

Implementação do módulo de mistura espectral Spectral Multiple Correlation Mapper

Osmar Abílio de Carvalho Júnior
Nilton Correia da Silva

¹Departamento de Geografia - Universidade de Brasília (UnB)- Campus Universitário Darcy Ribeiro, Asa Norte, , 70910-900, Brasília, Distrito Federal osmarjr@unb.br

²Departamento de Sistemas de Informação - Centro Universitário de Anápolis (Unievangélica) - Avenida Universitária km 3.5 Cidade Universitária - Anápolis Goiás Brazil – Nilton@unievangelica.edu.br

Abstract

Spectral classifiers identify a particular element from comparing the degree of adjustment between the image spectrum and the reference spectrum that comes either from spectral libraries or from endmembers. However, these methods do not adopt the mixture concept integrally. This limitation causes errors mainly when an element occurs with low abundance. Thus, the best mixture model must be to identify in spectral classification. The method proposed to determine the best predictive model using the stepwise forward multiple regression analysis and SCM. The procedure proposed effects a stepwise forward estimation for each pixel in the following steps: (a) compute a single regression of each endmember, (b) calculate the value SCM and eliminate the variables absent in the pixels (with negative values), (c) determine the best variable (highest SCM), (d) calculate a models set with addition of a variable using multiple regression among the best variable and others remaining variables and (e) in case of the best model obtained a SCM values with significant contribution return to step “d” if not stop. This procedure using mathematical function enables a better accuracy because established a control test.

Palavras-chave: spectral classification, digital image processing, mixture, classificação espectral, processamento digital de imagem, mistura.

1. Introdução

As técnicas de classificação mais utilizadas baseiam-se nos procedimentos estatísticos de análise de grupos (análise não supervisionada) e na análise de discriminante (análise supervisionada). Nesses métodos um determinado pixel é classificado como pertencente a uma única classe. No entanto, um pixel geralmente é composto por vários tipos de materiais e a inclusão dele em apenas um tipo de classe pode incorrer em erros. Assim, torna-se necessário o emprego de um procedimento que detecte a presença dos diferentes materiais presentes nos pixels, mesmo com baixa porcentagem, e estabeleça a sua quantidade. Nessa nova abordagem, a classificação de um pixel pode apresentar duas ou mais classes diferentes de forma a representar os constituintes da mistura espectral. De uma forma sintética, os procedimentos e os algoritmos desenvolvidos para análise de mistura espectral buscam responder três perguntas básicas: (a) Quais são os elementos que compõem a imagem? (b) Onde está o elemento procurado? (c) Quanto do elemento existe em cada pixel? (Carvalho Júnior et al. 2003a, b e c).

Os algoritmos usados para detectar os membros finais implicitamente ou explicitamente assumem a geometria do conjunto convexo aplicado no modelo linear de mistura (Batenson et al., 2000; Batenson & Curtis, 1996; Berman et al., 2004; Winter, 1999; Tompkins et al., 1997). Provavelmente, o modelo mais utilizado seja o algoritmo desenvolvido por Boardman & Kruse (1994) devido, em parte, ao fato de estar incorporado no pacote de processamento hiperespectral Environment for Visualizing Images – ENVI (ENVI, 2000) amplamente utilizado no processamento de imagens hiperespectrais (Carvalho Júnior et al., 1999; Kruse, 1996; 1999;

Kruse & Boardman, 1999; Kruse et al., 1996; Richardson, 1996; Richardson et al., 1994) como de imagens multiespectrais com bons resultados (Carvalho et al., 2002; Bloise et al., 2003).

A metodologia de Boardman & Kruse (1994) para a detecção dos membros finais apresenta três etapas: (a) redução da dimensão espectral (Minimum Noise Fraction - MNF) (Green et al. 1988, Carvalho Júnior et al., 2002), (b) redução da dimensão espacial (Purity Pixel Index - PPI), e (c) identificação manual (utilizando um visualizador n-dimensional). Essa metodologia visa eliminar os fatores redundantes, tanto espaciais como espectrais, que nada alteram o conjunto de soluções viáveis para os membros finais.

Os classificadores espectrais baseiam-se na comparação do espectro da imagem (EI) com um espectro de referência (ER), proveniente de bibliotecas espectrais ou de membros finais das imagens. A comparação é realizada por intermédio de um critério de similaridade. Desta forma, a identificação do material procurado é feita segundo o ajuste obtido entre as duas curvas espectrais. Quanto melhor for o ajuste, maior será a probabilidade da existência do material de referência no pixel da imagem. Basicamente procura-se identificar a existência ou não do espectro de referência. Esse fato torna-se importante, pois em muitos casos ocorrem equívocos com a utilização de métodos de quantificação com o objetivo de identificar ou vice-versa. Os procedimentos de quantificação apresentam resultados coerentes quando o material procurado apresenta um predomínio no pixel, em caso contrário, quando as proporções do material de interesse são baixas esses métodos assinalam a inexistência do material decorrendo em erro. Neste artigo, é dada ênfase nos métodos: Spectral Angle Mapper (SAM) e Spectral Correlation Mapper (SCM). A formulação matemática do SAM (Kruse et al., 1993) é oriunda da **equação 1** sendo expressa na forma de ângulo em vez de porcentagem.

$$SAM = \alpha = \cos^{-1} \frac{\sum_{i=1}^{i=nb} ER_i EI_i}{\sqrt{\sum_{i=1}^{i=nb} (EI_i)^2 \sum_{i=1}^{i=nb} (ER_i)^2}} \quad (1)$$

Desta forma, temos que o valor do SAM é expresso em radianos, sendo que, quanto menor o ângulo α , maior é a similaridade entre as curvas. O ângulo α , determinado pela função arco – coseno, apresenta uma variação entre 0° até 90° . O método SAM herda os problemas do coeficiente de correlação não normalizado pela média, ou seja, a incapacidade de detectar os falsos positivos. O método SCM foi proposto por Carvalho & Menezes (2000) sendo oriundo do coeficiente de correlação de Pearson. Apresenta como vantagem em relação aos métodos anteriores a capacidade de detecção da correlação negativa e melhor ajuste na presença de mistura espectral. Esse método por se fundamentar na correlação de Pearson, variando de -1 até 1 , diferentemente do $\cos(SAM)$, que varia de 0 até 1 . O SCM também pode ser expresso na forma de ângulo. Para tanto, os valores relativos à correlação negativa adquirem valores nulos e é aplicada a função arco-coseno sobre os coeficientes de correlação de Pearson.

$$SCM = \frac{\sum_{i=1}^{i=nb} (EI_i - \overline{EI})(ER_i - \overline{ER})}{\sqrt{\sum_{i=1}^{i=nb} (EI_i - \overline{EI})^2 \sum_{i=1}^{i=nb} (ER_i - \overline{ER})^2}} \quad (2)$$

Contudo, esses métodos de classificação espectral não adotam o conceito de mistura de forma integral. A correlação com o espectro da imagem não deve considerar somente os membros finais, porém também, os espectros provenientes de sua mistura. Essa limitação causa erros principalmente quando um elemento ocorre em baixa quantidade no *pixel*. Desta forma, o melhor modelo de mistura deve ser identificado utilizando como referência na classificação espectral.

A abundância relativa de um dado material pode ser determinada estabelecendo uma relação de proporcionalidade entre uma característica da forma do espectro e a sua quantidade. Pode-se distinguir dois tipos de mistura com comportamentos distintos no cálculo de abundância: a mistura macroscópica e a mistura microscópica ou mistura íntima. A mistura macroscópica ocorre em superfícies com partículas grandes e rugosas onde relativamente pouca luz é espalhada entre as partículas (Johnson et al., 1983). Este fato, torna a reflectância espectral de uma determinada superfície uma combinação linear das áreas de contribuição dos seus componentes, sendo o modelo denominado de tabuleiro de xadrez (checkerboard). Neste âmbito, o emprego da regressão linear é amplamente utilizado. A abundância relativa do material procurado pode ser obtida a partir dos coeficientes da regressão linear múltipla.

O método de Análise Linear de Mistura (ALM) baseia-se no emprego da regressão linear múltipla para quantificar a proporção dos minerais presentes na imagem (Smith & Adams, 1985). Os erros, que resultam em frações irrealis são provenientes do pressuposto que apenas um grupo de membros finais possam descrever todos os pixels da cena analisada (Roberts et al., 1997). Assim, o êxito da ALM possui uma forte dependência da quantidade e qualidade dos membros finais utilizados, pois qualquer tipo de interferência por parte de um membro final afeta todos os demais pixels. Pode-se descrever três tipos de erros na ALM considerando os membros finais utilizados: (a) excessiva simplificação ou retirada dos membros finais; (b) inserção de muitos membros para descrever uma cena; e (c) presença de espectros que não podem ser modelados a partir dos membros finais (Sabol et al., 1992).

Devido a esses erros descritos, inicialmente, buscaram-se soluções matemáticas para restringir as frações das componentes de mistura para valores entre 0 e 1. Os trabalhos de Boardman & Goetz, (1991) e Shimabukuro & Smith, (1991) estabelecem métodos para o cálculo das abundâncias relativas, de forma serem não negativas e com o seu respectivo somatório menor ou igual a 1. Shimabukuro & Smith (1991) avaliam dois métodos *Constrained Least Square* (CLS) e o *Weighted Least Square* (WLS). Boardman & Goetz (1991) utilizam a formulação matemática desenvolvida por Lawson & Handson (1974) que considera o efeito de sombra e iluminação como um fator de ganho desconhecido contrapondo-se a sua utilização como um membro final da mistura como descrito por Gillespie et al. (1990).

Uma outra abordagem para o emprego da regressão linear foi o modelo denominado MESMA (Multiple Endmember Spectral Mixture Analysis) que estabelece para cada pixel diferentes conjuntos de membros finais (Roberts et al., 1998a). Neste método são simuladas todas as combinações possíveis dos espectros de referência por meio de regressões múltiplas. Cada combinação é denominada de modelo. O melhor modelo existente para o pixel é determinado pelo menor erro médio quadrático (Smith et al., 1992; Sabol et al., 1992b; Roberts et al., 1992). No entanto um grande empecilho para a utilização desse método é o tempo computacional (Okin et al., 1999b).

O objetivo do presente trabalho é desenvolver um programa em linguagem C de um novo método de análise de mistura espectral que determina o melhor modelo e otimiza o processo de regressão linear. O tempo de processamento do método MESMA é relacionado com a

importância de membros finais que descreve a cena e conseqüentemente com o número de modelos de mistura. No método MESMA, a definição do melhor modelo para o pixel é obtida considerando todos os possíveis modelos o que proporciona o aumento do tempo de processamento, o que é minimizado no método proposto.

2. Metodologia

A metodologia proposta determina o melhor modelo usando o método “stepwise forward multiple regression analysis” e o classificador espectral SCM. O procedimento utilizado para cada pixel apresenta os seguintes passos:

- Calcula uma regressão simples entre o espectro do membro final e o espectro do pixel;
- Calcula o SCM e elimina a variáveis ausentes no pixels (presença de valores negativos de SCM);
- Determina a melhor variável (valor mais alto de SCM);
- Calculam os modelos com adição de uma variável, a partir da regressão múltipla entre a melhor variável e as outras remanescentes variáveis, e
- No caso do melhor modelo obter um valor de SCM com significativa contribuição retorna para o passo “d” se não para.

A **Figura 1** apresenta um fluxograma do processamento completo do método (**Figura 1**).

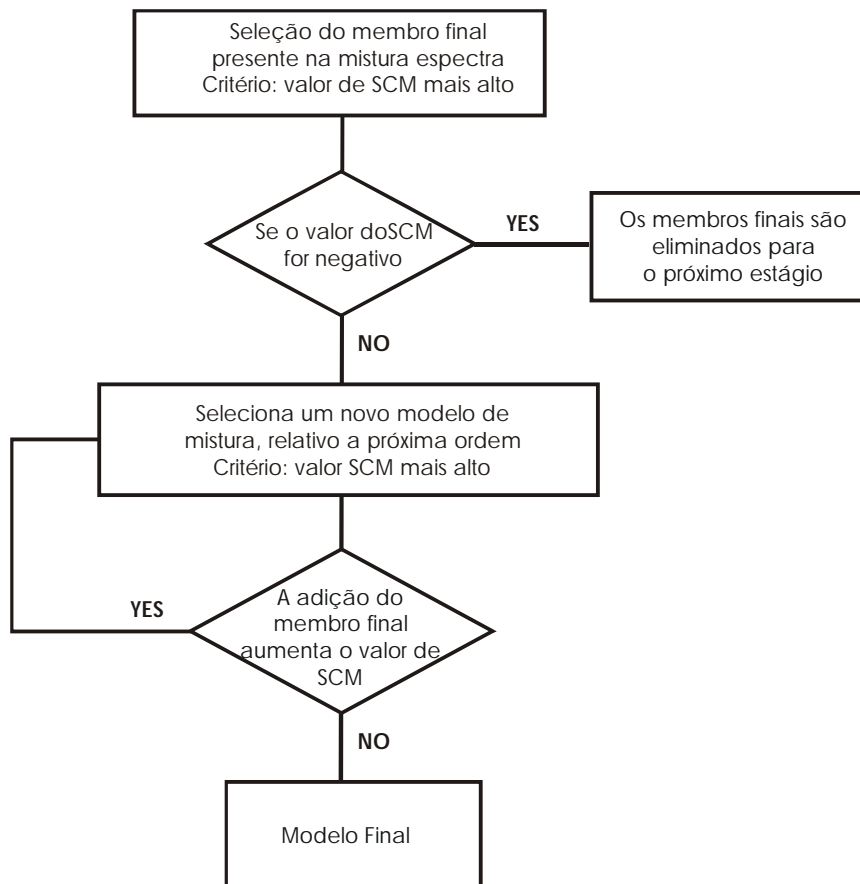


Figura 1 – Fluxograma do algoritmo SMCM.

No algoritmo do MESMA, a definição do melhor modelo para um pixel é obtido usando todas as possibilidades de combinações dos membros finais possíveis. Esse procedimento examina todos os modelos simples, com duas variáveis, três variáveis e todos os possíveis modelos. Assim, uma imagem com quatro membros finais possuem 15 modelos de mistura, enquanto que o número máximo de modelos no novo procedimento testado é de dez. (**Figura 2**).

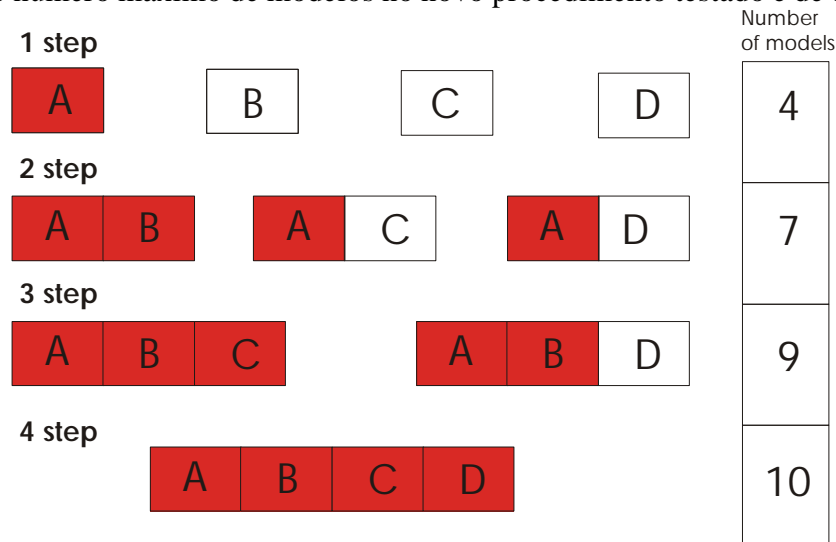


Figura 2 – Número máximo de modelos considerando quatro membros finais.

Esse algoritmo foi implementado no programa livre de processamento digital de imagem “ABÍLIO” utilizando a linguagem C++. Esse procedimento permite determinar o melhor conjunto de membros finais para cada pixel como também possibilita a otimização da identificação do sistema de mistura.

3. Resultados

Como resultado é gerado um módulo específico para o tratamento de mistura espectral que contém o método SMCM. O módulo utiliza uma interface que permite selecionar os membros finais e uma rotina que permite rodar o programa de mistura espectral.

O módulo desenvolvido permite selecionar os espectros referentes aos membros finais diretamente a partir das imagens ou das componentes principais. Para esse propósito foi desenvolvida uma interface, extremamente amigável, que permite visualizar automaticamente os espectros do pixel. Opcionalmente pode-se utilizar as imagens oriundas da principal componente, que permite uma melhor identificação dos espectros para a classificação. Com a seleção dos espectros de referência realiza-se uma gravação em um arquivo específico relativo as amostras selecionadas. No módulo de mistura espectral tem-se a opção de utilizar o método de análise linear de mistura, análise linear de mistura parcial e o método SCM que realiza o algoritmo proposto.

4. Conclusão

O método SMCM permite um alto desempenho na diferenciação das misturas espectrais presentes no pixel. Diferentemente, do método ALM o método proposto permite identificar para cada pixel o melhor conjunto de espectros, definindo mais precisamente os elementos e a sua

proporção. O programa desenvolvido em turbo C++ e implantado no programa ABÍLIO é de fácil uso e possibilita uma eficiente otimização dos processos na busca dos espectros que constituem o pixel.

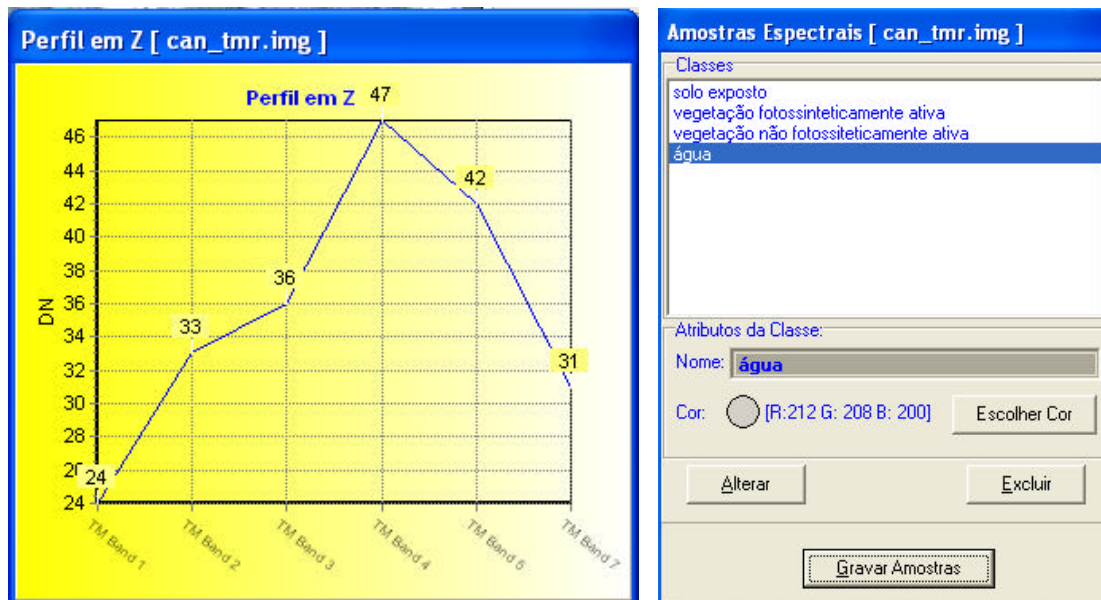


Figura 3 – (a) perfil em Z do programa e (b) módulo para seleção das amostras espectrais.

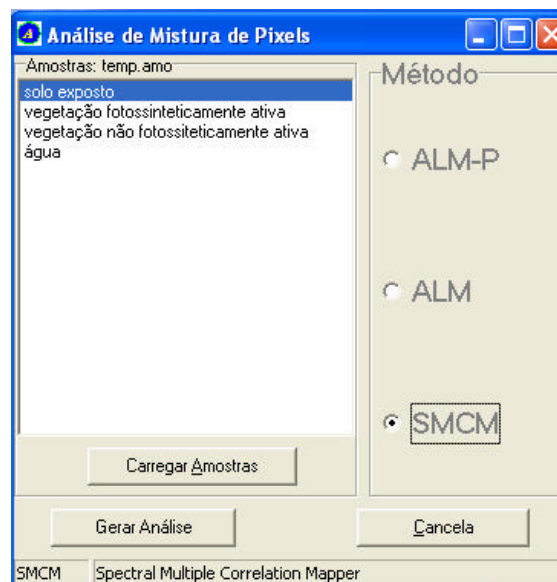


Figura 4 – Módulo de Mistura Espectral do programa ABÍLIO

Referências

Bateson, C.A. Curtiss, B. A method for manual endmember selection and spectral unmixing. **Remote Sensing of Environment**, 55: 229–243, 1996.

- Bateson, C.A., Asner, G. P., Wessman, C.A., Endmember bundles: a new approach to incorporating endmember variability into spectral mixture analysis. **IEEE Transactions on Geoscience and Remote Sensing**, 38(2): 1083-1094, 2000.
- Berman, M. Kiiveri, H. Ryan, L. Ernst, A. Dunne, R. Huntington, J.F. ICE: A statistical approach to identifying endmembers in hyperspectral images. **IEEE Transactions on Geoscience and Remote Sensing**, 42(10): 1-11, 2004.
- Bloise, P. L. C.; Guimarães, R. F.; Martins, E. S.; Carvalho, A. P. F.; Carvalho Junior, O. A. 2003. Análise de mistura espectral de imagens ASTER no Campo de Instrução Militar de Formosa. In: Simpósio Brasileiro de Sensoriamento Remoto, 11, Belo Horizonte (MG). **Anais XI SBSR**. São José dos Campos: INPE, p. 2311-2318.
- Boardman, J.W., Goetz, A.F.H. Sedimentary facies analysis using AVIRIS data: a geophysical inverse problem. AVIRIS Workshop, 3, Pasadena, CA. **Proceedings**, JPL-Publ. 91-28, 4-13. 1991.
- Boardman, J.W. Kruse, F.A. Automated spectral analysis: A geologic example using AVIRIS data, north Grapevine Mountains, Nevada. In: **Proceedings** of the 10th ERIM - Thematic Conference on Geologic Remote Sensing, Environmental Research Institute of Michigan, Ann Arbor, MI., vol. 1, p. 407-418, 1994.
- Carvalho Júnior, O. A.; Carvalho, A. P. F.; Guimarães, R. F., Meneses, P. R. Mistura espectral: (II) classificadores espectrais para identificação. **Espaço & Geografia**, v. 6. no. 1. 175-197. 2003b.
- Carvalho Júnior, O. A.; Carvalho, A. P. F.; Guimarães, R. F., Meneses, P. R. Mistura espectral: (III) quantificação espectral. **Espaço & Geografia**, v. 6. no. 1. 197-223. 2003c.
- Carvalho Junior, O. A.; Carvalho, A. P. F.; Guimarães, R. F.; Meneses, P. R.; Shimabukuro, Y.. Mistura espectral: (I) detecção dos membros finais utilizando a geometria do Simplex. **Espaço Geografia**, 6(1): 147-173. 2003a
- Carvalho Junior, O. A.; Carvalho, A. P. F., Meneses, P. R., Guimarães, R. F. Classificação e eliminação dos ruídos em imagens hiperespectrais pela análise seqüencial da transformação por fração de ruído mínima. **Revista Brasileira de Geofísica**. 20(1): 31-41. 2002.
- Carvalho Júnior, O.A., Menezes, P.R. Spectral Correlation Mapper (SCM): An Improving Spectral Angle Mapper. In: **Summaries** of the Ninth JPL Airborne Earth Science Workshop, vol. 1, AVIRIS Workshop, R. Green, Ed., Pasadena, CA, 2000, JPL Publ. 00-18, pp. 65-74.
- Carvalho Junior, O.A.; Baptista, G.M.M.; Madeira Neto, J.S.; Martins, E.S.; Meneses, P.R. Mineralogical Differentiation In: Weathering Profiles Of Lateritic Ni Using Aviris Data, In Niquelandia - Go, Brazil. In: AVIRIS AIRBORNE EARTH SCIENCE WORKSHOP, 1999, Pasadena, California. **Summaries** of the Eighth AVIRIS Airborne Earth Science Workshop. Pasadena, California: JPL - NASA, 1999. v. 1, p. 3-11.
- Carvalho, A. P. F.; Carvalho Junior, O. A.; Guimarães, R. F.; Martins, E. S.; Bustamante, M. M. C. Utilização do classificador Spectral Correlation Mapper em imagens TM-Landsat. **Espaço e Geografia**, 5:(1): 219-232. 2002.
- ENVI. **The Environment for Visualizing Images Users Guide**. 3.4 ed., Research Systems Inc., Boulder, CO, 2000, p. 930.
- Gillespie, A. R., Smith, M. O., Adams, J. B., Willis, S. C., Fischer, A. F., Sabol, D. E. Interpretation of residual images: spectral mixture analysis of AVIRIS images, Owens Valley, California. In: Annual JPL Airborne Visible/Infrared Imaging Spectrometer (AVIRIS) Workshop, 2, Pasadena, CA, **Proceedings**, JPL Publ. 90-54, 243-270. 1990.
- Green, A.A., Berman, M., Switzer, P., Craig, M.D. A transformation for ordering multispectral data in terms of images quality with implications for noise removal. **IEEE Transactions on Geoscience and Remote Sensing**, v.26, n.1, p.65-74, 1988.
- Johnson, P.E., Smith, M.O., Taylor-George, S., Adams, J.B. A semi-empirical method for analysis of the reflectance spectra of binary mineral mixtures. **J. Geophys. Res.**, 88, 3557-3561. 1983.
- Kruse, F. A. Geologic mapping using combined optical remote sensing and SIR-C/X-SAR data. In: Thematic Conference and Workshops on Applied Geologic Remote Sensing, 11, Las Vegas, Nevada. **Proceedings**, v. 2, p. 142-150. 1996.

- Kruse, F. A. Mapping hot spring deposits with AVIRIS at Steamboat Springs, Nevada. In: Annual JPL Airborne Earth Science Workshop, 8, Pasadena, CA. **Summaries**, JPL Publication 99-17, p. 239-245. 1999.
- Kruse, F. A.; Huntington, J. H.; Green, R. O. Results from the 1995 AVIRIS geology group shoot. In: **Proceedings** 2nd International Airborne Remote Sensing Conference and Exhibition, v.1, p. 211-220. 1996.
- Kruse, F.A. & Boardman, J.W. Fifteen years of hyperspectral data: Northern Grapevine Mountains, Nevada. In: Annual JPL Airborne Earth Science Workshop, 5, Pasadena CA, **Summaries**, JPL Publication 99-17, p. 247-258. 1999.
- Kruse, F.A., Lefkoff, A.B., Boardman, J.W., Heidedbrecht; K.B., Shapiro, A.T., Barloon, P.J., Goetz, A.F.H. The Spectral Image Processing System (SIPS) – Interactive Visualization and Analysis of Imaging Spectrometer Data. **Remote Sensing of Environment** 44:145-163. 1993.
- Okin, G. S.; Siegel, H.; Collier, J.; Miller, G. D., Okin, W. J.; Roberts, D. A., Murray B., Curkendall, D. W.; Painter, T. H.. The supercomputing visualization workbench for analysis and classification of imaging spectrometer data. In: JPL Airborne Earth Science Workshop, 8, Pasadena, CA. **Proceedings**, JPL-Publ. 99-17, p.317-322. 1999b.
- Richardson, L. L. Remote sensing of algal bloom dynamics. **BioScience**, 46(7): 492-501. 1996.
- Richardson, L. L., Buisson, D., Lui, C. J., Ambrosia, V. The detection of algal photosynthetic accessory pigments using Airborne Visible-Infrared imaging Spectrometer (AVIRIS) Spectral Data: Marine. **Tecnology Society Journal**, 28: 10-21. 1994.
- Roberts, D. A., Smith, M. O., Sabol, D. E., Adams, J. B., Ustin, S. Mapping the Spectral variability in photosynthetic and non-photosynthetic vegetation, soils and shade using AVIRIS. In: Annual JPL Airborne Geoscience Workshop, 3, Pasadena, CA. **Proceedings**, JPL Publ. 92-14, p.38-40. 1992.
- Roberts, D. A., Green, R. O., Adams, J. B. Temporal and spatial patterns in vegetation and atmospheric properties from AVIRIS. **Remote Sensing of Environment**. 62:223-240. 1997
- Roberts, D. A.; Gardner, M.; Church R., Ustin, S. Scheer, G., Green, R.O. Mapping Chaparral in the Santa Monica Mountains using multiple endmember spectral mixture models. **Remote Sensing of Environment**. 65:267-279. 1998.
- Sabol, D. E. Jr., Adams J. B. & Smith M.O. Quantitative Subpixel Spectral of Targets in Multispectral Images. **Journal of Geophysical Research**, 97(E2): 2659-2672. 1992a
- Sabol, D. E. Jr., Roberts, D. A., Smith, M. O., Adams, J. B. Temporal variation in spectral detection thresholds of substrate and vegetation in AVIRIS images, In Annual JPL Airborne Geoscience Workshop, 3, Pasadena, CA. **Proceedings**, JPL Publ. 92-14, p.132-134. 1992b
- Sabol Jr., D.E. Adams, J.B Smith, M.O. Quantitative subpixel spectral of targets in multiespectral images. **Journal of Geophysical Research**, 97: 2659-2672, 1992.
- Shimabukuro, Y. E., Smith, J. A. The least-squares mixing models to generate fraction images derived from remote sensing multispectral data. **IEEE Transactions on Geoscience and Remote Sensing**. 1:16-20. 1991.
- Smith, M. O., Adams, J. B., Ustin, S. L., Roberts, D. A. Using endmembers in AVIRIS images to estimate changes in vegetative biomass. In: Annual JPL Airborne Geoscience Workshop, 4, Pasadena, CA. **Proceedings**, JPL Publ. 92-14, p.69-71. 1992.
- Smith, M.O. Adams J.B. Interpretation of AIS images of Cuprite, Nevada, using constrains of spectral mixtures. In: **Proceedings** of the Airborne Imaging Spectrometer Data Analysis Workshop, Pasadena, CA, JPL Publ. 85-41, pp.62-68. 1985.
- Tompkins, S. Mustard, J.F. Pieters, C.M. Forsyth, D.W. Optimization of endmembers mixture analysis for spectral, **Remote Sensing of Environment**, 59: 472-489, 1997.
- Winter, M. Fast autonomous spectral endmember determination in hyperspectral data. In: **Proceedings** 13th Int. Conf. Applied Geologic Remote Sensing, Vancouver, BC, Canada, vol. 2, 1999, pp. 337–344.