

# Efeito do ruído e de espectros contaminados na seleção de Membros de Referência em Imagens Hiperespectrais

Marco Antonio Pizarro<sup>1</sup>  
David Fernandes<sup>2</sup>

<sup>1</sup>Instituto Nacional de Pesquisas Espaciais - INPE  
Caixa Postal 515 - 12245-970 - São José dos Campos - SP, Brasil  
pizarro@dea.inpe.br

<sup>2</sup>Instituto Tecnológico de Aeronáutica – ITA/CTA  
Praça Mal. Eduardo Gomes, 50 – 1228-900 – São José dos Campos – SP, Brasil  
david@ita.br

**Abstract.** In the hyperspectral data the spectra quality has a great influence in the endmember search process that can be done by several methods presented in the literature. The spectral quality is mainly related with the spectral mixture and the signal-to-noise ratio ( $SNR$ ). In this work both spectral mixture and the noise are simulated in order to evaluate the endmember search process that was performed in this study by the maximum Entropy method. It was considered three data set of hyperspectral data, one of them with very similar pure spectral samples (green vegetation with different evolutionary stages and / or different species), and other with different kinds of pure spectral samples (vegetation, soil and water) and the last with similar and different mixed spectral samples. In all set of samples it was consider the noise effect with several  $SNR$  values. The spectra mixture was done by the combinations of abundances in a linear spectral mixture model, it was also used several values of abundances in order to simulate different kinds and intensity of contamination. Nine selected spectra from the AVIRIS sensor was used as pure spectra and to generate the mixture spectra with controlled  $SNR$ .

**Palavras-chave:** simulação hiperespectral, análise de mistura espectral, membros de referência, entropia, hyperspectral simulation, spectral mixture analysis, endmember, entropia.

## 1. Introdução

Uma das grandes questões tratando-se de dados hiperespectrais é conhecer quais os membros de referência (MR) ou os espectros menos contaminados em uma dada cena. Além disso, um dos principais problemas na análise da qualidade dos métodos de estimação das abundâncias provenientes do modelo linear de mistura espectral (MLME) advém do fato que as informações da verdade terrestre sobre as reais abundâncias dos alvos são difíceis (se não impossível) de se obter em cenários reais (Plaza et al., 2004). Este fato tem tradicionalmente impedido a existência de análises comparativas utilizando-se bancos de dados volumosos de imagens reais. Para sanar esta deficiência à simulação de dados hiperespectrais tem sido sugerida como um caminho simples e intuitivo para executar a avaliação preliminar dos métodos de análise (Plaza, et al., 2003). Há vários experimentos usando dados hiperespectrais simulados previamente relatados na literatura, p. ex. Chang et al. (2002); Collins, Roberts e Borel (2001); Ifarraguerri e Chang (1999) e Robinson, Gross e Schott (2000).

A razão primária para o uso dos dados simulados é testar algoritmos de processamento em cenários controlados, pois todos os detalhes da simulação dos dados hiperespectrais são conhecidos. A simulação ajuda também a compreender melhor a questão da mistura espectral no processo de identificação dos espectros menos contaminados (puros ou MR). Na simulação essa contaminação espectral, conhecida e controlada, bem como a consideração de ruído nos espectros é um procedimento eficiente na análise do desempenho dos métodos de seleção de MR e de classificação da imagem.

No presente trabalho o enfoque é sobre a análise qualitativa da escolha de MR através da medida de similaridade entropia ( $H$ ) (Pizarro e Fernandes, 2007) sobre os vetores espectros pertencentes a distintas classes de alvos (vegetação, solos e água) e também com a presença

vetores espectros similares extraídos da classe de vegetação que podem estar associadas a diferentes estágios evolutivos e/ou diferentes espécies, na presença de ruído. Testa-se também o efeito da mistura destes espectros juntamente com o ruído.

## 2. Modelo de simulação dos espectros misturados com ruído

O modelo simula vetores espectros, representativo de *pixels* da imagem hiperespectral, onde a cobertura espacial pode ter diferentes tipos de materiais. Assim cada *pixel* pode ser chamado de *pixel* misturado por poder conter múltiplos vetores espectros pertencentes a diferentes classes de alvos.

O  $k$ -ésimo espectro misturado,  $N$ -dimensional ou com  $N$ -bandas,  $\vec{I}_k$  de um dado *pixel*  $(i, j)$  é sintetizado através do MLME utilizando-se um conjunto de vetores espectros considerados puros ou MR definidos como  $\vec{e}_r$ ,  $r = 1, 2, \dots, R$ , de modo que:

$$\vec{I}_k = \vec{I}_{ok} + \vec{\varepsilon}_k, \quad k = 1, 2, \dots, K \quad (1)$$

onde

$$\vec{I}_{ok} = \sum_{r=1}^R \phi_{kr} \vec{e}_r \quad (2)$$

$K$  é o número total de *pixels* misturados,  $R$  é o número total de MR considerados,  $\phi_{kr}$  é um escalar que representa a fração abundância do MR  $\vec{e}_r$  na composição do espectro  $\vec{I}_k$  e  $\vec{\varepsilon}_k$  é o vetor ruído,  $N$ -dimensional, gaussiano, dependente de  $\vec{I}_{ok}$ . Considera-se que as frações abundâncias têm as seguintes restrições:

$$0 \leq \phi_{kr} \leq 1 \text{ e } \sum_{r=1}^R \phi_{kr} = 1 \quad (3)$$

O vetor ruído, ou erro,  $\vec{\varepsilon}_k$  dependente do espectro e modelado como (Okin et al., 2001):

$$\varepsilon_k(n) = \frac{I_{ok}(n) \eta_g(n)}{SNR(n)}, \quad n = 1, 2, \dots, N \quad (4)$$

onde  $\varepsilon_k(n)$  é a  $n$ -ésima componente de  $\vec{\varepsilon}_k$ ,  $I_{ok}(n)$  é a  $n$ -ésima componente de  $\vec{I}_{ok}$ ,  $\eta_g(n)$  é uma realização de um processo aleatório gaussiano de média nula e variância unitária e  $SNR(n)$  é a relação sinal-ruído dependente da banda considerada (Green et al., 1998; Green e Boardman, 2000). Dentre as principais fontes de ruído em sistemas aplicados em sensoriamento remoto destacam-se três: efeito da atmosfera; ruído associado ao detector e pré-amplificador e o ruído de quantização (Landgrebe e Malaret, 1986).

Para a simulação foram escolhidos 10 espectros ( $N = 210$  bandas), que foram considerados como MR, ou seja, espectros puros extraídos das subcenas 4 e 7 obtidas pelo sensor AVIRIS (Pizarro, 2007), linha de vôo Campo Grande, em 1995. Os espectros escolhidos foram:  $\nu\nu1$ ;  $\nu\nu2$ ;  $\nu\nu3$ ;  $\nu\nu4$ ;  $\nu\nu5$  (representando diversos estágios de vegetação verde);  $\nu s$  (vegetação seca);  $a$  (água); NV (NITOSSOLO VERMELHO); LV (LATOSSOLO VERMELHO) e RQ (NEOSSOLO QUARTZARÊNICO).

Estes espectros foram agrupados em dois conjuntos. Um com espectros distintos  $D = \{v1; vs; a; NV; LV; NQ\}$  e outro com espectros similares  $S = \{v2, v3, v4, v5\}$ . A Figura 1 mostra estes dois conjuntos de espectros.




Figura 1 - Espectros considerados MR utilizados nas simulações.

Na Figura 1 os espectros de reflectância foram obtidos a partir do processo de correção atmosférica que produz um espectro “limpo”, ou seja, com a influência reduzida dos efeitos atmosféricos e do ruído.

Para a geração de espectros misturados utilizou-se as frações abundâncias listadas na matriz  $\Phi$ , da expressão (5), que contem as frações abundâncias  $\phi_{kr}$ :

$$\Phi^T = \begin{bmatrix} \phi_{11} & \phi_{21} & \dots & \phi_{401} \\ \phi_{12} & \phi_{22} & & \phi_{402} \\ \vdots & \vdots & & \vdots \\ \phi_{110} & \phi_{210} & \dots & \phi_{4010} \end{bmatrix} \quad (5)$$

onde

$$\Phi^r = \begin{bmatrix} 1,0 & 0,9 & 0,6 & 0,6 & 0,0 & 0,0 & 0,2 & 0,0 & 0,1 & 0,2 & 0,0 & 0,0 & 0,2 & 0,0 & 0,0 & 0,1 & 0,2 & 0,0 & 0,0 & 0,0 \\ 0,0 & 0,1 & 0,2 & 0,0 & 1,0 & 0,6 & 0,6 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,2 & 0,0 & 0,0 & 0,0 & 0,2 & 0,0 & 0,0 \\ 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 1,0 & 0,9 & 0,8 & 0,0 & 0,2 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 \\ 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 1,0 & 0,8 & 0,8 & 0,6 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 \\ 0,0 & 0,0 & 0,2 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 1,0 & 0,9 & 0,8 & 0,6 & 0,0 & 0,1 \\ 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,2 & 0,2 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,2 & 0,0 & 0,0 & 0,0 & 0,2 & 1,0 & 0,9 \\ 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 \\ 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 \\ 0,0 & 0,0 & 0,0 & 0,4 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 \\ 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,2 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 \\ 0,1 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,6 & 0,0 & 0,0 & 0,0 & 0,6 & 0,6 & 0,6 \\ 0,0 & 0,2 & 0,0 & 0,1 & 0,0 & 0,1 & 0,0 & 0,1 & 0,0 & 0,1 & 0,0 & 0,1 & 0,0 & 0,1 & 0,0 & 0,2 & 0,0 & 0,4 & 0,3 & 0,0 & 0,0 & 0,4 \\ 0,0 & 0,0 \\ 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,4 & 0,0 & 0,7 & 0,0 & 0,0 & 0,0 & 0,0 \\ 0,0 & 0,0 & 0,0 & 0,0 & 0,1 & 0,1 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 \\ 0,9 & 0,8 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,6 & 0,2 & 0,6 & 0,6 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 \\ 0,0 & 0,0 & 1,0 & 0,9 & 0,9 & 0,8 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,4 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,4 & 0,0 & 0,0 \\ 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 1,0 & 0,9 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,4 & 0,0 \\ 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 1,0 & 0,9 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 \\ 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 1,0 & 0,9 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 & 0,0 \end{bmatrix} \quad (6)$$

Os espectros misturados são representados pela nomenclatura original  $vv1$ ,  $vv2$ ,  $vv3$ ,  $vv4$ ,  $vv5$ ,  $vs$ ,  $a$ ,  $NV$ ,  $LV$  e  $RQ$  acrescido de uma letra minúscula de “a” a “d” que identifica o tipo de mistura. A seqüência dos espectros misturados é dada pelo conjunto  $M = \{vv1(a), vv1(b), vv1(c), vv1(d), vs(a), vs(b), vs(c), a(a), a(b), a(c), NV(a), NV(b), NV(c), NV(d), LV(a), LV(b), LV(c), LV(d), RQ(a), RQ(b), RQ(c), RQ(d), vv2(a), vv2(b), vv2(c), vv2(d), vv3(a), vv3(b), vv4(a), vv4(b), vv5(a), vv5(b), LV-RQ, vv1-vs-RQ, NV-RQ, vs-RQ, vs-NV, vv1-vv2, vv1-vv3, vv1-vs\}$ . Estes espectros do conjunto  $M$  correspondem as frações abundância  $\phi_{1r}, \phi_{2r}, \dots, \phi_{40r}$ , respectivamente, com  $r = 1, 2, \dots, 10$ . O índice (a) indica espectros puros e os demais índices espectros misturados.

O ruído foi considerado invariante com a banda, representada pelo índice  $n$  na expressão (4), e tendo  $SNR = 10, 30, 50, 70, 110, 150$  e  $400$ . Estes valores de  $SNR$  são iguais ou piores do que os valores encontrados no sensor AVIRIS missão de 1999. Nesta missão a  $SNR$  é de 1000 para 700 nm e 400 para 2.200 nm (Green e Pavri, 2000). Destaca-se ainda que este sensor apresenta maior  $SNR$  do que o sensor *Hyperion* que tem  $SNR$  de 150 para 700 nm e 40 para 2.200 nm (Pearlman et al., 2003). A relação sinal-ruído do AVIRIS é maior também do que a relação sinal-ruído dos sensores *ARIES-1* (*Australian Resource Information and Environment Satellite-1*) e do *NEMO* (*Naval EarthMap Observer*) (Okin et al., 2001).

### 3. Resultados e Discussão

Para a análise do efeito da mistura espectral e do ruído no processo de seleção dos MR utilizou-se o critério de seleção de MRs baseado no cálculo da máxima Entropia de um conjunto de espectros candidatos a MR. Esta metodologia de seleção de MR é descrita por Pizarro (2007) e Pizarro e Fernandes (2007).

No teste utilizou-se o conjunto de espectros  $S$  e  $D$ , sem mistura, mas com ruído, e o conjunto de espectros  $M$ , com espectros puros, misturados e com ruído.

Estabeleceu-se como situação ideal, considerando-se que o número de MR variava de 2 a 7 ( $R = 2, \dots, 7$ ), os MR escolhidos pelo método da máxima Entropia quando os espectros dos conjuntos  $S$ ,  $D$  e  $M$  sem ruído são utilizados para a busca de MR. A situação ideal de escolha dos MR pelo método da máxima Entropia é apresentada na Tabela 1.

Tabela 1: MR considerados como referência.

$R$	Conjunto $S$ :	Conjunto $D$ :	Conjunto $M$ :
2	$\nu\nu3; \nu\nu5$	$\nu\nu1 a$	$\nu\nu1(a); a(a)$
3	$\nu\nu3; \nu\nu4; \nu\nu5$	$\nu\nu1; a; LV$	$\nu\nu1(a); a(a); LV(a)$
4	$\nu\nu2; \nu\nu3; \nu\nu4; \nu\nu5$	$\nu\nu1; \nu s; a; LV$	$\nu\nu1(a); \nu\nu5(a); a(a); LV(a)$
5		$\nu\nu1; \nu s; a; NV; LV$	$\nu\nu1(a); \nu s(a); a(a); LV(a); RQ(a)$
6		$\nu\nu1; \nu\nu1; \nu\nu1; \nu\nu1; \nu\nu1$	$\nu\nu1(a); \nu s(a); a(a); NV(a); LV(a); RQ(a)$
7			$\nu\nu1(a); \nu s(a); \nu\nu4(a); a(a); NV(a); LV(a); RQ(a)$

Verificou-se nos testes que para a  $SNR \geq 400$  esta situação ideal sempre é verificada. A Tabela 2 mostra os MR escolhidos pelo método da máxima Entropia, considerando-se diversos valores de  $SNR$  menores que 400.

Na composição da Tabela 2 têm-se os resultados de somente uma realização dos espectros com ruído. Para um estudo mais quantitativo deve-se compilar os resultados de um grande número realizações para se evitar certas flutuações de resultados de desempenho como os presentes na Tabela 2.

Na Tabela 2 apresenta-se ainda o porcentual de erros na seleção dos MR, em relação ao caso ideal (Tabela 1).

Nota-se na Tabela 2, quando se tem interesse em selecionar apenas variedades de vegetação, como apresentado no conjunto  $S = \{\nu\nu2; \nu\nu3; \nu\nu4; \nu\nu5\}$ , a busca por MR teve resultados satisfatório a partir de  $SNR \geq 50$  para  $3 \leq R \leq 4$ . Para  $R = 2$  ocorreram alguns erros esporádicos.

No conjunto  $D = \{\nu\nu1; \nu s; a; NV; LV; RQ\}$ , formado por espectros distintos, os erros foram se alternando quanto ao número  $R$  de MR escolhidos.

Para o conjunto  $M$ , que apresenta uma situação mais próxima do real, nota-se mais claramente a tendência na diminuição dos erros na medida em que a  $SNR$  aumenta. Um fato interessante é que a seleção de uma maneira geral se dá primeiramente para os vetores espectros pertencentes ao conjunto  $D$ , espectros distintos, para depois começar a seleção dos pertencentes ao conjunto  $S$ , espectros semelhantes, à medida que melhora a  $SNR$ . Este fato se deve ao método de procura dos MR pela máxima Entropia que busca os espectros mais distintos.

No conjunto  $M$  além do ruído em cada espectro há também as misturas onde representam 75% do total de 40 espectros simulados. Estas misturas comprometem também a melhor escolha a partir deste conjunto de 40 espectros, que por sua vez e na sua grande maioria das vezes locais com misturas são a sua grande maioria em imagens hiperespectrais. Que por sua vez a seleção mal sucedida pode comprometer as imagens pós-classificadas obtidas através do MLME (Pizarro, 2007).

Tabela 2. MR selecionados.

SNR	R	Conjunto S :	Conjunto D :	Conjunto M :
10	2	$v_2; v_5$	$a; NV$	$NV(b); LV(b)$
	3	$v_2; v_3; v_5$	$a; NV; RQ$	$vs(c); LV(d); vseNV$
	4	$v_2; v_3; v_4; v_5$	$v_1; a; NV; RQ$	$vs(b); v_2(a); a(c); RQ(d); LVeRQ$
	5		$v_1; vs; a; NV; RQ$	$v_5(b); a(a); LV(a); v_1vseRQ; vseRQ$
	6			$v_5(b); a(a); LV(a); RQ(c); v_1vseRQ; vseRQ$
	7			$v_3(a); v_1ev_2; a(c); NV(a); LV(c); RQ(d); NVeRQ$
	<b>erro</b>	22,2%	50,0%	81,5%
30	2	$v_2; v_5$	$v_1; a$	$LV(a); vseRQ$
	3	$v_2; v_4; v_5$	$a; LV; RQ$	$a(a); LV(a); vseRQ$
	4	$v_2; v_3; v_4; v_5$	$a; NV; LV; RQ$	$v_4(b); a(a); LV(a); RQ(d)$
	5		$v_1; a; NV; LV; RQ$	$v_2(a); a(a); LV(c); RQ(a)$
	6			$v_2(a); a(a); NV(b); LV(c); LVeRQ$
	7			$v_2(a); vs(b); a(a); NV(b); LV(c); RQ(a); LVeRQ$
	<b>erro</b>	22,2%	21,5%	59,3%
50	2	$v_4; v_5$	$a; LV$	$a(a); RQ(b)$
	3	$v_3; v_4; v_5$	$v_1; a; LV$	$v_1(a); a(a); LV(a)$
	4	$v_2; v_3; v_4; v_5$	$v_1; a; NV; RQ$	$v_1(a); a(a); LV(a); RQ(b)$
	5		$v_1; a; NV; LV; RQ$	$v_1(a); a(a); LV(b); RQ(b); LVeRQ$
	6			$v_1(a); vs(b); a(a); LV(b); RQ(b); LVeRQ$
	7			$v_1(a); vs(a); a(a); NV(b); LV(c); RQ(b); LVeRQ$
	<b>erro</b>	11,1%	21,5%	44,4%
70	2	$v_3; v_5$	$a; LV$	$a(a); LV(a)$
	3	$v_3; v_4; v_5$	$v_1; a; LV$	$v_1(a); a(a); LV(a)$
	4	$v_2; v_3; v_4; v_5$	$v_1; a; LV; RQ$	$v_1(a); a(a); LV(a); RQ(b)$
	5		$v_1; a; NV; LV; RQ$	$v_1(a); a(a); NV(a); LV(a); RQ(b)$
	6			$v_1(a); v_5(b); a(a); NV(a); RQ(b); LVeRQ$
	7			$v_1(a); v_4(a); a(a); NV(a); LV(c); RQ(a); LVeRQ$
	<b>erro</b>	0 %	14,3%	29,6%
90	2	$v_3; v_5$	$v_1; a$	$a(a); LV(a)$
	3	$v_3; v_4; v_5$	$v_1; a; LV$	$v_1(a); a(a); LV(a)$
	4	$v_2; v_3; v_4; v_5$	$v_1; vs; a; LV$	$v_1(a); a(a); LV(a); RQ(a)$
	5		$v_1; a; NV; LV; RQ$	$v_1(a); v_5(b); a(a); LV(a); RQ(a)$
	6			$v_1(a); v_4(b); a(a); NV(b); LV(a); RQ(a);$
	7			$v_1(a); v_4(b); v_5(b); a(a); NV(b); LV(a); RQ(a)$
	<b>erro</b>	0 %	0 %	29,6%
110	2	$v_2; v_5$	$v_1; a$	$v_1(a); a(a)$
	3	$v_3; v_4; v_5$	$v_1; a; LV$	$v_1(a); a(a); LV(a)$
	4	$v_2; v_3; v_4; v_5$	$v_1; vs; a; LV$	$v_1(a); a(a); LV(a); RQ(b)$
	5		$v_1; a; NV; LV; RQ$	$v_1(a); v_5(b); a(a); LV(a); RQ(b)$
	6			$v_1(a); v_4(a); a(a); NV(b); LV(a); RQ(b)$
	7			$v_1(a); v_4(a); v_5(b); a(a); NV(b); LV(a); RQ(b)$
	<b>erro</b>	11,1%	7,1%	33,3%
150	2	$v_3; v_5$	$v_1 a$	$v_1(a); a(a)$
	3	$v_3; v_4; v_5$	$v_1; a; LV$	$v_1(a); a(a); LV(a)$
	4	$v_2; v_3; v_4; v_5$	$v_1; a; LV; RQ$	$v_1(a); v_5(b); a(a); LV(a)$
	5		$v_1; a; NV; LV; RQ$	$v_1(a); vs(a); a(a); LV(a); RQ(a)$
	6			$v_1(a); vs(a); a(a); NV(a); LV(a); RQ(a)$
	7			$v_1(a); vs(a); v_4(b); a(a); NV(a); LV(a); RQ(a)$
	<b>erro</b>	0 %	14,3%	7,4%

#### 4. Conclusões

Avaliou-se neste trabalho o efeito da mistura espectral e do ruído no processo de busca de MR. Nos testes utilizou-se o método da máxima Entropia para a seleção do MR e considerou-se a SNR independente da banda espectral, apesar do modelo de geração do ruído poder considerar a variação na SNR em função das bandas, portanto a técnica de simulação

implementada pode também ser aplicada a outros tipos de sensores desde que devidamente adaptada.

Com valores de  $SNR \geq 110$  a escolha dos MR tende a preservar as escolhas anteriores à medida que  $R$  aumenta. Isto mostra a consistência do algoritmo de busca de MR em dados hiperespectrais pelo método da máxima Entropia.

Para os três conjuntos de amostras utilizados resalta-se, de modo geral, que o processo de busca de MR tem uma dependência entre o número de candidatos a MR e a SNR. Quanto maior o conjunto de amostras candidatas, maior deve ser a SNR para se ter melhores resultados na busca dos MR.

Pelos testes realizados e tendo-se em conta os valores de  $SNR$  do sensor *Hyperion* pode-se prever que haverá certa dificuldade no processo de seleção dos MR nos dados hiperespectrais deste sensor, já que a sua melhor relação sinal ruído é 150. Observou-se ainda que de modo geral a  $SNR \geq 150$  produz bons resultados no processo de escolha dos MR. Este valor está próximo ao observado por Kruse (2002) onde este autor faz a comparação entre os dados obtidos pelo AVIRIS e o Hyperion para o mapeamento mineral e sugere que para as próximas missões com sensores hiperespectrais tenha relação  $SNR \geq 100$  na faixa do infravermelho médio (2.200 nm).

### Agradecimentos

Ao projeto CAPTAER-FINEP em desenvolvimento no ITA pelo apóio ao trabalho realizado.

### Referências Bibliográficas

Chang, C.-I.; Chiang, S.-S. Smith, J. A.; Ginsberg, I. W. Linear spectral random mixture analysis for hyperspectral imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v. 40, n. 2, p. 375-392, Feb. 2002.

Collins, E.F.; Roberts, D. A.; Borel, C.C. Spectral mixture analysis of simulated thermal infrared spectrometry data: an initial temperature estimate bounded TESSMA search approach. **IEEE Transactions on Geoscience and Remote Sensing**, v. 39, n. 7, p. 1435-1446, July 2001.

Green, R.O.; Boardman, J.W. Exploration of the relationship between information content and signal-to-noise ratio and spatial resolution in AVIRIS spectral data. In: Summaries of the 9th JPL Airborne Earth Science Workshop. **Anais**. Pasadena, CA, U.S.A.: JPL, 2000.

Green, R.O.; Eastwood, M.L.; Sarture, C.M.; Chrien, T.G.; Aronsson, M.; Chippendale, B.J.; Faust, J.A.; Pavri, B.E.; Chovit, C.J.; Solis, M. Imaging spectroscopy and the Airborne Visible/Infrared Imaging Spectrometer (AVIRIS). **Remote Sensing of Environment**, v. 65, n. 3, p. 227-248, Sept. 1998.

Green, R.O.; Pavri, B. AVIRIS in-flight calibration experiment, sensitivity analysis, and intraflight stability. In: AIRBORNE VISIBLE/INFRARED IMAGING SPECTROMETER (AVIRIS) WORKSHOP, 2000, Pasadena. **Proceedings...** Pasadena: NASA.JPL, 2000.

Ifarraguerri, A.; Chang, C. I. Multispectral and hyperspectral image analysis with convex cones. **IEEE Transactions on Geoscience and Remote Sensing**, v. 37, n. 2, p. 756-770, March 1999.

Landgrebe, D.A.; Malaret, E. Noise in remote-sensing systems: the effect on classification error. **IEEE Transactions on Geoscience and Remote Sensing**, v. GE-4, n. 2, p. 294-300, March 1986.

Okin, G.S.; Roberts, Dar A.; Murray, B.; Okin, W.J. Practical limits on hyperspectral vegetation discrimination in arid and semiarid environments. **Remote Sensing of Environment**, v. 77, n. 2, p. 212-225, April 2001.

Pearlman, J.S.; Barry, P.S.; Segal, C.C.; Shepanski, J.; Beiso, D.; Carman, S.L. Hyperion, a space-based imaging spectrometer. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 6, p. 1160-1173, June 2003.

Pizarro, M. A. **Triagem de amostras e múltipls medidas de similaridade spectral para seleção de membros de referência em imagens hiperespectrais**. 2007. 185 p. (CTA/ITA-IEE/TD-002/2007) Tese (Doutorado em Telecomunicações) – Instituto Tecnológico de Aeronáutica, São José dos Campos. 2007.

Pizarro, M.A.; Fernandes, D. Determinação de membros de referência em dados hiperespectrais pelo método da máxima entropia. **Revista Brasileira de Cartografia**, n.59/03, dezembro 2007.

Plaza, A.; Martinez, P.; Perez, 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. 650-663, March 2004a.

Plaza, J.; Plaza, A.; Martínez, P.; Pérez, R. H-COMP: a tool for quantitative and comparative analysis of endmember identification algorithms. [CD-ROM] In: Learning From Earth's Shapes & Colors, July 21-25, 2003. **Anais** . Toulouse, France: IGARSS, July 21-25, 2003.

Robinson, G.D.; Gross, H.N.; Schott, J.R. Evaluation of two applications of spectral mixing models to image fusion. **Remote Sensing of Environment**, v. 71, n. 3, p. 272-281, June 2000.