

MISTURA ESPECTRAL: (II) CLASSIFICADORES ESPECTRAIS PARA IDENTIFICAÇÃO

Osmar Abílio de Carvalho Júnior¹, Ana Paula Ferreira de Carvalho²,
Renato Fontes Guimarães³, Paulo Roberto Meneses⁴,
Yosio Edemir Shimabukuro¹

¹INPE - Instituto Nacional de Pesquisas Espaciais
12201-970 - São José dos Campos - SP, Brasil.
[osmar,yosio}@ltid.inpe.br](mailto:{osmar,yosio}@ltid.inpe.br)

²UnB - Universidade de Brasília - Departamento de Ecologia
Campus Universitário Darcy Ribeiro, Asa Norte - 70910-900, Brasília, DF, Brasil
anapaula@unb.br

³UnB - Universidade de Brasília - Departamento de Geografia
Campus Universitário Darcy Ribeiro, Asa Norte, 70910-900, Brasília, DF, Brasil.
renatofg@unb.br

⁴UnB - Universidade de Brasília - Departamento de Geologia
Campus Universitário Darcy Ribeiro, Asa Norte, 70910-900, Brasília, DF, Brasil.
pmeneses@unb.br

Resumo – O presente trabalho possui como objetivo apresentar uma revisão sobre os métodos desenvolvidos para classificação espectral. Os classificadores espectrais que visam à identificação realizam uma comparação do espectro da imagem (EI) com um espectro de referência (ER), proveniente de bibliotecas espectrais ou de membros finais das imagens. As principais diferenças entre os métodos são basicamente duas: (a) opção do emprego da remoção do contínuo e (b) o critério de similaridade a partir do ajuste linear. A remoção do contínuo tem como propósito enfatizar as feições de absorção a partir da retirada do *background* utilizando uma função matemática, geralmente, o *spline* cúbico. Os critérios de similaridade são oriundos da regressão linear e do ajuste por mínimos quadrados sendo assim utilizadas formulações do coeficiente de correlação

e do erro padrão. Serão descritos os algoritmos dos principais métodos existentes: Spectral Angle Mapper (SAM), Spectral Feature Fitting (SFF), Spectral Correlation Mapper (SCM) e o coeficiente de determinação utilizado pelo Tricorder e Tetracorder.

Palavras – Chave – mistura espectral, classificação espectral, sensoriamento remoto.

Abstract – This present work has as objective to present a review about the methods developed for spectral classification. The spectral classifiers that focus in the identification perform a comparison of spectrum (EI) of the image with a reference spectrum (ER), obtained from the spectral library or the image endmembers. The main differences between these methods are basically two: (a) the option to employ continuum removal, and (b) the similarity criterion based on linear fitting. Continuum removal has as purpose to emphasize the absorption features from the background removal utilizing a mathematical function, generally, the cubic spline. The similarity criteria are originated from linear regression and by minimum squares fitting so utilizing formulations of the correlation coefficient and the standard error. It will be described the algorithms of the main existing methods: Spectral Angle Mapper (SAM), Spectral Feature Fitting (SFF), Spectral Correlation Mapper (SCM), and coefficient of determination utilized by Tricorder and Tetracorder.

Keywords – spectral mixture, spectral classification, remote sensing.

INTRODUÇÃO

Os classificadores espectrais para identificação 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.

O objetivo desse tipo de classificação é responder aonde existe o espectro procurado, sem importar com a sua quantidade no *pixel*. 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.

Um dos primeiros métodos desenvolvidos com esse objetivo foi o método *Binary Encoding* (Mazer *et al.*, 1988). Os demais métodos desenvolvidos foram baseados no ajuste linear entre o espectro da imagem e o espectro de referência. Desta forma, os critérios de similaridade considerados são medidas de correlação e de erro médio da regressão linear. Por causa disso observa-se que o efeito provocado pelo sombreamento que é proveniente de um ganho arbitrário é minimizado ou anulado. Além dos critérios de similaridade outra variação entre os métodos é o emprego de curvas espectrais com ou sem a remoção do contínuo. O emprego dessa técnica permite realçar as feições de absorção que são geralmente as principais características para identificação do material. Portanto, as principais diferenças entre os métodos são basicamente duas: (a) opção do emprego da remoção do contínuo e (b) o critério de similaridade a partir do ajuste linear.

O presente trabalho possui como propósito descrever os principais métodos de classificação espectral para identificação realizando uma comparação e salientando as principais características de cada procedimento.

REMOÇÃO DO CONTÍNUO

A remoção do contínuo tem como propósito enfatizar as feições de absorção a partir da retirada do *background* utilizando uma função matemática, geralmente, o *spline* cúbico (Clark *et al.*, 1990). Essa função gera uma linha contínua que se ajusta ao *background* do espectro proporcionando o realce das feições de absorção (Clark, 1980, 1981b, 1983; Clark & Lucey, 1984; Clark & Roush, 1984; Clark *et al.*, 1990; McCord *et al.*, 1981; Singer, 1981). A obtenção do espectro removido do contínuo (E_c) é obtida pela simples divisão do espectro (E) pela linha contínua (C) (Clark & Roush, 1984; Clark *et al.*, 1990).

$$E_{c_{\lambda}} = \frac{E_{\lambda}}{C_{\lambda}} \quad (1)$$

A **Figura 1** mostra a seqüência dos procedimentos para a remoção do contínuo da feição espectral da caulinita (**Figura 1a**). Inicialmente delinea-se a curva do contínuo sobre o espectro da caulinita (**Figura 1b**). Determinada a reta, efetua-se a divisão entre a curva espectral e o seu respectivo contínuo. Isso proporciona um nivelamento da feição a partir da linha estabelecida, que é rebatida para um valor unitário (**Figura 1c**).

A partir das curvas sem o contínuo realiza-se o processo de classificação pelo método da regressão linear.




Figura 1 – Etapas para a remoção do contínuo de um espectro.

CRITÉRIOS DE SIMILARIDADE POR AJUSTE LINEAR


O procedimento baseia-se em estabelecer o grau de ajuste de uma regressão linear com apenas uma variável independente. Podemos considerar a variável independente (X) sendo o espectro da imagem (EI) e a variável dependente (Y) como o espectro de referência (ER) ou podemos empregar de forma inversa.

O emprego de um ou outro procedimento apresenta diferenças que são posteriormente discutidas. No presente tópico para descrever os fundamentos da regressão linear é adotada a regressão onde $Y = ER$ e $X = EI$ sendo expressa pela seguinte equação:

$$ER = a + bEI \tag{2}$$

Quanto maior a similaridade entre o ER e o EI, maior é a aderência da distribuição dos dados em uma reta. Como exemplificação, a **Figura 2** compara um determinado ER com dois EI (EI1, EI2). Observa-se, nesse caso hipotético, que o EI1 apresenta maior grau similaridade ao ER, do que o EI2.

Os valores do coeficiente angular (b) e o linear (a) da reta gerada são obtidos pelas seguintes equações:



(3)

$$a = \frac{\sum ER_i}{n} - b \frac{\sum EI_i}{n} \quad (4)$$

ou,

$$a = \overline{ER} - b\overline{EI} \quad (5)$$

Desta forma, a reta da regressão que estima o valor de ER (\hat{ER}) a partir de EI torna-se:

$$\hat{ER}_i = a + bEI_i \quad (6)$$

Todo o valor estimado \hat{ER} ocorre dentro de um certo intervalo de confiança. Para definir esse intervalo é necessário descrever os três termos que definem a variação da variável dependente.

- A soma total dos quadrados (SQt).

A SQt representa a variância do ER. A sua formulação é descrita pelo desvio dos pontos de ER em relação à sua média (\overline{ER}):

$$SQt = \sum (ER_i - \overline{ER})^2 \quad (7)$$

- A soma dos quadrados da regressão (SQr)

A SQr representa a variância do \hat{ER} , ou seja, o desvio dos pontos de \hat{ER} em relação à sua média. Como a média do \hat{ER} é igual a do ER, temos que:

$$SQr = \sum (\hat{ER}_i - \overline{ER})^2 \quad (8)$$

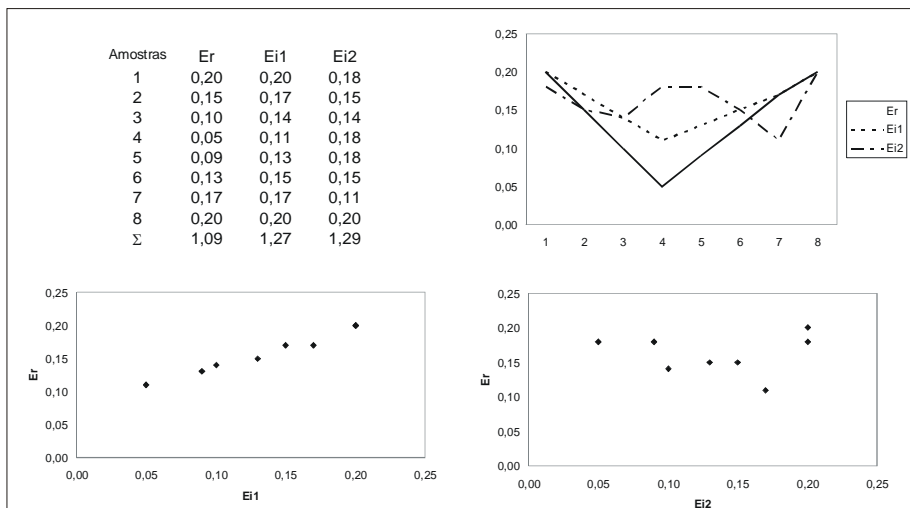


Figura 2. Relação entre um espectro de referência (ER) e dois espectros de uma imagem (EI1 e EI2): (a) tabela dos dados, (b) curvas relativas aos espectros, (c) diagrama de dispersão entre ER e EI1, e (d) diagrama de dispersão entre ER e EI2.

Para exemplificar o comportamento do SQR a **Tabela 1** apresenta os valores de \hat{ER} para os dados presentes na **Figura 1**. O $\Sigma\hat{ER}$ é igual ao ΣER e como consequência suas médias (0,13625) também.

Quanto melhor for o ajuste da regressão linear, maior é a variância de \hat{ER} e maior é o valor obtido para o SQR. A **Figura 3** ilustra as retas de regressão para os dados $\hat{ER}1$ (variância próxima do ER) e $\hat{ER}2$ (praticamente nula).

O valor máximo que o SQR pode adquirir é igual ao SQt. Com base nessa constatação estipula-se um coeficiente de confiança para a regressão denominado de coeficiente de determinação:

$$R^2 = \frac{SQr}{SQt} \quad (9)$$

Observa-se que quando existe um perfeito ajuste dos dados segundo uma regressão linear, o SQr se iguala ao SQt resultando em um R^2 igual a 1. A raiz quadrada desse coeficiente é conhecida como sendo o coeficiente de correlação R.

$$R = \sqrt{\frac{SQr}{SQt}} \quad (10)$$

O R varia de 0 a 1, podendo ser expresso em porcentagem. No entanto, o coeficiente de correlação R não considera a correlação negativa. Como todos os termos das **equações 9 e 10** estão ao quadrado, a correlação negativa acaba sendo convertida para o campo da correlação positiva.

Tabela 1 - Análise dos dados obtidos com a regressão.

Amostras	\hat{E}_{r_1}	\hat{E}_{r_2}	$(\hat{E}_{r_1} - E_r)^2$	$(\hat{E}_{r_2} - E_r)^2$
1	20.45283	13.66879	46.61927	0.001918
2	15.48714	13.59873	3.467549	0.00069
3	10.52144	13.57537	9.63208	0.002463
4	5.555746	13.66879	65.11286	0.001918
5	8.866209	13.66879	22.64609	0.001918
6	12.17667	13.59873	2.097653	0.00069
7	15.48714	13.50531	3.467549	0.014326
8	20.45283	13.7155	46.61927	0.00819
Σ	109	109	199.6623	0.032113

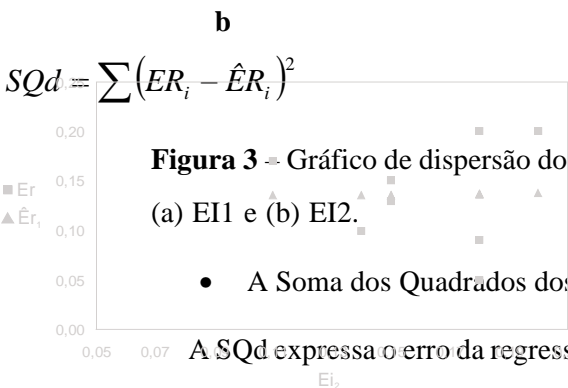



Figura 3 – Gráfico de dispersão dos dados referentes a $\hat{E}R$ e ER com relação: (a) EI1 e (b) EI2.

- A Soma dos Quadrados dos desvios (SQd)

A SQd expressa o erro da regressão sendo obtida pela seguinte formulação:

$$SQd = SQt - SQr \tag{11}$$

Que também pode ser apresentada como:

$$\tag{12}$$

O SQd é denominado de Erro Médio Quadrático. Quanto menor for o valor do SQr, maior é o ajuste da regressão e maior a probabilidade da existência da feição procurada. A Raiz do Erro Médio Quadrático é utilizada para retornar a

mesma unidade de medida dos dados, sendo também conhecida como erro padrão da estimativa:

$$Erro = \sqrt{\sum (\hat{E}R_i - ER_i)^2} \quad (13)$$

O erro é um importante parâmetro para definir o grau de similaridade entre as curvas.

CLASSIFICADORES ESPECTRAIS QUE UTILIZAM COEFICIENTES DE CORRELAÇÃO

Além do coeficiente de determinação R^2 (**Eq. 9**) e o seu respectivo coeficiente de correlação R (**Eq. 10**) existe também um coeficiente de correlação (CC) simplificado que apresenta a seguinte formulação:

$$CC = \frac{\sum X_i Y_i}{\sqrt{\sum (X_i)^2 \sum (Y_i)^2}} \quad (12)$$

No entanto, essa formulação também é incapaz de detectar correlações negativas e apresenta algumas variações em relação ao coeficiente R . Um aprimoramento dessa formulação é o coeficiente de correlação de Pearson (CCP) que utiliza os desvios relativos à média.

$$CCP = \frac{\sum (X_i - \bar{X}_i)(Y_i - \bar{Y}_i)}{\sqrt{\sum (X_i - \bar{X}_i)^2 \sum (Y_i - \bar{Y}_i)^2}} \quad (13)$$

Uma grande vantagem dessa formulação é que apresenta uma mesma eficiência do coeficiente R e ainda possui a capacidade de detectar correlações negativas.

Os principais classificadores espectrais de identificação são propostos a partir dessas três medidas de correlação (coeficiente de determinação, coeficiente de correlação e coeficiente de correlação de Pearson).

CRITÉRIO DE SIMILARIDADE DO MÉTODO TRICORDER.

O Tricorder proposto por Clark & Swayze (1995), utiliza como critério de similaridade uma simplificação do coeficiente de determinação (R^2). Quando o contínuo é removido pode-se adotar uma simplificação do procedimento de regressão linear baseada em uma interessante relação matemática entre os coeficientes da regressão linear que é expressa como:

$$a = 1 - b \quad (14)$$

Desta forma, pode-se descrever esses coeficientes pelo emprego de um único fator k (Clark *et al.*, 1990), sendo:

$$a = \frac{k}{1.0 + k} \quad (15)$$

$$b = \frac{1.0}{1.0 + k} \quad (16)$$

Portanto o espectro removido do contínuo previsto pelo método de regressão linear ($\hat{E}RC$) expressa uma relação matemática onde o ajuste das feições de absorção é obtido pela simples operação de uma constante (k) ao espectro removido do contínuo da imagem:

$$\hat{E}RC_i = \frac{EIC_i + k}{1.0 + k} \quad (17)$$

A relação descrita não alterada considerando tanto $Y=ERc$ e $X=EIc$ ou o inverso $Y=EIc$ e $X=ERc$. Tanto o coeficiente angular quanto o coeficiente de correlação apresentam-se inalterados por essa simplificação podendo-se utilizar qualquer uma das abordagens para a obtenção dos resultados do Tricorder.

A metodologia do Tricorder vem sendo testada e aprimorada, principalmente pelos pesquisadores da USGS (United States Geological Survey), para o mapeamento mineralógico e geológico em várias localidades como em Canon City, Colorado (Clark *et al.*, 1991), Cuprite, Nevada (Clark *et al.*, 1991; Swayze *et al.*, 1992, 1998a), Canyonlands, Utah (Clark *et al.*, 1992a), Death Valley (Crowley & Clark, 1992), Summitville, sudoeste do Colorado (Duncan *et al.*, 1998; Dalton *et al.*, 1998) e nas fontes termais do Yellowstone National Park (Livo *et al.*, 1999). Também, muitos dos trabalhos apresentam como enfoque a detecção de fontes de contaminação em regiões de minas abandonadas que coloca em risco o meio ambiente (King *et al.*, 1995; Clark *et al.*, 1996; Clark *et al.*, 1998; Swayze *et al.*, 1996, 1998b; Livo *et al.*, 1998). Com relação à vegetação, trabalhos têm sido desenvolvidos no Yellowstone National Park (Kokaly *et al.*, 1998).

É importante enfatizar que o Tricorder não utiliza o critério de similaridade R^2 somente para a classificação. Esse método apresenta outros procedimentos complementares para a detecção do elemento procurado como a posição da feição espectral, as feições espectrais de emissão, a profundidade das bandas entre outros (Clark *et al.*, 1992b). O Tricorder com o acréscimo de novas funções foi ampliado em uma nova versão denominada de Tetracorder (Clark *et al.*, 2003).

MÉTODO SAM

A formulação matemática do SAM (Kruse *et al.*, 1993a) é oriunda da **equação 12** sendo expressa na forma de ângulo em vez de porcentagem.

$$SAM = \alpha = \cos^{-1} \frac{\sum ER_i * EI_i}{\sqrt{\sum (EI_i)^2 \sum (ER_i)^2}} \quad (18)$$

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 (Carvalho & Meneses, 2000).

O SAM é um dos métodos de classificação espectral mais utilizado. Esse método foi utilizado em muitas pesquisas como: estudos de região semi-árida (Conel *et al.*, 1992; Yuhás *et al.*, 1992); mapeamento geológico (Baugh *et al.*, 1998; Bogliolo *et al.*, 1998; McCubbin *et al.*, 1998; Rianza *et al.*, 1998; Rowan & Mars, 2003), estudos da superfície lunar (Pinori & Bellucci, 2001), entre outros.

MÉTODO SCM

Esse método 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 $\cos(\text{SAM})$, 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.

$$SCM = \frac{\sum (EI_i - \overline{EI}_i)(ER_i - \overline{ER}_i)}{\sqrt{\sum (EI_i - \overline{EI}_i)^2 \sum (ER_i - \overline{ER}_i)^2}} \quad (19)$$

CLASSIFICADORES ESPECTRAIS QUE UTILIZAM MEDIDAS DE ERRO

A regressão linear entre os espectros pode ser realizada de duas formas considerando o ER como termo dependente ou o EI. Essas variantes da forma de realizar a regressão apresentam particularidades para os valores de erro médio e mantêm-se inalterada para os valores de correlação.

A regressão do tipo $Y=ER$ possui como a variável dependente sempre um dado fixo e gera imagens de erro padrão e de coeficientes de correlação (R) que são descritas por uma função. Como exemplo, a **Figura 4** mostra os gráficos de dispersão dos valores de erro médio considerando $Y=ER$, R e SCM para a detecção do mineral caulinita em uma imagem hiperespectral. Nesse gráfico são representados todos os pixels da imagem tratada que se distribuem conforme uma função parabólica. Observa-se que o emprego do SCM apresenta vantagens em relação aos dois demais métodos por detectar os *pixels* com correlação negativa.




Figura 4 – Gráfico de dispersão entre: (a) Erro Padrão onde $Y=ER$ e R , e (b) Erro Padrão onde $Y=ER$ e SCM para o mineral de caulinita em uma imagem.

Em contraposição a regressão onde $Y=EI$ caracteriza-se por gerar uma imagem de erro que não estabelece uma função com as imagens R ou SCM . A comparação das imagens dos erros considerando $Y=EI$ e $Y=ER$ apresenta uma intensa diferença visual. A **Figura 5** mostra um diagrama de dispersão entre imagens referentes aos dois tipos de erro para a caulinita. Observa-se a existência de valores altos para um tipo de erro e baixo para outro o que constata a inexistência de correlação entre esses dois parâmetros. Desta forma, o emprego do erro do tipo $Y=EI$ apresenta um resultado pior que o erro $Y=ER$ devendo-se ter cuidados especiais no seu uso.

MÉTODO SPECTRAL FEATURE FITTING

Na mesma concepção metodológica do Tricorder/Tetracorder, existe um módulo dentro do ENVI para realizar um procedimento análogo, denominado de Spectral Feature Fitting (SFF). O método SFF consiste em uma simplificação do método Tricorder, considerando os seus principais pontos de tratamento. Os dois métodos

realizam também as seguintes funções: (a) remoção do efeito do background; (b) cálculo da profundidade da banda de absorção, e (c) comparação de espectros sendo que o SFF utiliza o erro do tipo $Y=EI$ e o Tricorder/Tetracorder emprega o coeficiente de determinação (R^2). A comparação dos dois métodos por um diagrama de dispersão evidencia as pronunciadas diferenças entre os dois métodos (**Figura 6**).




Figura 5 – Diagrama de dispersão entre as imagens dos erros do tipo $Y=ER$ e $Y=EI$ para a feição da caulinita.




Figura 6 – Gráfico de dispersão entre as imagens conforme o método Tricorder (R^2) e do SFF para o mineral caulinita.

CONSIDERAÇÕES FINAIS

Os dois principais fatores para a distinção dos classificadores espectrais são o critério de similaridade adotado e a utilização ou não da remoção do contínuo. A **Tabela 2** apresenta uma síntese dos diferentes métodos para a classificação espectral. A apresentação dos métodos conforme esse prisma permite estabelecer uma relação entre as diferentes estratégias adotadas para a classificação espectral. Dentre os critérios de similaridade o que apresenta melhores resultados é a correlação de Pearson, pois possui a vantagem de ser o único procedimento capaz de detectar a correlação negativa. O emprego ou não da remoção do contínuo deve ser avaliado, considerando o espectro a ser procurado. Esse procedimento intensifica as feições de absorção que

Critério de similaridade	Remoção do contínuo	Método
Coeficiente de correlação	RC	Tricorder/Tetracorder
	sem RC	
Coeficiente de correlação	RC	
	sem RC	SAM
Coeficiente de correlação	RC	SAM
	sem RC	
Coeficiente de correlação	RC	
	sem RC	
Coeficiente de correlação	RC	SFF
	sem RC	

Tabela 2. Principais métodos de classificação espectral

REFERÊNCIAS BIBLIOGRÁFICAS

- BAKKER, W. H., SCHMIDT, K. S. (2002). Hyperspectral edge filtering for measuring homogeneity of surface cover types. *ISPRS Journal of Photogrammetry & Remote Sensing*, 56:246–256.
- BAUGH, W. M., KRUSE, F. A., ATKINSON JR., W. W. (1998). Quantitative geochemical mapping of ammonium minerals in the southern cedar mountains, Nevada, using the airborne visible/infrared imaging spectrometer (AVIRIS). *Remote Sens. Environ.* 65:292-308.
- BOGLIOLO, M. P., TEGGI, S., BUONGIORNO, M.F, PUGNAGHI, S. (1998), Retrieving Ground Reflectance from MIVIS Data: A Case Study on Volcano Island (Italy), In: EARSeL Workshop on Imaging Spectroscopy, 1, University of Zurich, Switzerland. *Proceedings*, p. 403-416.
- CARVALHO JÚNIOR, O. A., MENEZES, P. R. (2000). Spectral Correlation Mapper (SCM): an Improving Spectral Angle Mapper. In: Airborne Earth Science Workshop, 7, Pasadena, CA. *Summaries*, JPL Pub. 00-18. pp. 65-74.
- CLARK, R. N. (1980). A large scale interactive one dimensional array processing system. *Publ. Astron. Soc. Pac.*, 92, 221-224.
- CLARK, R. N. (1981). The spectral reflectance of water-mineral mixtures at low temperatures, *J. Geophys. Res.*, 86, 3074-3086.
- CLARK, R. N. (1983). Spectral properties of mixtures of montmorillonite and dark carbon grains: Implications for remote sensing minerals containing chemically and physically adsorbed water. *J. Geophys. Res.*, 88:10635-10644.
- CLARK, R. N., LUCEY, P. G. (1984). Spectral properties of ice-particulate mixture and Implications for Remote Sensing 1. Intimes Mixtures. *J. Geophys. Res.*, 89:6341-6348

- CLARK, R. N., ROUSH, T. L., (1984), Reflectance Spectroscopy: Quantitative analysis techniques for remote sensing applications. *J. Geophys. Res.*, 89, 6329-6340.
- CLARK, R. N., GALLAGHER, A. J., SWAYZE, G. A. (1990). Material absorption band depth mapping of imaging spectrometer data using a complete band shape least-squares fit with library reference spectra. In: Annual JPL Airborne Geoscience Workshop, 2, Pasadena, CA. *Summaries*, JPL-Publ. 90-54, p.176-186.
- CLARK, R. N., SWAYZE, G. A., GALLAGHER, A., GORELICK, N., KRUSE, F. (1991). Mapping with imaging spectrometer data using complete band shape least-squares algorithm simultaneously fit to multiple spectral features from multiple materials. In: Annual JPL Airborne Geoscience Workshop, 3, Pasadena, CA. *Summaries*, JPL Pub-91-28, p.2-3
- CLARK, R. N.; SWAYZE, G. A., GALLAGHER, A. (1992a). Mapping the mineralogy and lithology of Canyonlands, Utah with imaging spectrometer data and multiple spectral feature mapping algorithm. In: Annual JPL Airborne Geoscience Workshop, 4, Pasadena, CA. *Summaries*, JPL Publ. 92-14, p. 11-13.
- CLARK, R. N.; SWAYZE, G. A.; KOCH, C., AGER, C. (1992b). mapping vegetation types with the multiple spectral feature mapping algorithm in both emission and absorption. In: Annual JPL Airborne Geoscience Workshop, 4, Pasadena, CA. *Summaries*, JPL Pub-92-14, p. 60-62.
- CLARK, R. N., SWAYZE, G. A. (1995). Mapping minerals, amorphous materials, environmental materials, vegetation, water, ice and snow, and other materials: the USGS Tricorder algorithm. In: JPL Airborne Earth Science Workshop, 5, Pasadena, CA. *Summaries*, JPL Publ. 95-1, p. 39-40.
- CLARK, R. N., SWAYZE, G. A., ROWAN, L., LIVO, E., WATSON, K. (1996), Mapping Superficial Geology, Vegetation Communities, and Environmental Materials in Our National Parks: USGS Imaging Spectroscopy, Integrated Geology, Ecosystems, and

- Environmental Mapping Project. In: JPL Airborne Earth Science Workshop, 6, Pasadena, CA. *Summaries*, JPL Publ. 96-1, p.39-40.
- CLARK, R. N.; VANCE, S. LIVO, L. K., GREEN, R. O. (1998). Mineral mapping with imaging spectroscopy: the Ray Mine, AZ. JPL Airborne Earth Science Workshop, 7, Pasadena, CA. *Summaries*, JPL Publ. 97-21, p. 67-77.
- CLARK, R. N., SWAYZE, G. A., LIVO, K. E., KOKALY, R. F., SUTLEY, S. J., DALTON, J. B., MCDUGAL, R., GENT, C. A. (2003). Imaging Spectroscopy: Earth and Planetary Remote Sensing with the USGS Tetracorder and Expert Systems, *Journal of Geophysical Research*, In Press, 2003.
- CONEL, J. E., HOOVER, G., NOLIN, A., ALLEY, R., MARGOLIS, J. (1992). Empirical Relationships Among Semi-Arid Landscape Endmembers Using the Spectral Angle Mapper (SAM) Algorithm. In: Annual JPL Airborne Geoscience Workshop, 4, Pasadena, CA. *Summaries*. JPL Publ. 92-14, p. 150-151.
- CROWLEY, J. K., CLARK, R. N. (1992). AVIRIS, Study of Death Valley evaporite deposits using least-squares band-fitting methods. In: Annual JPL Airborne Geoscience Workshop, 4, Pasadena, CA. *Summaries*, JPL Publ. 92-14, p. 29-31.
- DALTON, B., KING, T., BOVIE, D., KOKALY, R. F., CLARK, R. N., SWAYZE, G. A., VANCE, S. (1998). Mapping of acid-generating and acid-buffering minerals in the animas watershed by imaging spectroscopy. In: JPL Airborne Earth Science Workshop, 7, Pasadena, CA. *Summaries*, JPL Publ. 97-21, p.79-79.
- DUCAN, W. S., LEDGER, E. B., WHITEHEAD, V. S. (1998). X-ray diffraction verification of AVIRIS clay mineral identification, Summitville area, South Western Colorado. In: JPL Airborne Earth Science Workshop, 7, Pasadena, CA. *Summaries*, JPL Publ. 97-21, p.85-95.
- KING, T. V. V., CLARK, R. N., AGER, C., SWAYZE, G. A. (1995). Remote mineral mapping using AVIRIS data at Summitville, Colorado, and the adjacent San Juan Mountains. In: JPL Airborne Earth Science Workshop, 5, Pasadena, CA. *Summaries*, JPL Publ. 95-1, p.113-116.

- KOKALY, R. F., CLARK, R. N., LIVO, K. E. (1998). Mapping the Biology and Mineralogy of Yellowstone National Park Using Imaging Spectroscopy. In: JPL Airborne Earth Science Workshop, 7, Pasadena, CA. *Summaries*, JPL Publ. 97-21, p.245-254.
- KRUSE, F. A., LEFKOFF, A. B., BOARDMAN, J. W., HEIEDBRECHT, K. B., SHAPIRO, A. T., BARLOON, P. J., GOETZ, A. F. H. (1993). The Spectral Image Processing System (SIPS) – Interactive Visualization and Analysis of Imaging Spectrometer Data, *Remote Sens. Environ.* 44:145-163.
- LIVO, K. E., CLARK, R. N., KRUSE, F. A., KOKALY, R. F. (1999). Characterization of hydrothermally altered rock and hot spring deposits at Yellowstone National park using AVIRIS data. In: JPL Airborne Earth Science Workshop, 8, Pasadena, CA. *Summaries*, JPL Publ. 99-17, p. 259-266.
- LIVO, K. E., WATSON, K., KNEPPER JR., D. H., HUMMER-MILLER, S. (1998). Environmental study of the Bonanza Mining District, Colorado, using AVIRIS, aircraft, satellite, and terrain data. In: JPL Airborne Earth Science Workshop, 7, Pasadena, CA. *Summaries*, JPL Publ. 97-21, p. 261-267.
- MAZER, A. S., MARTIN, M., LEE, M., SOLOMON, J. E. (1988). Image processing software for imaging spectrometry analysis. *Remote Sens. Environ.*, 24 (1):201-210.
- MCCORD, T. B., CLARK, R. N., HAWKE, B. R., MCFADDEN, L. A., OWENSBY, P. D., PIETERS, C. M., ADAMS, J. B. (1981). Moon: near-infrared spectral reflectance, a first good look, *J. Geophys. Res.*, 86:10.883-10.892.
- MCCUBBIN, I., LANG, H., GREEN, R., LANG, H., ROBERTS, D. (1998). Mineral mapping AVIRIS data at Ray Mine AZ. In: JPL Airborne Earth Science Workshop, 7, Pasadena, CA. *Summaries*, JPL Publ. 97-21, p. 269-272.
- PINORI, S., BELLUCCI, G. (2001), Imaging spectroscopy of selected regional dark mantle deposits of the Moon. *Planetary and Space Science*, 49 (2001) 487–500.

- RIAZA, K. H., ZOCK, A., MÜLLER, A. (1998), Mineral Mapping in Maktesh_Ramon (ISRAEL) Using DAIS 7915, In: EARSeL Workshop on Imaging Spectroscopy, 1, University of Zurich, Switzerland. *Proceedings*, p. 365-373.
- ROWAN, L. C., MARS, J. C. (2003). Lithologic mapping in the Mountain Pass, California area using Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER) data. *Remote Sens. Environ.*, 84:350–366.
- SWAYZE, G. A., CLARK, R. N., PEARSON, R. M., LIVO, K. E. (1996). Mapping acid-generating minerals at the California Gulch Superfund Site in Leadville, Colorado using imaging spectroscopy. In: JPL Airborne Earth Science Workshop, 6, Pasadena, CA. *Summaries*, JPL Pub. 96-1 v.1.
- SWAYZE, G., CLARK, R. N., GOETZ, A. F., LIVO, K. E., BISDORF, R. J., SUTLEY, S. J., (1998a). Using imaging spectroscopy to better understand the hydrothermal and tectonic history of the Cuprite Mining District, Nevada. In: JPL Airborne Earth Science Workshop, 7, *Summaries*, JPL Publ. 97-21, p. 385-390.
- SWAYZE, G., CLARK, R. N., HAGEMAN, P. L., SMITH, K. S., SUTLEY, S. J., BRIGGS, P. H., SINGLETON, M. J., MEIER, A. L., PEARSON, R. M., RUST, G. S. (1998b). Using imaging spectroscopy to cost-effectively locate acid-generating minerals at mine sites: an example from the California Gulch Superfund Site in Leadville, Colorado. In: Airborne Earth Science Workshop, 7, Pasadena, CA. *Summaries*, JPL Pub. 97-21, p. 383-384.
- SWAYZE, G., CLARK, R. N., KRUSE, F., SUTLEY, S., GALLAGHER, A. (1992). Ground-truthing AVIRIS mineral mapping at Cuprite, Nevada. In: Annual JPL Airborne Geoscience Workshop, 4, Pasadena, CA. *Summaries*, JPL Publ. 92-14, p. 69-71.
- YUHAS, R. H., GOETZ, A. F. H., BOARDMAN, J. W. (1992). Discrimination among Semi-Arid landscape endmembers using Spectral Angle Mapper (SAM) Algorithm. In: Annual JPL Airborne Geoscience Workshop, 4, Pasadena, CA. *Summaries*, JPL Publ. 92-14, p 147-150.