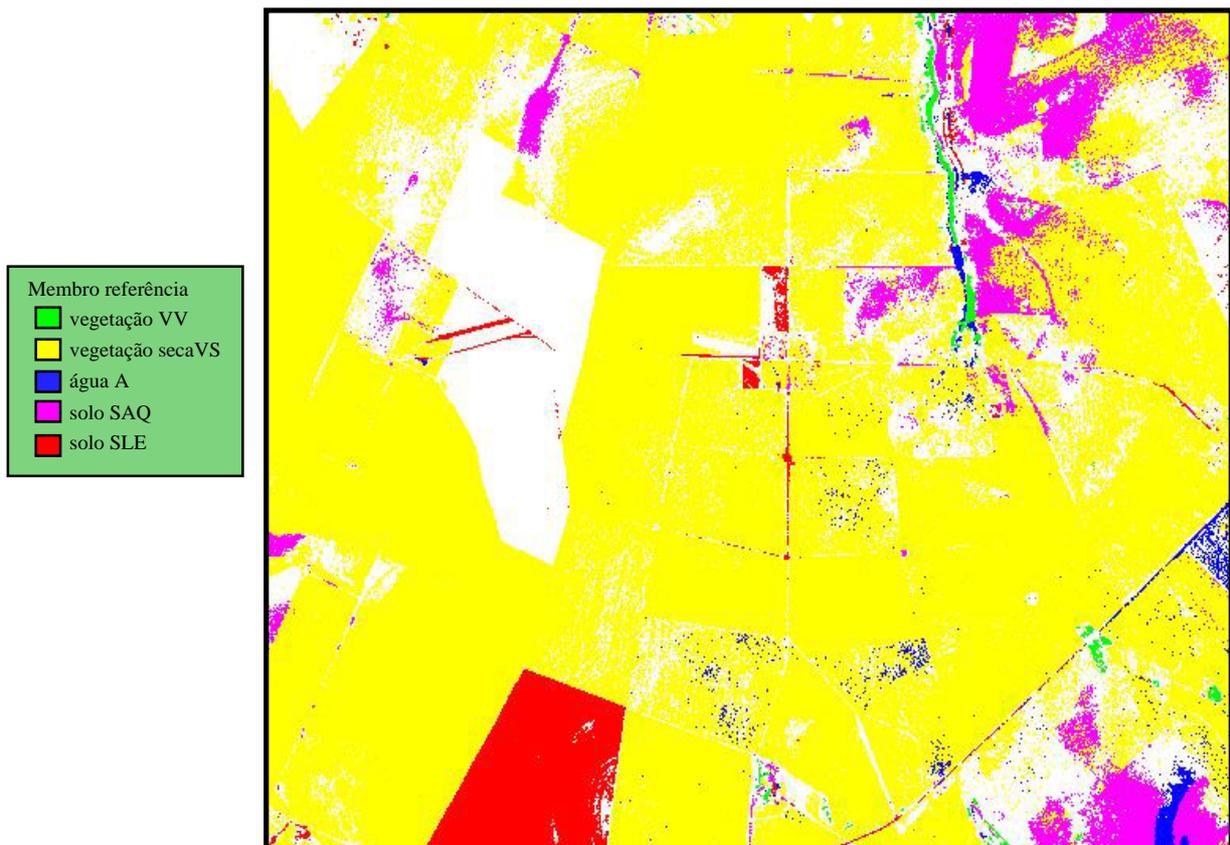


Figura 4 – A imagem resultante da aplicação do MLME, pós-classificada para realçar os pixels com valores de abundância dos membros de referência selecionados a 50 % da fração total. As áreas não-classificadas e, portanto, de intensa mistura espectral das componentes da cena são mostradas em branco.

4. Comentários finais

Foi proposta uma metodologia para a escolha de membros de referência em imagens hiperespectrais. Esta metodologia está baseada na seleção dos membros de referência a partir de um conjunto de amostras candidatas agrupadas em classes. Dado o número de membros de referência desejados a metodologia, que utiliza a medida de coerência entre a derivada dos espectros médios estimados, seleciona entre as amostras candidatas os membros de referência, sendo que somente uma amostra por classe candidata pode ser selecionada.

O método proposto foi testado com sucesso em um conjunto de imagens hiperespectrais do sensor AVIRIS.

A metodologia proposta para encontrar os membros de referência em imagens hiperespectrais, se apresentou interessante, pois ela mantém as classes de alvo inalteradas à medida que se aumenta o número de membros de referência (R) desejados. Notou-se que nem sempre baixos valores de (μ_{RMS}) levam a uma boa classificação, portanto é de suma importância a análise da imagem pós-classificada.

Deve ser mais bem investigada uma metodologia para o agrupamento automático de amostras semelhantes nas classes candidatas. Deve-se, também, verificar de forma automática a consistência das amostras agrupadas em uma mesma classe candidata.

Referências

- 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.
- Green, R.O. Retrieval of reflectance from AVIRIS measured radiance using a radiative transfer code. In: *Airborne Visible/Infrared Imaging Spectrometer (AVIRIS) 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.
- Keshava, N.; Mustard, J.F. Spectral unmixing. *IEEE Signal Processing Magazine*, v. 19, n. 1, p. 44-57, 2002.
- Novaes, A.S.S.; Amaral Filho, Z.P.; Vieira, P.C.; Fraga, A.G.C. *Pedology*, Technical Report of the Radam Brasil Project, Vol. 31, Section SE.22, p. 413-576, 1983.
- 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.
- 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.
- Roberts, D.A.; Smith, M.O.; Adams, J.B. Green vegetation, nonphotosynthetic vegetation, and soils in AVIRIS data. *Remote Sensing of Environment*, v. 44, n. 2/3, p. 255-269, 1993.
- Tsai, 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.