

# Classificação Não-Supervisionada de Dados Hiperespectrais Usando Análise em Componentes Independentes

José M. P. Nascimento\* José M. B. Dias\*\*

\* Instituto Superior de Engenharia de Lisboa  
Dep. de Engenharia de Electrónica e de Telecomunicações e de Computadores  
R. Conselheiro Emídio Navarro, 1, 1949-014 Lisboa  
Telefone: +351.21.8317237, Fax: +351.21.8317114  
E-mail: zen@isel.pt

\*\* Instituto Superior Técnico  
Instituto de Telecomunicações  
Av. Rovisco Pais, Torre Norte, Piso 10, 1049-001 Lisboa  
Telefone: +351.21.8418466, Fax: +351.21.841472  
E-mail: bioucas@lx.it.pt

## RESUMO

*No passado recente foram desenvolvidas várias técnicas para classificação de dados hiperespectrais. Uma abordagem típica consiste em considerar que cada pixel é uma mistura linear das reflectâncias espectrais dos elementos presentes na célula de resolução, adicionada de ruído. Para classificar e estimar os elementos presentes numa imagem hiperespectral, vários problemas se colocam: Dimensionalidade dos dados, desconhecimento dos elementos presentes e a variabilidade da reflectância destes. Recentemente foi proposta a Análise em Componentes Independentes, para separação de misturas lineares. Nesta comunicação apresenta-se uma metodologia baseada na Análise em Componentes Independentes para detecção dos elementos presentes em imagens hiperespectrais e estimação das suas quantidades. Apresentam-se resultados desta metodologia com dados simulados e com dados hiperespectrais reais, ilustrando a potencialidade da técnica.*

## 1 Introdução

O desenvolvimento de sensores de detecção remota de alta resolução espectral, denominados por sensores hiperespectrais, tem extendido as capacidades dos sensores existentes, nomeadamente na aquisição de dados sobre elementos na superfície terrestre. A informação gerada por estes sensores tem inúmeras aplicações, nomeadamente em mapeamento ambiental, investigação sobre alterações à escala global, investigação geofísica e geográfica, mapeamento de zonas húmidas, identificação de plantas e minerais, análise de colheitas e detecção e classificação de actividades de alvos [1], [2].

Os sensores hiperespectrais geram imagens compostas por centenas de bandas contíguas de alta resolução espectral ( $<10$  nm) no espectro óptico e infra vermelho, (0.4 a 2.5  $\mu\text{m}$  [3], [4]), permitindo distinguir elementos numa imagem com reflectâncias espectrais (designadas por assinaturas) semelhantes. Em muitos casos a resolução espacial destes sensores é de 10 a 20 metros. Em consequência, o vector de observação associado a cada pixel é uma mistura de vários elementos com concentrações distintas (designadas por abundâncias). A comunidade científica tem estudado o problema da detecção dos elementos presentes na imagem e a estimação das quantidades de cada elemento detectado.

Relativamente ao tipo de mistura de reflectâncias tem sido proposto o modelo linear [5] e o mistura não-linear [6]. Neste trabalho adopta-se o primeiro, até porque o não-linear pode ser

linearizado pelo método proposto por Johnson et al. [7].

O modelo linear define cada pixel como uma mistura linear das assinaturas espectrais dos elementos contidos na célula de resolução, imerso em ruído [8]. Baseado neste modelo têm sido propostos vários esquemas de classificação e estimação, nomeadamente os seguintes: projecção ortogonal [9], [10], classificação não supervisionada [11], [12], análise das componentes principais [13], estimador de máxima verosimilhança [14], filtro de Match [15] e fusão de dados [16]. Todos estes métodos necessitam de conhecer previamente as assinaturas dos materiais e precisam de processamento prévio para reduzir a dimensão dos dados. Recentemente foi proposta uma técnica que não é afectada com a dimensionalidade dos dados [17].

O desconhecimento das assinaturas, do seu número e a sua variabilidade em cada pixel e ainda o ruído introduzido no processo de aquisição das imagens hiperespectrais, afectam a robustez dos métodos de classificação tradicionais. Neste trabalho propõe-se uma metodologia baseada na análise em componentes independentes aplicada a dados hiperespectrais projectados no subespaço de sinal. A análise em componentes independentes tem vindo a ser investigada [18] para separação de misturas lineares de fontes estatisticamente independentes com distribuições não-gaussianas <sup>1</sup>.

A comunicação organiza-se da seguinte forma: Na Secção 2 formula-se o problema da estimação das abundâncias como um modelo de mistura linear; A Secção 3 apresenta sumariamente o conceito de análise de componentes independentes; A Secção 4 aborda aspectos de redução de dimensionalidade dos dados; Na Secção 5 são apresentados resultados obtidos com dados simulados e com dados reais.

## 2 Modelo de Mistura Linear

O modelo de mistura linear de assinaturas em dados hiperespectrais tem vindo a ser utilizado em trabalhos recentes para detectar e quantificar elementos numa imagem [8]. Este modelo admite que cada pixel da imagem hiperespectral é uma mistura linear de reflectâncias espectrais resultante dos diferentes materiais presentes. Seja um vector  $r$  de dimensão  $l \times 1$  representando um dado pixel da imagem hiperespectral, com  $l$  bandas, e  $n$  outro vector de igual dimensão representando ruído aditivo gaussiano com média nula e variância  $\sigma^2 I$ , em que  $I$  é a matriz identidade de dimensão  $l \times l$ . Tem-se portanto

$$r = M\alpha + n, \tag{1}$$

onde  $M = [m_1 \ m_2 \ \dots \ m_p]$  é uma matriz de dimensão  $l \times p$ , cujas colunas são linearmente independentes,  $m_k$  é um vector de dimensão  $l \times 1$  representando a assinatura do  $k$ -ésimo elemento e  $p$  o número de assinaturas de interesse. O vector  $\alpha = [\alpha_1 \ \alpha_2 \ \dots \ \alpha_p]^T$  de dimensão  $p \times 1$  denota a abundância de cada elemento no pixel  $r$ .

A maior dificuldade no processamento de dados hiperespectrais reside no desconhecimento da matriz  $M$ .

---

<sup>1</sup>De facto uma das fontes pode ter distribuição gaussiana.

### 3 Análise em Componentes Independentes

Seja  $x$  um vector de dimensão  $l \times 1$  de observações tal que

$$x = M\alpha, \quad (2)$$

onde  $M$  é uma matriz de dimensão  $l \times p$  ( $l \geq p$ ) de mistura desconhecida e  $\alpha = [\alpha_1 \ \alpha_2 \ \dots \ \alpha_p]^T$  um vector aleatório de dados desconhecidos, mutuamente independentes em que apenas uma das componentes  $\alpha_i$  pode ter distribuição gaussiana. Na análise em componentes independentes pretende-se obter  $W$ , uma matriz de separação de dimensão  $p \times l$ , em que

$$y = Wx = PC\alpha, \quad (3)$$

onde  $P$  é uma matriz de permutação e  $C$  uma matriz de escala, portanto diagonal. As matrizes  $P$  e  $C$  surgem aqui porque a análise em componentes independentes não permite determinar nem a ordem das componentes independentes nem a sua energia. O vector  $y$  é assim uma estimativa da fonte  $\alpha$  a menos de um factor de escala e de uma permutação.

O princípio básico da determinação das componentes independentes tira partido de ser a soma de duas variáveis independentes com distribuição não-gaussiana “mais gaussiana” do que as variáveis aleatórias originais (ver, p.e., [19] Cap. 2.5). Deste modo, pretende-se obter uma matriz  $W$  que maximize uma medida de não gaussianidade, para cada componente do vector  $y$ . Uma medida utilizada é a *negentropia* [20] e está na base do algoritmo *FastIca* apresentado em [20]. Outro critério possível é o da minimização da informação mútua de  $y$  dada por

$$\sum_i H(y_i) - H(y). \quad (4)$$

Este critério é seguido, por exemplo, nos trabalhos [21], [22].

Neste artigo adopta-se o algoritmo *FastIca* [20] por produzir bons resultados e ser eficiente do ponto de vista computacional.

A análise em componentes independentes assenta nos pressupostos de não-gaussianidade e independência das fontes. Relativamente aos dados hiperespectrais a hipótese de não-gaussianidade tem sido confirmada (ver, p.e., [23]). Porém, a hipótese de independência não se verifica; note-se que as fontes representam abundâncias por elemento de resolução cuja soma deve ser constante. Ainda assim, as experiências efectuadas sugerem que este paradigma conduz a resultados com sentido em dados hiperespectrais e por isso será adoptado neste trabalho.

### 4 Detecção do Subespaço de Sinal

O número  $l$  de componentes de  $r$  é de ordem das dezenas ou centenas. Todavia, na ausência de ruído os vectores de observação pertencem a um subespaço de dimensão  $p$ , normalmente de dimensão muito inferior a  $l$ . Este facto permite reduzir drasticamente a dimensionalidade dos vectores observados e simultaneamente aumentar a relação sinal ruído.

Para tal, projecta-se os dados observados na estimativa de máxima verosimilhança do subespaço de sinal gerado pela matriz  $M$ . O projector neste sub-espço é dado por [24]

$$P_M = U_P U_P^T, \quad (5)$$

onde  $U_P$  é a matriz dos  $p$  vectores próprios da matriz de correlação dos dados observados associados aos  $p$  maiores valores próprios. Cada pixel é então representado por um vector de dimensão  $p \times 1$  dado por

$$r' = U_P^T r. \quad (6)$$




Figura 1: Esquerda: Banda de imagem hiperespectral AVIRIS (canal  $0.76\mu m$ ); Direita: Módulo dos valores próprios da matriz de correlação dos dados observados em escala logarítmica.

Por observação da Figura 1, conclui-se que apenas os primeiros  $p = 10$  valores próprios têm energia significativa. Notar que os restantes têm valores menores do que três ordens de grandeza do maior valor próprio. Com esta redução de dimensionalidade verifica-se também o aumento da relação sinal ruído de um factor de  $l/p$  [10].

## 5 Resultados Experimentais

O método proposto é testado primeiro com dados simulados e depois com dados reais. No primeiro caso simula-se uma imagem hiperespectral de 30 linhas por 20 colunas, onde cada pixel é um vector com 224 bandas ( $l=224$ ) resultante da mistura linear de 3 materiais ( $p=3$ ) cujas reflectâncias são extraídas de uma base de dados e as abundâncias simuladas são apresentadas na Figura 2.

Os testes realizados medem a eficiência do método proposto com diferentes relações sinal ruído (SNR) definido como

$$SNR = 10 \log \frac{\sum_{ij} \|m_{ij}\|^2 / l}{\sigma^2}, \quad (7)$$

onde  $m_{ij}$  é  $i$ -ésimo elemento da assinatura  $m_j$  e  $\sigma^2$  a variância do ruído. O ruído pode ser decorrelacionado ou correlacionado com uma matriz de covariância dada por

$$R_{ij} = E[n_i n_j] = \rho^{|i-j|}, \quad (8)$$




Figura 2: No topo e na esquerda em baixo: Abundâncias dos materiais; Na direita em baixo: Reflectâncias espectrais de três materiais em função do comprimento de onda em  $\mu\text{m}$ .

com uma factor de correlação  $\rho = 0.9$ . Para medir a razão de semelhança entre a abundância do  $i$ -ésimo material e a sua estimativa utiliza-se a seguinte medida de desempenho

$$R_{dB} = 10 \log \frac{\|D_{ij}\alpha_j\|^2}{\|y_i - D_{ij}\alpha_j\|^2}, \quad (9)$$

onde  $D = WM$  é uma matriz  $p \times p$ , sendo a matriz  $W$  resultante do algoritmo *FastIca*,  $\alpha_j$  a abundância do material e  $y_i$  a sua estimativa. A Figura 3 apresenta a estimativa das abundâncias para os três materiais com uma relação sinal ruído de 5 dB. Nesta figura pode-se verificar que as abundâncias estimadas estão escaladas e permutadas.




Figura 3: Estimativa das abundâncias dos 3 materiais, com  $\text{SNR} = 5\text{dB}$ .

Na Figura 4 (gráfico à esquerda) é apresentada a razão de semelhança em dB em função da relação sinal ruído com ruído decorrelacionado e correlacionado com um factor  $\rho=0.9$ . Verifica-se por este gráfico que a relação é menor com ruído correlacionado e que o valor da razão aumenta

com relações sinal ruído maiores.




Figura 4: Razão de semelhança em função de SNR com ruído descorrelacionado (linha contínua) e ruído correlacionado com factor de 0.9 (linha interrompida); Esquerda: 3 materiais presentes na imagem; Direita: 5 materiais presentes na imagem;

Realizou-se outro teste em que a imagem hiperespectral é formada por uma mistura linear de 5 materiais adicionada de ruído. Nestas condições a medida de desempenho, para a mesma relação sinal ruído, é menor que no primeiro teste realizado (ver Fig. 4 à direita).

Finalmente realizaram-se testes com dados hiperespectrais reais. Para modelizar a variabilidade associada a uma dada assinatura, extraiu-se conjuntos  $s_i$  de assinaturas de três zonas de uma imagem hiperespectral correspondentes a três materiais diferentes (ver Fig. 5). A imagem hiperespectral foi posteriormente construída de acordo com as abundâncias geradas. Em cada pixel a assinatura  $m_i$  foi escolhida aleatoriamente do conjunto  $s_i$  referido anteriormente.

O procedimento descrito serve para gerar uma imagem a partir de dados reais em que se introduz variabilidade dentro da mesma assinatura, de forma controlada e próxima da realidade.

Numa imagem hiperespectral, cada elemento de resolução representa a mistura dos componentes presentes na área observada. As quantidades de cada componente representado num pixel está, assim, compreendido entre 0 e 1, sendo a soma sempre constante. Neste pressuposto, a quantidade de um dos componentes da mistura é dependente das restantes. Assim, a análise em componentes independentes determina apenas as abundâncias do número de componentes a menos de uma.

Procede-se então da seguinte forma: Extrai-se das abundâncias estimadas pelo algoritmo *FastIca* os pixels que tem valor máximo considerando estes como as assinaturas de dois materiais. A assinatura do terceiro material é determinada quando as abundâncias estimadas tem o seu valor mínimo. O resultado final obtém-se pelo produto da pseudo-inversa da matriz constituída pelas assinaturas obtidas pela imagem hiperespectral. A Figura 6 apresenta a abundância de um material e a sua estimativa para todos os pixels. Com estes resultados conclui-se que a determinação das abundâncias dos componentes é influenciada por quatro factores: A dimensionalidade dos dados, a variabilidade das assinaturas, o número de materiais presentes na imagem hiperespectral e o ruído no qual a mistura está imersa. Todos estes factores perturbam o desempenho da análise em componentes independentes e serão objecto de estudo em trabalhos futuros.

Banda da Imagem Hiperespectral

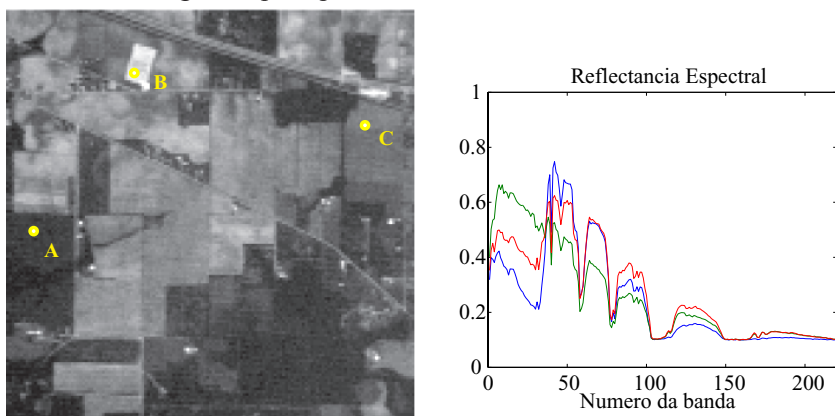


Figura 5: Esquerda: Banda da imagem hiperespectral (em amarelo as zonas de extracção de assinaturas); Direita: Assinaturas extraidas das três zonas da imagem.

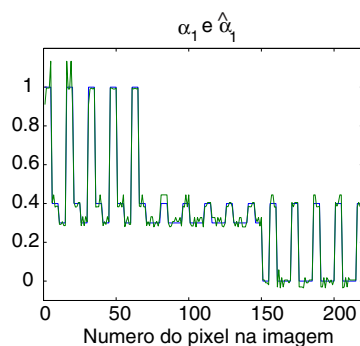


Figura 6: Abundâncias de um material e sua estimativa em função dos pixels da imagem.

## 6 Conclusões

Nesta comunicação apresentou-se uma metodologia de classificação não supervisionada de dados hiperespectrais baseada na Análise de Componentes Independentes. Foi adoptado o modelo de mistura linear para representar os dados hiperespectrais. O facto de se projectar os dados observados num subespaço de dimensão menor permite reduzir o ruído de observação e a dimensionalidade dos dados. Com os resultados apresentados concluiu-se que a análise em componentes independentes é eficaz na determinação das abundâncias dos materiais presentes na imagem hiperespectral, sendo o seu desempenho influenciado pelos seguintes factores: A dimensionalidade dos dados, a variabilidade das assinaturas, o número de materiais presentes na imagem hiperespectral e o ruído no qual a mistura está emersa.

São objectivos de trabalho futuro o estudo de técnicas de determinação do número de componentes que geram a imagem hiperespectrais e a modificação do procedimento de análise em componentes independentes tendo em conta a dependência das fontes hiperespectrais.

## REFERÊNCIAS

- [1] M. O. Smith, P. E. Johnson, and J. B. Adams, "Quantitative Determination of Mineral Types and Abundances from Reflectance Spectra Using Principal Component Analysis" in *Proc. 15th Lunar and Planetary Sci. Conf., Part 2, Geophys. Res.*, Vol. 90, Suppl., pp. C797-C804, Feb. 15, 1985.
- [2] A. R. Gillespie, M. O. Smith, J. B. Adams, S. C. Willis, A. F. Fisher, III, and D. E. Sabol, "Interpretation of Residual Images: Spectral Mixture Analysis of AVIRIS Images, Owens Valley, California" in *Proc 2nd AVIRIS Workshop, R. O. Green, Ed., Jpl Publ.* 90-54, 243-270.
- [3] T. Lillesand and R. Kiefer, "*Remote Sensing and Image Interpretation*", 3<sup>a</sup> ed., John Wiley & Sons, Inc., 1994.
- [4] G. Vane, R. Green, T. Chrien, H. Enmark, E. Hansen e W. Porter, "The Airborne Visible/Infrared Imaging Spectrometer (AVIRIS)", *Remote Sens. Environ.*, vol 44, pp. 127-143, May. 1993.
- [5] J. B. Adams e M. O. Smith, "A New Analysis of Rock and Soil Types at the Viking Lander 1 site." in *J. of Geophysical Research*, 91(B8):8098-8112, 1986.
- [6] B. Hapke, "Bidirectional Reflectance spectroscopy. I. Theory", *J. Geophys. Res.*, vol 86, pp. 3039-3054, Apr. 10, 1981.
- [7] P. Johnson, M. Smith, S. Taylor-George, and J. Adams, "A semiempirical method for analysis of reflectance spectra of binary mineral mixtures", *J. Geophys. Res.*, vol 88, pp. 3357-3561, 1983.
- [8] J. B. Adams, M. O. Smiths e A. R. Gillespie, "Remote Geochemical analysis: Elemental and Mineralogical Composition", *imaging spectroscopy: interpretation based on spectral mixture analysis*, C. Pieters and P. Englert, Eds. Cambridge: Cambridge Univ. Press, pp. 145-166, 1993.
- [9] J. C. Harsanyi and Chein-I Chang, "Hyperspectral Image Classification and Subspace Projection Approach", *IEEE Trans. On Geoscience and Remote Sensing*, Vol 32, No. 4, July 1994.
- [10] C. Chang, X. Zhao, M. L. G. Althouse and J. J. Pan, "Least Squares Subspace Projection Approach to Mixed Pixel Classification for Hyperspectral Images", *IEEE Trans. On Geoscience and Remote Sensing*, Vol 36, No. 3, May 1998.
- [11] A. Ifarraguerri and C. Chang, "Unsupervised Hyperspectral Image Analysis with Projection Pursuit", *IEEE Trans. On Geoscience and Remote Sensing*, Vol 38, No. 6, November 2000.
- [12] H. Ren and C. Chang, "A Generalized Orthogonal Subspace Projection Approach to Unsupervised Multispectral Image Classification", *IEEE Trans. On Geoscience and Remote Sensing*, Vol 38, No. 6, November 2000.
- [13] A. R. Heute, "Separation of Soil-plant Spectral Mixtures by Factor Analysis", *Remote sens. Environ.*, vol. 19, pp. 237-251, 1986.
- [14] J. J. Settle, "On the Relationship between Spectral Unmixing and Subspace Projection", *IEEE trans. Geosci. Remote Sensing*, vol. 34, pp. 1045-1046, July 1996.
- [15] A. S. Mazer, M. Martin et al. "Image Processing Software for Imaging Spectrometry Data Analysis", *Remote Sensing Environ.*, vol. 24, n<sup>o</sup> 1, pp 201-210, 1988.
- [16] Junping Zhang, Ye Zhang, et al. "Fusion classification of Hyperspectral Image Based on Adaptive Subspace Decomposition", *ICIP 2000*, Canada, pp. 472-475, 2000.
- [17] Junping Zhang, Ye Zhang and Tingxian Zhou, "Classification of Hyperspectral Data Using Support Vector Machines", *ICIP 2001*, pp. 882-885, 2001.
- [18] P. Common, "Independent Component Analysis: A New Concept", *Signal Processing*, 36, pp 287-314, 1994.
- [19] Richard O. Duda, Peter E. Hart and David G. Stork, "*Pattern Classification*", 2<sup>a</sup> ed., John Wiley & Sons, Inc., 2001.
- [20] Aapo Hyvarinen and Erkki Oja, "Independent Component Analysis: Algorithms and Applications", *Neural Networks*, 13(4-5):411-430, 2000.
- [21] A. J. Bell and T. J. Sejnowski, "An Information-maximization Approach to Blind Separation and Blind Deconvolution", *Neural Computation*, 10, 215-234, 1995.
- [22] J.F. Cardoso, "Informax and Maximum Likelihood of Source Separation", *IEEE Trans. on Signal Processing*, 44, 3017-3030, 1996.
- [23] Dimitris Manolakis, Christina Siracusa and Gary Shaw, "Hyperspectral Subpixel Target Detection Using Linear Mixing Model", *IEEE Trans. On Geoscience and Remote Sensing*, Vol. 39, N<sup>o</sup> 7, pp 1392-1409, July 2001.
- [24] Louis L. Sharf, "*Statistical Signal Processing, Detection, Estimation and Time Series Analysis*", Addison-Wesley Pub. Comp., 1991.