

## ANEXOS

### ANEXO A

**Cópia do artigo apresentado e publicado no XI Simpósio Brasileiro de Sensoriamento Remoto** (FERREIRA, M. E.; FERREIRA, L.G.; SANO, E. E.; SHIMABUKURO, Y. E. Uso do modelo linear de mistura espectral para o mapeamento sistemático e operacional do bioma Cerrado: possibilidades, implicações e procedimentos metodológicos. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., 2003, Belo Horizonte, MG. **Anais...** São José dos Campos: INPE, 2003. p. 657-664).

### ANEXO B

**Cópia do artigo apresentado e publicado no X Simposio Latino-Americano de percepción Remota y Sistemas de Información Espacial** (FERREIRA, M. E.; SANO, E. E.; FERREIRA, L. G.; MENESES, P. R. 2002b. Preliminary insights on the use of a linear mixture model for vegetation mapping in the Brazilian Cerrado. In: SIMPOSIO LATINO-AMERICANO DE PERCEPCIÓN REMOTA Y SISTEMAS DE INFORMACIÓN ESPACIAL, 10., 2002, Cochabamba, Bolívia. **Anais...** Bogotá: SELPER, 2002. 1 CD-ROM).

### ANEXO C

**Bibliografia atualizada, relacionada com o Modelo Linear de Mistura Espectral no estudo da vegetação.**

### ANEXO D

**Novo mapa de vegetação do Parque Nacional de Brasília (PNB), formato analógico, impresso no tamanho A3.**

## ANEXO A

### USO DO MODELO LINEAR DE MISTURA ESPECTRAL PARA O MAPEAMENTO SISTEMÁTICO E OPERACIONAL DO BIOMA CERRADO: POSSIBILIDADES, IMPLICAÇÕES E PROCEDIMENTOS METODOLÓGICOS

Manuel Eduardo Ferreira<sup>1</sup>  
Laerte Guimarães Ferreira<sup>2</sup>  
Edson Eijy Sano<sup>3</sup>  
Yosio Edemir Shimabukuro<sup>4</sup>

<sup>1</sup>Universidade de Brasília

Instituto de Geociências - Departamento de Geologia Geral e Aplicada  
Campus Universitário Darcy Ribeiro – 70919-970 – Brasília - DF, Brasil

[manfer@unb.br](mailto:manfer@unb.br)

<sup>2</sup>Universidade Federal de Goiás

Instituto de Estudos Sócio-Ambientais (IESA)  
Campus Samambaia, Caixa Postal 131 – 74001-970 – Goiânia - GO, Brasil

[laerte@iesa.ufg.br](mailto:laerte@iesa.ufg.br)

<sup>3</sup>Embrapa Cerrados

BR-020 Km 18, Caixa Postal 08.223 - 73301-970 – Planaltina - DF, Brasil

[sano@cpac.embrapa.br](mailto:sano@cpac.embrapa.br)

<sup>4</sup>INPE - Instituto Nacional de Pesquisas Espaciais  
Caixa Postal 515 – 12201-970 – São José dos Campos - SP, Brasil  
[yosio@ltid.inpe.br](mailto:yosio@ltid.inpe.br)

**Abstract.** The Cerrado biome, one of the largest and richest savanna environments in the world, is also an endangered ecosystem due to the severe land conversion. Therefore, it becomes mandatory a systematic and operational monitoring of the vegetation cover. Within this scope, in this study we evaluated the use of a linear spectral mixture model for mapping the Cerrado physiognomies. The model was applied to a dry season (July 2001) Landsat 7 ETM+ scene (221/71) converted to reflectance values, for an area corresponding to the Brasilia National Park. Three endmembers were acquired directly from the image (vegetation, soil, and shadow) and the respective derived images were capable of discriminating the major Cerrado domains (herbaceous, arbustive, and arborescent), with proportions ranging from 0.7 to 1.0. Currently, we are evaluating a different set of endmembers and the use of segmentation techniques as an attempt to more precisely map the Cerrado physiognomies. In addition, the impact of atmospheric contamination on the model output is being assessed as well.

**Keywords:** linear mixture modeling, vegetation mapping, Cerrado.

## 1. Introdução

O bioma Cerrado, constituído por um complexo vegetacional presente em mais de dez Estados brasileiros, exibe uma das floras mais ricas dentre os ambientes savânicos no mundo. A manutenção desta biodiversidade é favorecida pela presença das três maiores bacias hidrográficas da América do Sul (Tocantins, São Francisco e Prata), além de uma grande diversidade de solos, geologia, e queimadas naturais (Eiten, 1972). Apesar disto, este ecossistema é pouco valorizado em termos de conservação, apresentando apenas 1% de sua área assegurada na forma de parques ou reservas.

Em função da contínua abertura de novas áreas para pastagem e agricultura, estima-se que, até o momento, aproximadamente 40% deste bioma tenham sido desmatados (Sano et al., 2002), de um total de 208 milhões de hectares. Há, portanto, uma real necessidade de se estabelecer o monitoramento sistemático da vegetação, através do uso operacional e efetivo dos diversos produtos de sensoriamento remoto atualmente disponíveis.

Por outro lado, estudos recentes sobre mapeamento do Cerrado, utilizando dados de sensoriamento remoto de última geração, têm demonstrado algumas restrições quanto à discriminação de fitofisionomias deste bioma (Ferreira et al., 2002). Em geral, observa-se uma certa confusão espectral entre classes gramíneo-lenhosas (Campo Limpo e Campo Sujo) e arbustivas (Campo Cerrado e Cerrado *sensu stricto*).

Neste sentido, o presente estudo busca avaliar a aplicação de um Modelo Linear de Mistura Espectral (MLME) para o mapeamento das fisionomias de Cerrado. Objetivos específicos incluem (1) a definição de um conjunto apropriado de componentes puros (*endmembers*) para modelar as misturas espectrais existentes no bioma Cerrado, (2) a avaliação do uso de *endmembers* intrínsecos à imagem, bem como aqueles definidos a partir de dados espectroradiométricos obtidos em campo e (3) a avaliação dos efeitos da contaminação atmosférica na aplicação dos modelos de mistura.

## 2. Modelo Linear de Mistura Espectral

Imagens de sensoriamento remoto normalmente apresentam, na maior parte das vezes, *pixels* misturados, devido à variação e proximidade dos alvos na superfície. Em geral, esta mistura espectral ocorre devido ao campo de visada instantâneo do sensor (GIFOV) incluir mais de uma classe de cobertura, havendo assim uma combinação da radiância dos diversos materiais observados pelo sensor (Verhoeve & De Wulf, 2002). Também contribuem à mistura no sinal, principalmente entre *pixels*, fatores espúrios à obtenção das imagens, em particular aqueles devido à contaminação atmosférica e variações na geometria de aquisição.

O Modelo Linear de Mistura Espectral (MLME) possui como objetivos básicos (1) reduzir o volume de dados a serem utilizados em um processamento (e.g. classificação de imagens) e (2) realçar os alvos de interesse. Este modelo fundamenta-se no pressuposto de que a resposta espectral de um *pixel*, numa imagem qualquer (bandas 1, 2, ...,  $m$ ), seria uma combinação linear dos espectros de diversos materiais contidos na superfície. Nestas condições, para qualquer imagem (multiespectral ou hiperespectral) e sendo as respostas espectrais dos componentes conhecidas, as proporções destes podem ser estimadas, de forma individual, por meio da geração de imagens-fração (Shimabukuro & Smith, 1995; Shimabukuro et al., 1998).

A imagem-fração, para um respectivo *endmember*, pode ser obtida através da aplicação do modelo de mistura apresentado na Equação 1. A Equação 2 refere-se ao termo de erro da

primeira equação, correspondendo aos valores residuais presentes em cada *pixel*, não solucionados pelo método de análise proposto.

$$r_i = \sum_{j=1}^n (a_{ij} x_{ij}) + e_i \quad (1)$$

$$e_i = r_i - \sum_{j=1}^n (a_{ij} x_j) \quad (2)$$

Onde:  $r_i$  = reflectância espectral observada na banda  $i$  de um *pixel*, contendo um ou mais componentes;  $a_{ij}$  = reflectância espectral do componente  $j$  para a banda espectral  $i$ ;  $x_j$  = proporção do componente  $j$  (*endmember*) dentro de um *pixel*;  $e_i$  = erro para a banda  $i$  (contribuição residual não considerada pelo conjunto de *endmembers*);  $j = 1, 2, 3, \dots, n$  (número de componentes);  $i = 1, 2, 3, \dots, m$  (número de bandas espectrais).

O MLME deve seguir as restrições apresentadas na Equação 3, as quais orientam a análise das proporções de cada componente amostrado na imagem. As imagens-fração podem ser estimadas por diferentes métodos, dentre estes, os mais conhecidos são o CLS (*Constrained Least Square*) e o WLS (*Weighted Least Square*), ambos voltados para minimizar a soma dos quadrados dos erros (ou valores residuais) em cada *pixel*. Uma descrição detalhada destes e de outros métodos pode ser encontrada em Holben & Shimabukuro (1993).

$$0 \leq x_j \leq 1 \text{ e } \sum x_j = 1 \quad (3)$$

## 2. Desenho Experimental

### Área de estudo

O MLME foi avaliado em uma cena Landsat 7 ETM<sup>+</sup> (221/71), obtida em 20 de julho de 2001, especificamente para a área correspondente ao Parque Nacional de Brasília (PNB), localizado ao norte do Distrito Federal, entre a latitude sul 15° 35' / 15° 45' e longitude oeste 47° 53' / 48° 05'. Trata-se de uma área relativamente extensa e preservada, com aproximadamente 30.000 hectares, bastante representativa das principais fitofisionomias de Cerrado (Campo Limpo, Campo Sujo, Campo Cerrado e Cerrado *sensu stricto*) (**Figura 1**).

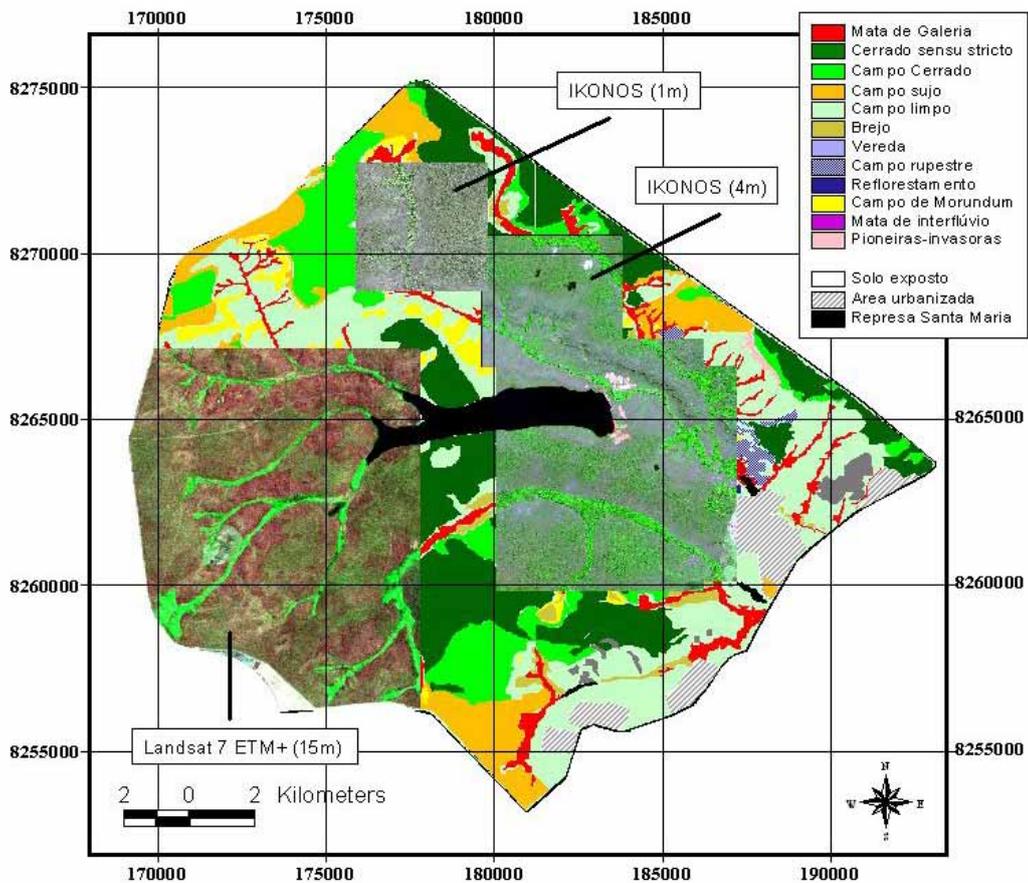
### Abordagem Metodológica

- Atualização do mapa de cobertura vegetal do Parque Nacional de Brasília, por meio de levantamentos de campo e uso de dados orbitais: ETM<sup>+</sup> 15m (Red, NIR, SWIR + Pan) / IKONOS 1m e 4m (Blue, Red, NIR) (**Figura 1**). O atual mapa está sendo utilizado como verdade de campo a fim de se avaliar e validar o modelo de mistura quanto à discriminação das fisionomias predominantes na área de estudo.
- Aplicação do MLME com os componentes *vegetação*, *solo* e *sombra*, haja a vista a possibilidade de se mapear os vários tipos de cobertura presentes na área de estudo a partir de três *endmembers*, conforme demonstrado na **Figura 2**.

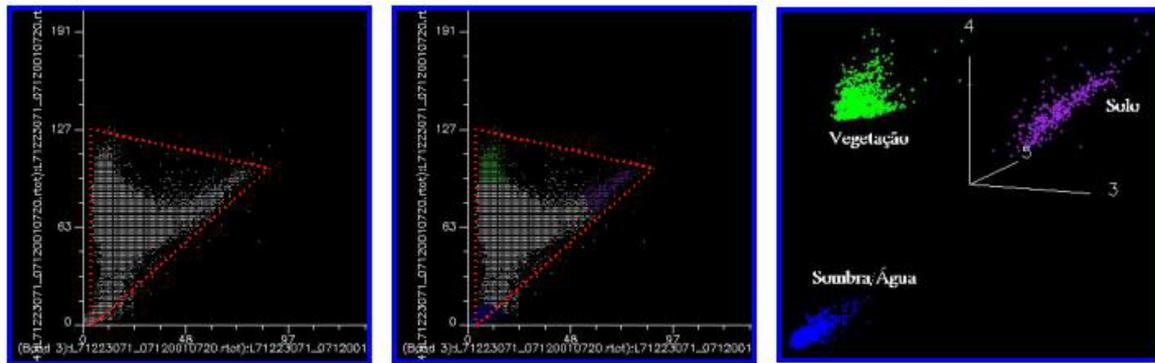
### Aplicação do MLME nos dados Landsat 7 ETM<sup>+</sup>

O MLME foi aplicado na imagem Landsat ETM+ (bandas 1 - 5 e 7), convertida para nível de reflectância, direcionando-se a análise para o Parque Nacional de Brasília. Amostras dos componentes *vegetação*, *solo* e *sombra* (consideradas como puras) foram extraídas diretamente da imagem (221/71). Para tanto, realizou-se uma seleção prévia dos *endmembers* com base na distribuição dos *pixels* no espaço amostral vermelho - infravermelho, e considerando a teoria do *simplex* (Bajjouk et al., 1998), onde os *pixels* mais puros encontram-se nos extremos desta distribuição.

O componente *vegetação* foi amostrado em áreas com Mata de Galeria, por ser esta classe a de maior vigor vegetacional no bioma Cerrado. Amostras do componente *sombra* foram obtidas na área correspondente na imagem à represa Santa Maria. Na Figura 2 observam-se as etapas de definição das amostras, consideradas como *pixels* puros, para os três componentes.

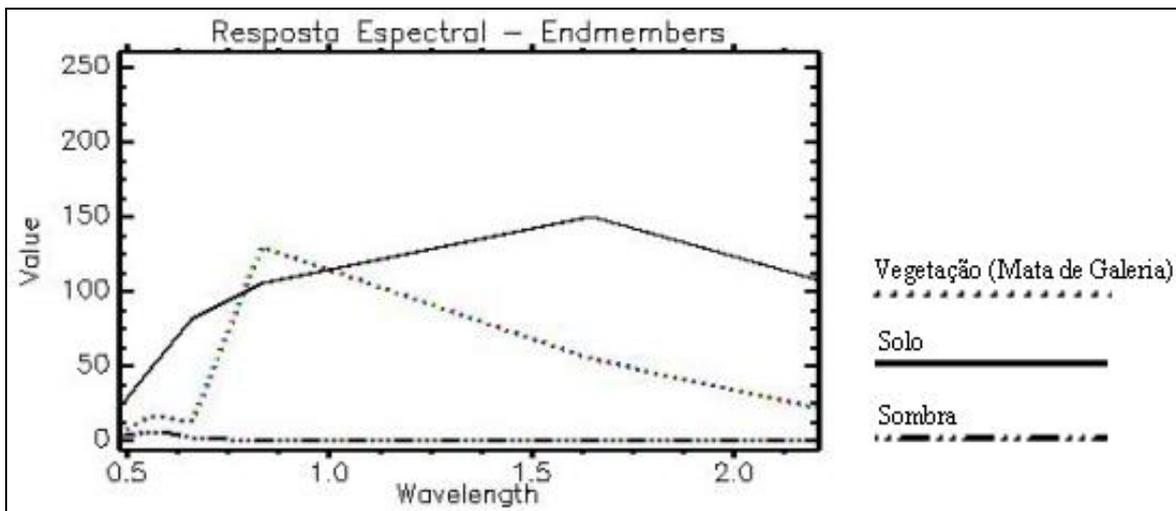


**Figura 1.** Área de Estudo. Mapa de cobertura vegetal do Parque Nacional de Brasília, atualizado através das cenas Landsat 7 ETM<sup>+</sup> e IKONOS (1m e 4m).



**Figura 2.** Espaço amostral vermelho - infravermelho, com a localização dos componentes *vegetação*, *solo* e *sombra*.

A resposta espectral de cada um dos três *endmember*, e posteriormente aplicadas no MLME, podem ser verificadas na **Figura 3**. O método WLS (*Weighted Least Square*) foi utilizado para estimar a proporção de cada componente dentro do *pixel*. Três imagens-fração (*vegetação*, *solo* e *sombra*) do Parque Nacional de Brasília foram geradas. Uma “imagem-erro” também foi adicionada a esta análise.



**Figura 3.** Resposta espectral dos componentes *vegetação*, *solo* e *sombra*, extraídas da imagem Landsat 7 ETM<sup>+</sup>, na área do Parque Nacional de Brasília.

#### 4 - Resultados e Considerações Finais

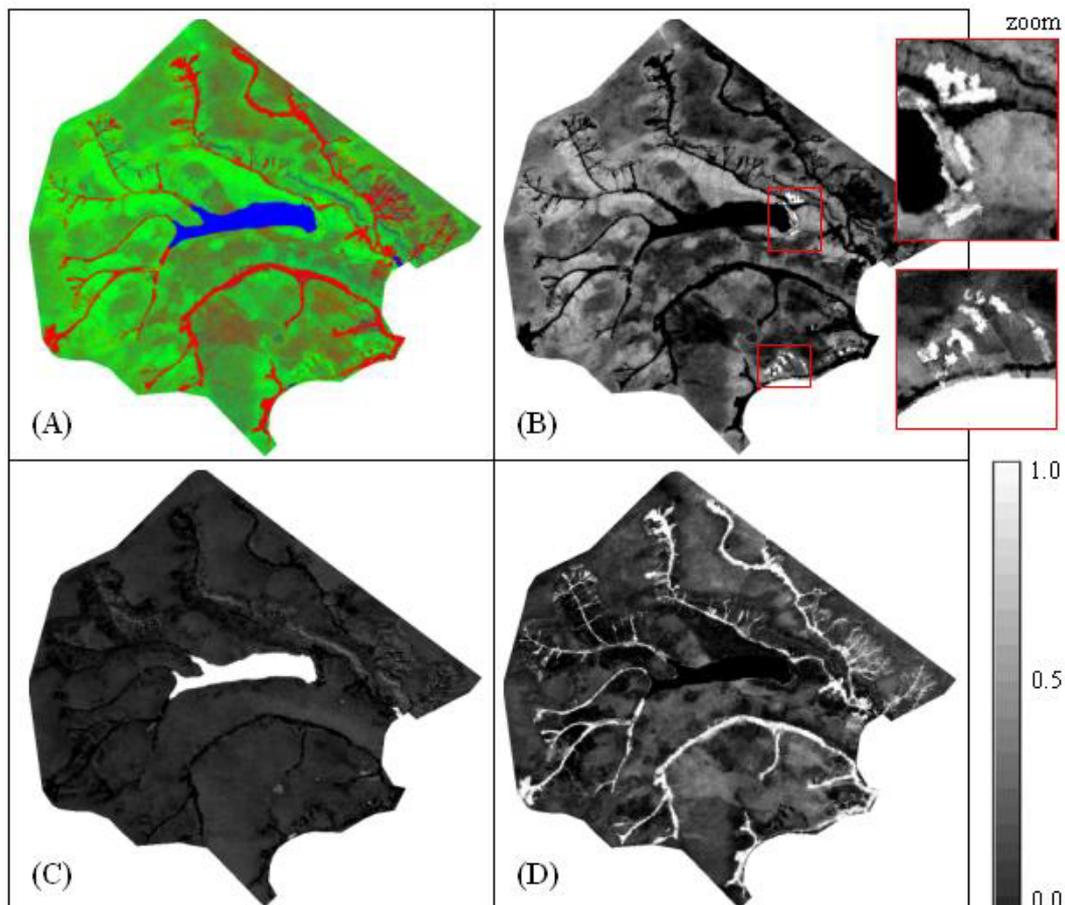
Na **Figura 4** são apresentadas as imagens-fração (bandas sintéticas), geradas com o método WLS, contendo as proporções para os componentes *vegetação* (Mata de Galeria), *solo* e *sombra* (água). Bandas sintéticas utilizando o método CLS foram geradas, com resultados muito similares ao WLS. Contudo, optou-se pelo método WLS, haja vista este ter destacado melhor as proporções dos respectivos componentes.

De uma forma geral, todos os componentes foram bem realçados, com proporções entre 0.7 e 1.0 (*pixels* com maior brilho) para todos os *endmembers* amostrados. A imagem-fração *solo* destacou, além dos pontos com solo exposto, aquelas áreas correspondentes ao estrato herbáceo (e.g. Campo Limpo - manchas mais claras na imagem-fração *solo*), onde a presença de um componente arbustivo (e.g. Campo Cerrado, Cerrado *sensu stricto*) ou arbórescente (e.g. Cerradão, Mata de Galeria) é praticamente nula. No outro extremo, encontra-se a imagem-fração

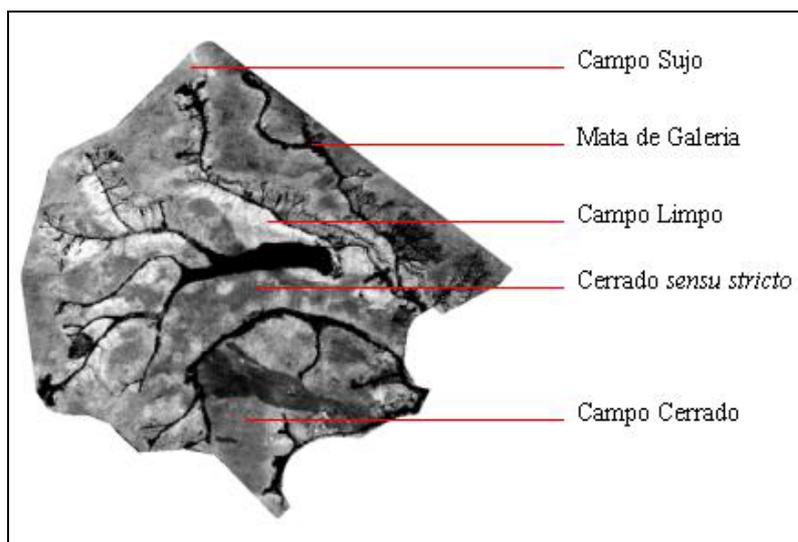
vegetação, a qual destacou, além das áreas com maior vigor vegetacional (Mata de Galeria), fisionomias de Cerrado pertencentes ao estrato arbustivo.

Ainda na **Figura 4**, uma composição colorida foi gerada com as frações *vegetação* (Red), *solo* (Green) e *sombra* (Blue), indicando visualmente a discriminação de pelo menos 4 classes de Cerrado: Campo Limpo, Campo Cerrado, Cerrado *sensu stricto*, e Mata de Galeria.

A imagem-erro (**Figura 5**) indica o inverso das imagens-fração, ou seja, áreas de maior brilho correspondem ao maior erro (valor residual) presente em cada *pixel*. Dessa forma, as proporções de componentes não definidos no modelo de mistura e/ou não solucionadas (classificadas) pelo método utilizado no processamento (e.g. WLS, CLS, e outros), são destacados em diferentes níveis de cinza, conforme o valor residual. Especificamente no PNB, observou-se que na imagem-erro as manchas mais claras obedecem à presença de fitofisionomias de Cerrado com baixa biomassa, tal como Campo Limpo / Campo Sujo, classes estas não incluídas no conjunto de *endmembers* avaliados, com valores residuais em torno de 11. À medida que as fitofisionomias aproximam-se do componente arbóreo / florestal (Mata de Galeria), o erro diminui para valores em torno de 8 (áreas de Campo Cerrado) e 4 (áreas de Cerrado *sensu stricto*). Nas áreas com nível de cinza escuro, referentes aos componentes aplicados no modelo de mistura, o erro ficou entre 0 e 2. Tais resultados indicam uma confiabilidade maior quanto ao conjunto de *endmembers* amostrados na imagem.



**Figura 4.** Imagens-fração do Parque Nacional de Brasília: (A) composição colorida (R - vegetação, G - solo, B - sombra);; (B) solo; (C) sombra (água); e (D) vegetação.



**Figura 5.** Imagem-erro correspondente às imagens-fração do PNB.

Em fato, os resultados demonstram o potencial do MLME para o mapeamento dos componentes florestais, arborescentes, arbustivos e herbáceos, encontrados no bioma Cerrado. No momento estamos avaliando o uso do modelo de mistura aplicado somente às fisionomias de Cerrado. Especificamente, estamos analisando o Campo Limpo, Campo Cerrado e Cerrado *sensu stricto*, haja a vista o fato destas fisionomias resultarem da mistura, em diferentes proporções, dos estratos herbáceo, arbustivo e arborescente.

Técnicas de processamento, tal como a segmentação de imagens e o uso de algoritmos supervisionados / não-supervisionados para classificação, podem contribuir para uma análise mais efetiva e operacional destas imagens-fração, como observado em outros trabalhos que adotam esta metodologia de análise (Shimabukuro et al., 2000).

Outro aspecto que estamos considerando nesta pesquisa é o impacto da contaminação atmosférica sobre as imagens-fração geradas para o bioma Cerrado. Neste caso, os modelos de mistura espectral “vegetação, solo e sombra” e “Campo limpo, Campo Cerrado e Cerrado *sensu stricto*” estão sendo aplicados em imagens com (a) nível de cinza, (b) convertidas para nível de reflectância, bem como (c) às imagens radiométricamente retificadas, conforme metodologia desenvolvida por Hall et al. (1991).

## 5 - Referências Bibliográficas

Bajjouk, T.; Populus J.; Guillaumont, B. Quantification of subpixel cover fractions using principal component analysis and a linear programming method: application to the Coastal Zone of Roscoff (France). *Remote Sensing of Environmental*, 64:153-165, 1998.

Eiten, G. The Cerrado vegetation of Brazil. *The Botanical Review* 38 (2): 201-341, 1972.

Ferreira, L.G.; Yoshioka, H.; Huete, A.R.; Sano, E.E. Seasonal landscape and spectral vegetation index dynamics in the Brazilian Cerrado: An analysis within the Large Scale Biosphere-Atmosphere Experiment in Amazonia (LBA). LBA special issue, *Remote Sensing of Environment*, 2002 (in press).

Hall, F.G.; Strebel, D.E.; Nickeson, J.E.; Goetz, S.J. Radiometric rectification: toward a common radiometric response among multidata, multisensor images. *Remote Sensing of Environment*, 35: 11-27, 1991.

Holben, B.N.; Shimabukuro, Y.E. Linear Mixing Model applied to coarse spatial resolution data from multispectral satellite sensors. *International Journal of Remote Sensing*, vol. 14, 2231-2240, 1993.

Sano, E.E.; Barcellos, A.O.; Bezerra, H.S. Assessing the spatial distribution of cultivated pastures in the Brazilian savanna. *Pasturas Tropicales*, 22 (3), p. 2-15, 2002.

Shimabukuro, Y.E.; Novo, E.M.; Ponzoni, F.J. Índice de vegetação e modelo linear de mistura espectral no monitoramento da região do Pantanal. *Pesquisa Agropecuária Brasileira*: Brasília, vol. 33, número especial, p. 1729-1737, 1998.

Shimabukuro, Y.E.; Smith, J.A. Fraction images derived from Landsat TM and MSS data for monitoring reforested areas. *Canadian Journal of Remote Sensing*, vol. 21, no. 1, 67-74, 1995.

Shimabukuro, Y.E.; Duarte, V.; Mello, E.M.K.; Moreira, J.C. Apresentação da metodologia de criação do PRODES Digital. São José dos Campos: INPE (7520-PUD/41), p. 1-36, 2000.

Verhoeve, J.; De Wulf, R. Land cover mapping at sub-pixel scales using linear optimization techniques. *Remote Sensing of Environment*, 79: 96-104, 2002.

## ANEXO B

### AVALIAÇÃO PRELIMINAR DO MODELO LINEAR DE MISTURA ESPECTRAL PARA O MAPEAMENTO DO CERRADO BRASILEIRO

Manuel E. Ferreira<sup>1</sup>

Edson E. Sano<sup>2</sup>

Laerte G. Ferreira<sup>3</sup>

Paulo R. Meneses<sup>1</sup>

<sup>1</sup>Universidade de Brasília, Instituto de Geociências, Departamento de Geologia Geral e Aplicada - IG,  
ICC - Campus Universitário Darcy Ribeiro, Brasília-DF, Brasil, 70919-970

[manfer@unb.br](mailto:manfer@unb.br), [pmeneses@unb.br](mailto:pmeneses@unb.br)

<sup>2</sup>Embrapa Cerrados, Planaltina-DF, Brasil, 73301-970

[sano@cpac.embrapa.br](mailto:sano@cpac.embrapa.br)

<sup>3</sup>Universidade Federal de Goiás, Instituto de Estudos Sócio-Ambientais, Campus Samambaia, Caixa  
Postal 131, Goiânia-GO, Brasil, 74001-970

[laerte@iesa.ufg.br](mailto:laerte@iesa.ufg.br)

**PALAVRAS CHAVES:** Cerrado, Modelo Linear, Mistura Espectral, Landsat 7 ETM+

#### RESUMO

O Cerrado brasileiro, segundo maior bioma na América do Sul, compreende um mosaico de vegetação, verticalmente estruturado por gramíneas, arbustos e árvores. Considerado como a principal fronteira agrícola no Brasil, estima-se que 40% da cobertura de Cerrado já tenham sido convertidas em pastagens cultivadas, plantações de grãos, expansão urbana e áreas degradadas. Apesar desta agressiva conversão, poucas pesquisas vêm sendo desenvolvidas quanto ao uso operacional do sensoriamento remoto para eficientemente monitorar e entender este bioma. Dentro deste contexto, nós avaliamos a utilidade de um Modelo Linear de Mistura Espectral (MLME) para o mapeamento das principais fitofisionomias de Cerrado (Campo Limpo, Campo Sujo, Cerrado Ralo e Cerrado Denso) encontradas no Parque Nacional de Brasília, uma área com aproximadamente 30.000 ha, ao norte do Distrito Federal, entre 15° 35' - 15° 45' latitude sul e 47° 53' - 48° 05' longitude oeste. O MLME, aplicado sobre uma cena Landsat 7 ETM+ (221 / 71) atmosféricamente corrigida, obtida em 20 de julho de 2001 (estação seca), e baseado em *endmembers* coletados na própria imagem, discriminou quatro componentes: a) Campo Limpo, b) Mata de Galeria, c) solo exposto, e d) água / sombra. De uma forma geral, consideramos o método *Constrained Least Square* (CLS) como o mais indicado para discriminar a vegetação densa / componentes florestais, com valores próximos a 1 nas imagens-fração, em acordo com os dados de campo, enquanto que o componente graminoso foi subestimado (imagens-fração com valores abaixo de 0.7). Nossos resultados, embora preliminares e não-conclusivos, indicam o potencial do MLME para mapear este complexo bioma, marcado por misturas espectrais significantes, particularmente nas fitofisionomias com baixa biomassa (Campo Limpo e Campo Sujo).

## ABSTRACT

The Brazilian Cerrado, the second largest biome in South America, comprises a vertically structured mosaic of grassland, shrubland, and woodland. As a major farming frontier in Brazil, it is estimated that about 40% of the Cerrado land cover has already been converted into cultivated pastures, field crops, urban development, and degraded areas. Despite this aggressive pace of land conversion, there have been few investigations on the operational utilization of remote sensing data to effectively monitor and understand this biome. Within this context, we evaluated the usefulness of a linear mixture model (LMM) for mapping the major Cerrado physiognomies (i.e. Cerrado grassland, Shrub Cerrado, wooded Cerrado, and Cerrado woodland) found at the Brasília National Park, an area of approximately 30,000 ha located in the northern Federal District, Brazil, between 15°35' and 15°45' south latitude and 47°53' and 48°05' west longitude. The LMM, performed over an atmospherically corrected Landsat 7 ETM+ scene (221 / 71) obtained on July 20<sup>th</sup> 2001 (dry season) and based on image endmembers, accounted for four land cover components: a) Cerrado grassland, b) gallery forest, c) bare soil, and d) water / shadow. Overall, we found the constrained least square method (CLS) to provide an improved discrimination of the dense vegetation / forest component, with fraction image values close to 1, in close agreement with our ground truth data, while the grassland component was mostly underestimated (fraction image values lower than 0.7). Our results, although preliminary and not conclusive, do indicate the potential of the LMM approach to map this complex biome, marked by significant spectral mixing, particularly within the low biomass physiognomies (e.g. Cerrado grassland and Shrub Cerrado).

## 1 - INTRODUÇÃO

Nas últimas décadas, o sensoriamento remoto vem desempenhando um importante papel no monitoramento da cobertura vegetal, atuando, sobretudo, como uma fonte de dados contínua e regular (Abrams, 2000). As características da vegetação, incluindo seus aspectos fisionômicos, exercem grande influência nos fenômenos climáticos, na absorção e emissão da radiação solar e na ciclagem do carbono (Zhu & Tateishi, 2001). Daí a importância de mapeamentos mais eficientes, capazes de quantificar com precisão as alterações ambientais nos ecossistemas terrestres, ocasionadas, em sua maioria, por desmatamentos e queimadas.

Estudos recentes sobre mapeamento do Cerrado, através de dados de sensoriamento remoto de última geração, têm demonstrado algumas restrições relativas à discriminação de fitofisionomias deste bioma. Em geral, classes com baixa biomassa, analisadas com imagens de radar, apresentam uma certa confusão espectral (Sano et al., 2000). Índices de vegetação, obtidos de dados espectro-radiométricos de campo (Ferreira et al., 2002), confirmam também um agrupamento das classes gramíneo-lenhosas (Campo Limpo e Campo Sujo) e arbustivas (Cerrado Ralo e Cerrado Típico).

Visando melhorar esta separabilidade espectral entre as classes de Cerrado, vem sendo testado o uso de um Modelo Linear de Mistura Espectral (MLME), capaz de detectar as alterações na cobertura vegetal por meio da geração de imagens-fração (IF), considerando os componentes contidos em cada *pixel* de uma imagem (Schweik & Green, 1999; Shimabukuro et al., 1998; Bryant, 1996; Holben & Shimabukuro, 1993).

Este trabalho avalia, de forma preliminar e não-conclusiva, o uso do MLME como suporte ao mapeamento da vegetação de Cerrado, abordando-se os fundamentos e as aplicações práticas da análise de mistura espectral.

## 2 - FUNDAMENTOS

### 2.1 - Modelo Linear de Mistura Espectral

O Modelo Linear de Mistura Espectral (MLME) fundamenta-se no pressuposto de que a resposta espectral de um *pixel*, numa imagem qualquer (bandas 1, 2, ..., *n*), é na verdade uma mistura linear dos

espectros de vários materiais contidos na superfície imageada pelo sensor (Shimazaki & Tateishi, 2001; Schweik & Green, 1999; Schowengerdt, 1997).

Segundo Shimabukuro (1998), esta relação linear representa a mistura espectral dos componentes contidos em um único *pixel*. Assim, cada *pixel* possui as informações sobre a proporção e a resposta espectral de cada componente. Nestas condições, para qualquer imagem (multiespectral ou hiperespectral), sendo as respostas espectrais dos componentes conhecidas, as proporções destes podem ser estimadas.

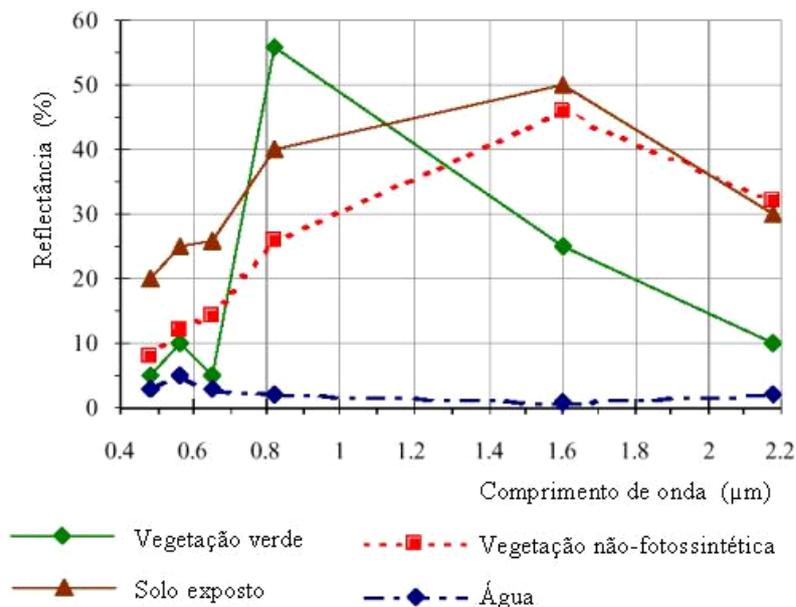
Imagens de sensoriamento remoto normalmente apresentam uma combinação de *pixels* puros e *pixels* misturados. Os *pixels* misturados surgem quando o campo de visada instantâneo do sensor (IFOV) inclui mais de uma classe de cobertura (Verhoeve & De Wulf, 2002). Como exemplo, pode-se citar as pequenas áreas úmidas, inseridas em um ambiente seco, proporcionando uma mistura espectral no sinal recebido pelo sensor. Outros fatores também influenciam na mistura do sinal captado pelo sensor (espectrômetro), tal como a variação da iluminação na superfície, devido aos aspectos topográficos da região (sombra); mudanças no ângulo solar zenital; ou resposta espectral de vários materiais espacialmente próximos. De acordo com Piwowar et al. (1998), apesar da resolução espacial dos sensores orbitais ter aumentado substancialmente nos últimos anos, a maioria dos dados coletados apresenta uma característica espectralmente misturada, pois a escala de variação espacial dos fenômenos naturais é freqüentemente maior do que a atual resolução espacial dos sensores.

## 2.2 - Métodos para Aplicação do MLME

Um modelo linear busca identificar a contribuição espectral de cada alvo dentro de um *pixel* da imagem. Normalmente, os alvos imageados apresentam curvas de reflectância diferenciadas em um determinado comprimento de onda do espectro-eletromagnético (Figura 1); assim ocorre, por exemplo, para a vegetação verde, vegetação seca, solo exposto e água, permitindo que a cena seja classificada de forma precisa, ao nível de *subpixel* (Schweik & Green, 1999; Schowengerdt, 1997).

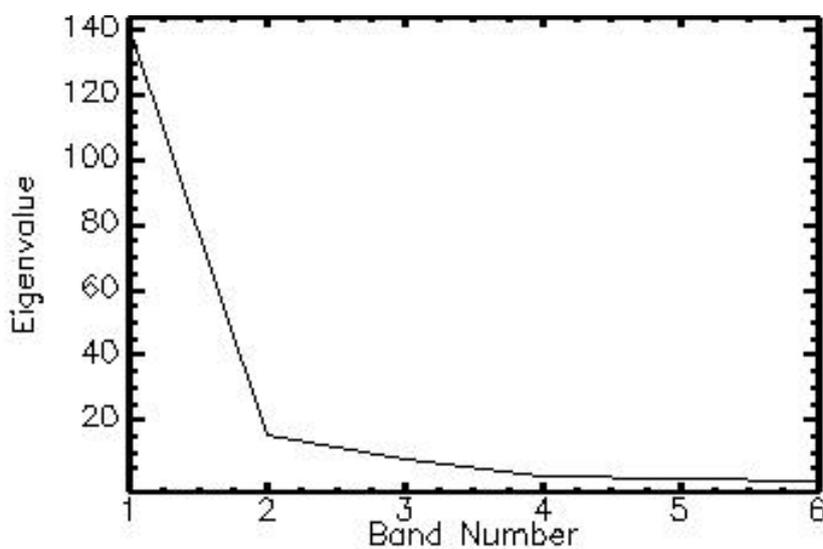
Antes da aplicação de um MLME, é necessário que a imagem, originalmente em números digitais (0 - 255), seja convertida para valores de reflectância aparente (Rogan et al. 2002; Shimabukuro et al., 1998). Este procedimento é fundamental para a geração de imagens-fração baseadas na reflectância dos componentes, dados obtidos diretamente na imagem ou a partir de bibliotecas espectrais.

Outro processamento não menos importante, realizado preferencialmente em imagens multiespectrais, é a Análise por Principais Componentes (APC). A APC é uma rotação do espaço multidimensional da imagem, agrupando os dados inerentes a esta, ao mesmo tempo em que os ruídos são isolados. Normalmente, as resultantes PC 1 e PC 2 concentram a estrutura da imagem, apresentando os *eigenvalues* mais altos (Crósta, 1993). Transformação semelhante, comumente aplicada às imagens hiperespectrais, é a chamada *Minimum Noise Fraction* (MNF), que também realiza a separação entre os dados inerentes à imagem e os ruídos desta. Da mesma forma que as Principais Componentes, as resultantes MNF 1 e MNF 2 apresentam os *eigenvalues* mais altos, representando a dimensionalidade dos dados. Ambas transformações são necessárias para reduzir os requerimentos computacionais nos processamentos subseqüentes no método em questão. A figura 2 ilustra a distribuição dos *eigenvalues* entre as resultantes MNF, geradas a partir de bandas do sensor Landsat 7 ETM+ (bandas 1 - 5 e 7).



**Figura 1.** Porcentagem de reflectância para Vegetação verde, Vegetação não-fotossintética, Solo exposto e Água. Modificada de Shimazaki & Tateishi (2001).

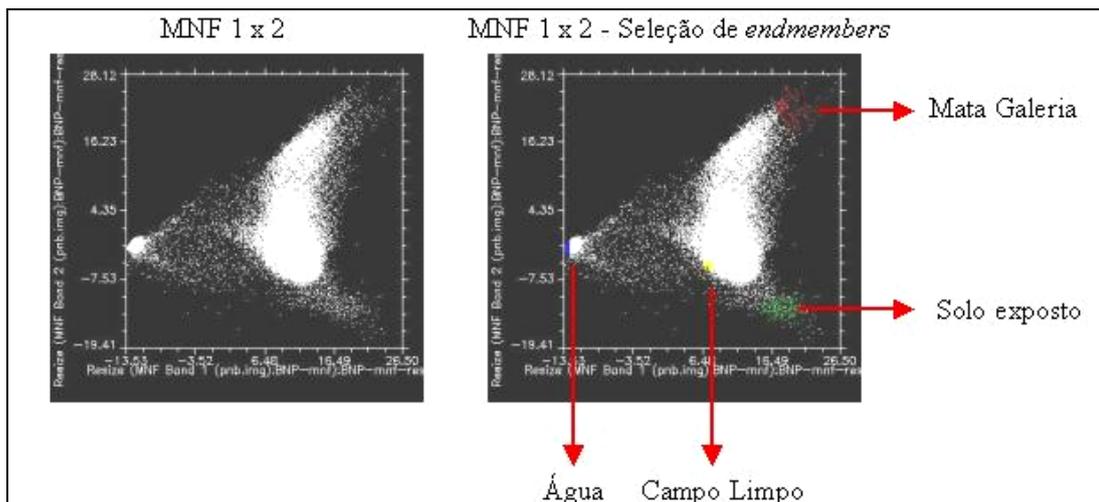
Após aplicação da APC ou MNF, a análise de mistura espectral pode ser realizada em duas etapas básicas (Shimazaki & Tateishi, 2001; Schweik & Green, 1999). A primeira etapa refere-se à aquisição de *pixels* puros, freqüentemente denominados de *endmembers*, visando separar um componente (ex: vegetação verde, solo, água) (Figura 3). Os *endmembers* podem ser adquiridos a partir de três fontes: (a) bibliotecas espectrais conhecidas, coletadas com espectrorradiômetros de campo ou de laboratório; (b) bibliotecas espectrais coletadas a partir de estudos anteriores com MLME; ou (c) a partir de *pixels* considerados puros para um determinado alvo, selecionados na própria imagem (método *Pixel Purity Index*). Normalmente, a última opção é a mais empregada, considerando a dificuldade de se encontrar um espectro puro de um alvo qualquer, adequado ao objetivo da pesquisa, numa biblioteca espectral disponível; outro fator desfavorável é o elevado custo de um espectro-radiômetro de campo, cujo uso nem sempre é possível.



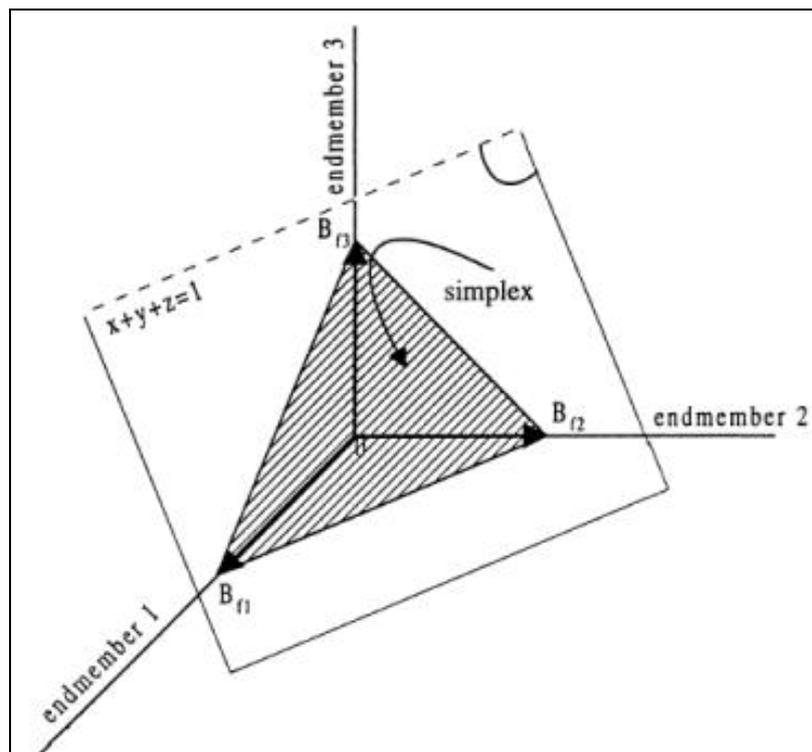
**Figura 2.** Distribuição dos eigenvalues após realização da transformação MNF com as bandas 1-5 e 7 do sensor Landsat 7 ETM+. Eigenvalues mais altos correspondem as resultantes MNF 1 e MNF 2.

De acordo com Schweik & Green (1999), no caso do Landsat 7 ETM+, o número de *endmembers* utilizados em um MLME não deve ultrapassar quatro, devido à alta correlação entre as bandas do espectro refletido. Bajjouk et al. (1998), avaliando a quantificação das frações de cobertura em *subpixel* por meio de Análise por Principais Componentes e métodos lineares, demonstram que, entre 10 e 13 bandas espectrais, o número de Principais Componentes mantidas (após transformação) e componentes identificados permanece constante em três e seis, respectivamente, podendo se distinguir entre quatro a seis componentes. Entre 4 e 7 bandas espectrais, a primeira e a segunda PC normalmente acumulam 98% dos dados, reduzindo o número de componentes passíveis de serem discriminados para 3 ou 4.

A seleção de *endmembers* em um *scatterplot* (ex: PC 1 x PC 2 ou MNF 1 x MNF 2) deve obedecer, em tese, à idéia do *simplex*. Isto é, os componentes puros (*endmembers*) devem ser coletados nos extremos das nuvens de pontos de um *scatterplot*, observando a localização dos *endmembers* na imagem (Bajjouk et al., 1998). As figuras 3 e 4 exemplificam esta regra.



**Figura 3.** Seleção dos *endmembers* (Mata Galeria, Campo Limpo, solo exposto e água / sombra) no *scatter plot* obtido a partir das resultantes MNF 1 e MNF 2.



**Figura 4.** Simplex utilizado para a coleta de *endmembers*, em um caso tri-dimensional. Fonte: Bajjouk et al. (1998).

A segunda etapa da análise de mistura espectral visa estimar a proporção ou abundância dos *endmembers* (componentes puros) presentes em cada *pixel* das imagens selecionadas, por meio da aplicação de uma equação de mistura linear (Schweik & Green 1999; Schowengerdt, 1997) (Equação 1). Esta equação, em geral na forma matricial, é utilizada na conversão dos valores de reflectância para imagens-fração de cada *endmember* previamente selecionado. O termo de erro, presente na Equação 1, pode ser expresso através da Equação 2 (Schweik & Green, 1999). Esta proporção, estimada para cada *endmember* por meio do MLME, baseia-se no método CLS (*Constrained Least-Squares*), assumindo que os valores fracionados, produzidos em uma matriz  $x$ , devem ser sempre positivos, com um somatório igual a 1 (Equação 3) (Holben & Shimabukuro, 1993).

$$r_i = \sum_{j=1}^n (a_{ij} x_j) + e_i \quad (1)$$

$$e_i = r_i - \sum_{j=1}^n (a_{ij} x_j) \quad (2)$$

De acordo com as restrições definidas pelo método CLS:

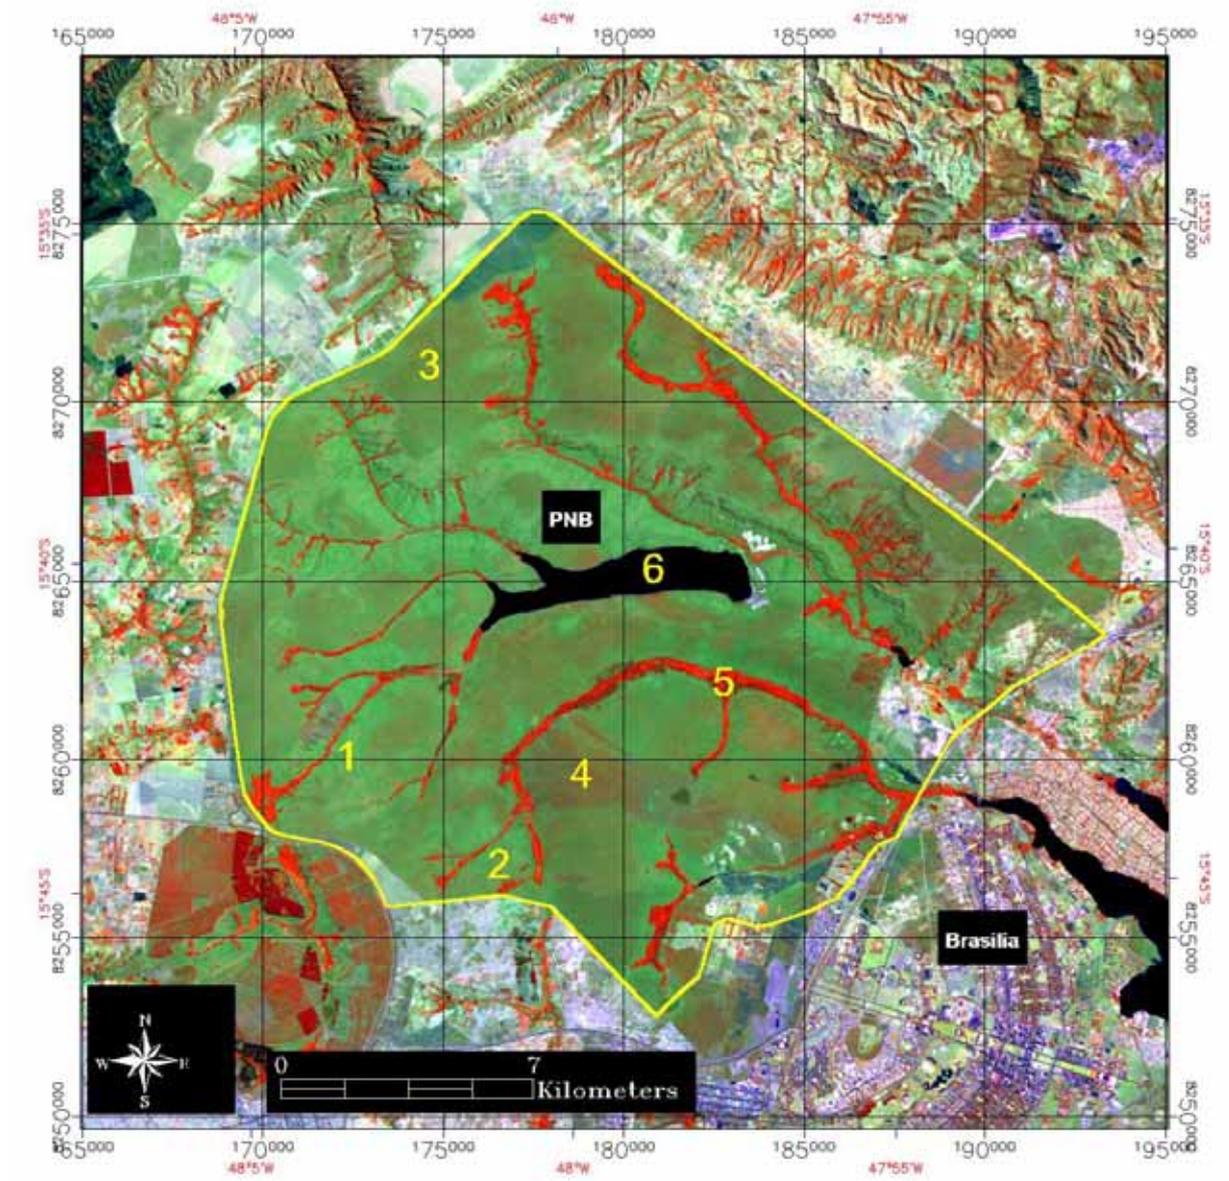
$$1 \geq x_j \geq 0 \text{ e } \sum x_j = 1 \quad (3)$$

onde:

$r_i$  = reflectância espectral observada na banda  $i$  de um *pixel*, contendo um ou mais componentes (*endmembers*);  $a_{ij}$  = reflectância espectral do componente  $j$  para a banda espectral  $i$ ;  $x_j$  = proporção do componente  $j$  (*endmember*) dentro de um *pixel*;  $e_i$  = erro para a banda  $i$  (contribuição residual não considerada pelo conjunto de *endmembers*);  $j = 1, 2, 3, \dots, n$  (número de componentes);  $i = 1, 2, 3, \dots, n$  (número de bandas espectrais).

### 3 - MATERIAIS E MÉTODOS

No intuito de avaliar o uso do MLME para o mapeamento do Cerrado, o modelo foi aplicado numa cena multiespectral (221 / 71) obtida pelo sensor Landsat 7 ETM+ (bandas 1-5 e 7) em 20 de julho de 2001 (estação seca). A área-teste foi o Parque Nacional de Brasília (PNB), situada ao norte do Distrito Federal, entre 15° 35' - 15° 45' latitude sul e 47° 53' - 48° 05' longitude oeste. Trata-se de uma área relativamente extensa e preservada, com aproximadamente 30.000 ha, bastante representativa das principais fitofisionomias de Cerrado (Campo Limpo, Campo Sujo, Cerrado Ralo e Cerrado Típico) (Figura 5).



**Figura 5.** Parque Nacional de Brasília. Imagem Landsat 7 ETM + (221 / 71), composição colorida RGB 453, julho de 2001 (estação seca). Os números 1 a 6 indicam, respectivamente, a presença de Campo Limpo, Campo Sujo, Cerrado Ralo, Cerrado Típico, Mata de Galeria e Água (Represa Santa Maria). Trechos mais claros (cor branca) na área interna do Parque indicam a presença de solo exposto.

A imagem original foi processada pela Transformação MNF, agrupando-se os dados inerentes à mesma, ao mesmo tempo em que os ruídos da cena foram também separados. Dessa forma, os dados originais foram concentrados em duas novas bandas (MNF 1 e MNF 2). Procedeu-se, então, com a coleta de quatro *endmembers* (espectros dos componentes puros): Campo Limpo, Mata Galeria, Solo exposto, Água / Sombra (Figura 6). A Equação 4 refere-se ao modelo MLME aplicado na imagem em questão.

$$R_i = A \times \text{Mata Galeria } i + B \times \text{Solo } i + C \times \text{Campo Limpo } i + D \times \text{Água / Sombra } i + \text{Erro } i \quad (4)$$

onde:  $R_i$  = resposta espectral do pixel na banda  $i$ ;  $A$  = proporção de Mata Galeria;  $B$  = proporção de Solo;  $C$  = proporção de Campo Limpo;  $D$  = proporção de Água;  $\text{Mata Galeria } i$  = resposta espectral do componente Mata Galeria na banda  $i$ ;  $\text{Solo } i$  = resposta espectral do componente solo na banda  $i$ ;  $\text{Campo Limpo } i$  = resposta espectral de Campo Limpo na banda  $i$ ;  $\text{Água / Sombra } i$  = resposta espectral do componente água / Sombra na banda  $i$ ;  $\text{Erro } i$  = erro na banda  $i$ ;  $i$  = bandas Landsat (1 - 5 e 7).

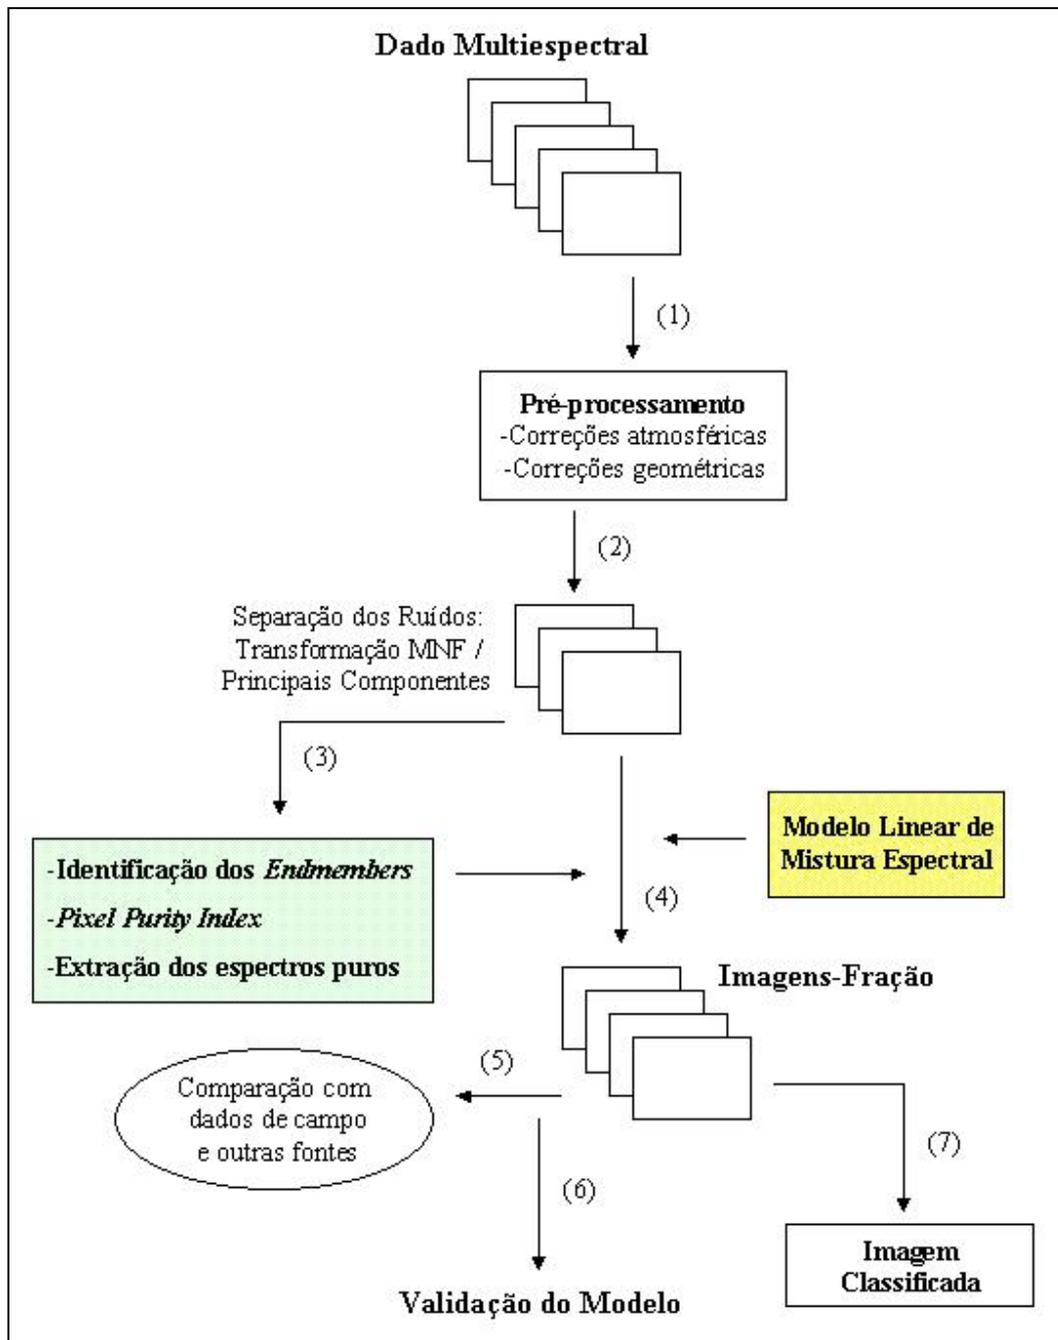


Figura 6. Esquema-resumo para aplicação do MLME na imagem do PNB. Modificado de Bajjouk et al. (1998).

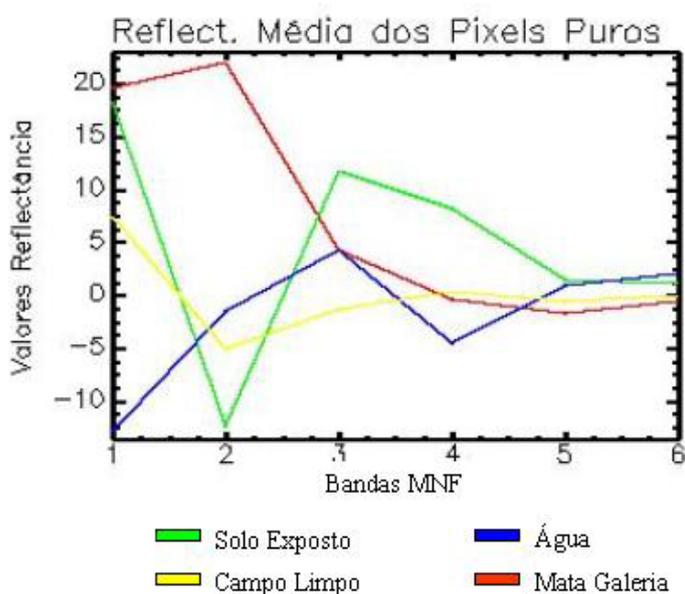
#### 4 - RESULTADOS PRELIMINARES E CONCLUSÕES

A aplicação do *Minimum Noise Fraction* (MNF) na imagem multiespectral, antecedendo as demais etapas do MLME, otimizou a identificação de *endmembers*, assim como a geração de imagens-fração, reduzindo o tempo de análise computacional. A técnica *Pixel Purity Index* (PPI), outra ferramenta útil na obtenção de *endmembers*, promoveu uma visualização e coleta mais eficiente dos chamados *pixels*

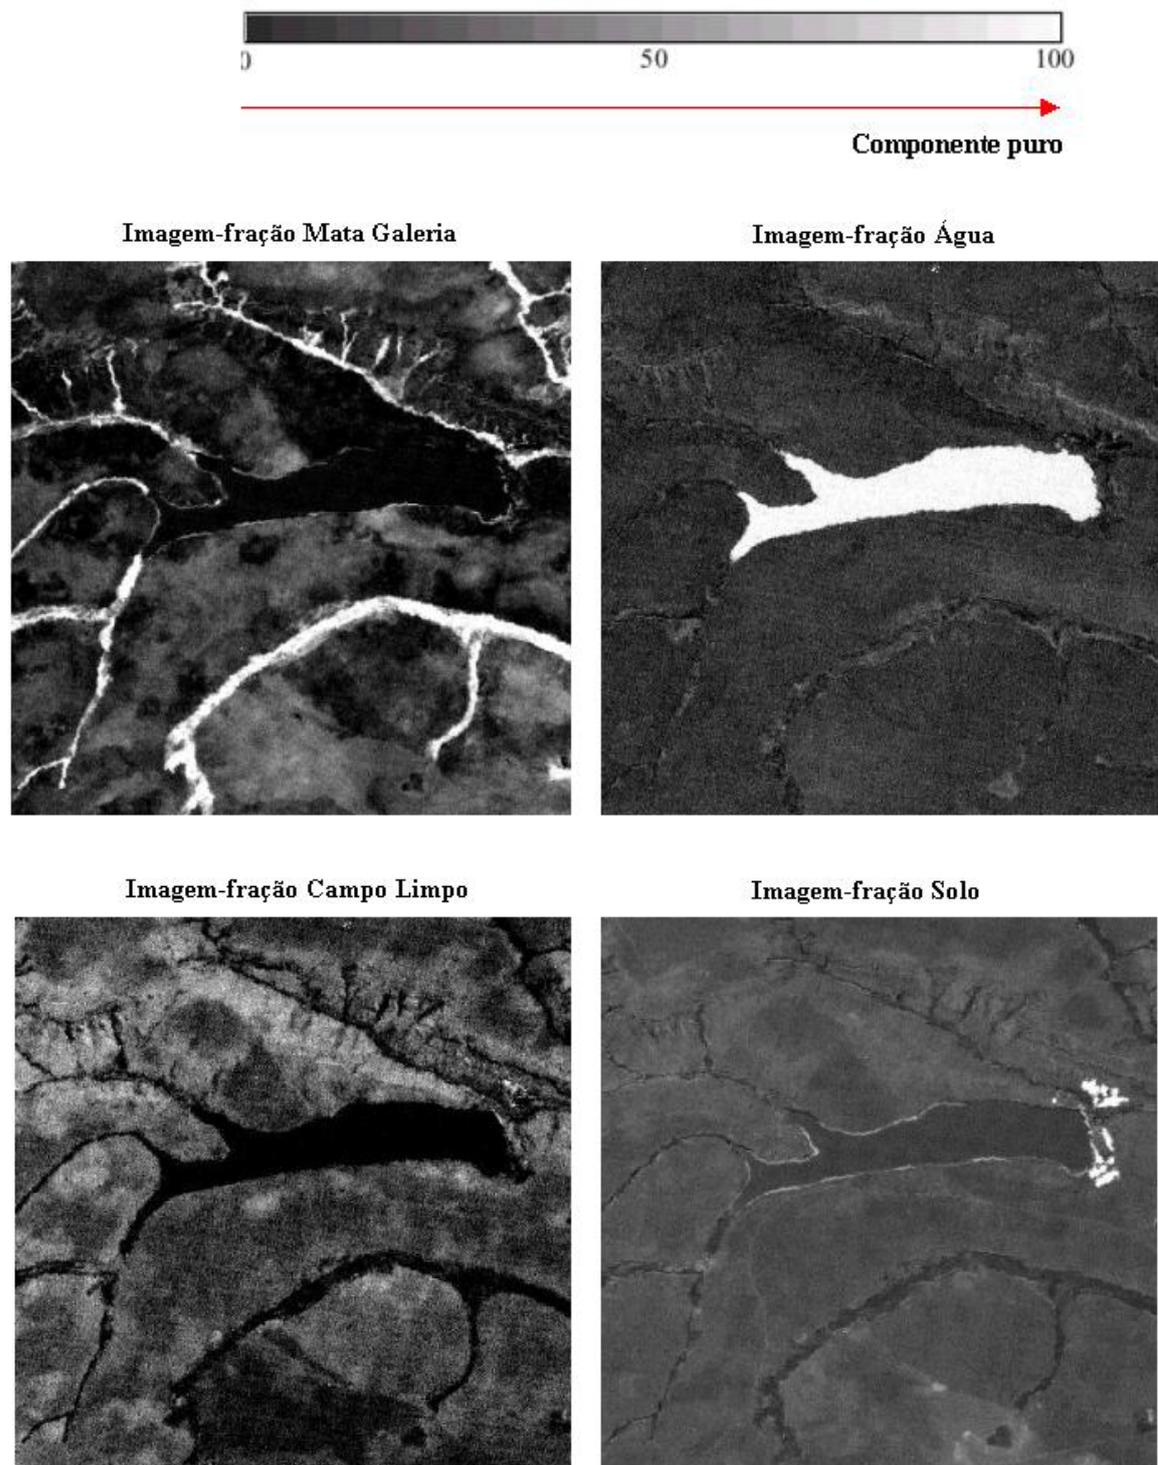
puros. A figura 7 ilustra as curvas de reflectância média utilizadas no MLME, correspondendo aos 4 componentes analisados.

O Modelo Linear de Mistura Espectral, juntamente com a utilização do método *Constrained Least Square* (CLS) (Equação 2), contribuiu para uma melhor discriminação da vegetação densa / componentes florestais (Mata de Galeria), com valores próximos a 1 nas imagens-fração (áreas mais claras), em acordo com os dados de campo. Resultados semelhantes foram observados para os componentes Solo exposto e Água / Sombra, com valores próximos a 1. O componente gramíneo (Campo Limpo) foi subestimado, apresentando imagens-fração com valores em torno de 0.7. A figura 8 ilustra as imagens-fração dos respectivos componentes analisados.

Nossos resultados, embora preliminares e não-conclusivos, indicam o potencial do MLME para mapear este complexo bioma, marcado por misturas espectrais significantes, particularmente nas fitofisionomias com baixa biomassa (Campo Limpo e Campo Sujo). O uso de curvas espectrais puras (*endmembers*), coletadas na própria imagem (na escala de reflectância aparente), possibilita a geração de imagens-fração dos componentes abordados, assim como a análise de suas respectivas proporções ao nível de *subpixel*.



**Figura 7.** Curvas de reflectância média dos componentes extraídos das imagens MNF.



**Figura 8.** Imagens-fração dos componentes Mata Galeria, Campo Limpo, Água e Solo Exposto, presentes no Parque Nacional de Brasília.

## AGRADECIMENTOS

Agradecimentos à Fundação de Empreendimentos Científicos e Tecnológicos - FINATEC, a qual viabilizou a participação no "X Latin American Symposium on Remote Sensing" - SELPER, Bolívia, e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq, pelo suporte a esta pesquisa.

## REFERÊNCIAS

- Abrams, M. 2000. The Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER): data products for the high spatial resolution imager on NASA's Terra platform. *International Journal of Remote Sensing*, 21: 847-859.
- Bajjouk, T.; Populus J.; Guillaumont, B. 1998. Quantification of subpixel cover fractions using principal component analysis and a linear programming method: application to the Coastal Zone of Roscoff (France). *Remote Sensing of Environmental*, 64:153-165.
- Bryant, R.G. 1996. Validated linear mixture modeling of Landsat TM data for mapping evaporite minerals on a playa surface: methods and applications. *International Journal of Remote Sensing*, vol. 17, 2: 315-330.
- Crósta, A.P. *Processamento de imagens digitais de sensoriamento remoto*. Campinas - SP: IG/UNICAMP, 1993. 170p.
- Ferreira, L.G.; Yoshioka, H.; Huete, A.R.; Sano, E.E. 2002. Seasonal landscape and spectral vegetation index dynamics in the Brazilian Cerrado: An analysis within the Large Scale Biosphere-Atmosphere Experiment in Amazonia (LBA). LBA special issue, *Remote Sensing of Environment (in press)*.
- Holben, B.N.; Shimabukuro, Y.E. 1993. Linear Mixing Model applied to coarse spatial resolution data from multispectral satellite sensors. *International Journal of Remote Sensing*, vol. 14, 2231-2240.
- Piwowar, J.M.; Derek R.P.; Le Drew, E. 1998. Temporal mixture analysis of Arctic Sea ice imagery: a new approach for monitoring environmental change. *Remote Sensing of Environmental*, 63:195-207.
- Rogan, J.; Franklin, J.; Roberts, D.A. 2002. A comparison of methods for monitoring multitemporal vegetation change using Thematic Mapper imagery. *Remote Sensing of Environmental*, 80: 143-156.
- Sano, E.E. Pinheiro, G.G.C. e Meneses, P.R. 2000. Assessing JERS-1 synthetic aperture radar data for vegetation mapping in the Brazilian savanna. *Journal of the Remote Sensing Society of Japan (in press)*.
- Schowengerdt, R. A. *Remote sensing: models and methods for image processing*. San Diego: Academic Press, 2<sup>nd</sup> ed., 1997. 522p.
- Schweik, C.M.; Green, G.M. 1999. The use of spectral mixture analysis to study human incentives, actions, and environmental outcomes. *Social Science Computer Review*. Thousand Oaks 17 (1): 40-63.
- Shimabukuro, Y.E.; Novo, E.M.; Ponzoni, F.J. 1998. Índice de vegetação e modelo linear de mistura espectral no monitoramento da região do Pantanal. *Pesquisa Agropecuária Brasileira*: Brasília, vol. 33, número especial, p. 1729-1737.
- Shimazaki, Y.; Tateishi, R. 2001. Land cover mapping using spectral and temporal linear mixing model at Lake Baikal Region. 22<sup>nd</sup> Asian Conference on Remote Sensing. 5 - 9 November 2001, Singapore.
- Verhoeve, J.; De Wulf, R. 2002. Land cover mapping at sub-pixel scales using linear optimization techniques. *Remote Sensing of Environmental*, 79: 96-104.
- Zhu, L.; Tateishi, R. 2001. Application of linear mixture model to time series AVHRR NDVI data. 22<sup>nd</sup> Asian Conference on Remote Sensing. 5 - 9 November 2001, Singapore.

**ANEXO C - Bibliografia atualizada, relacionada com o Modelo Linear de Mistura Espectral no estudo da vegetação.**

ADAMS, J. B.; SABOL JÚNIOR, D. E.; KAPOS, V.; ALMEIDA FILHO, R.; ROBERTS, D. A. R.; SMITH, M. O.; GILLESPIE, A. R. Classification of multispectral images based on fraction of endmembers: application to land-cover change in the Brazilian Amazon. **Remote Sensing of Environment**, New York, v. 52, p. 137-154, 1995.

ADAMS, J. B.; SMITH, M. O.; GILLESPIE, A. R. Simple models for complex natural surfaces: a strategy for the hyperspectral era of remote sensing. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS 89). **Proceedings...** [S. l. : s. n.], 1989. p. 16-21.

AGUIAR, A. P. D.; SHIMABUKURO, Y. E.; MASCARENHAS, N. D. A. Use of synthetic bands derived from mixing models in the multispectral classification of remote sensing images. **International Journal of Remote Sensing**, Londres, v. 20, n. 4, p. 647-657, 1999.

ASNER, G. P.; LOBELL, D. B. A biogeophysical approach for automated SWIR unmixing of soils and vegetation. **Remote Sensing of Environment**, New York, v. 74, p. 99-112, 2000.

BAJJOUK, T.; POPULUS, J.; GUILLAUMONT, B. Quantification of subpixel cover fractions using principal component analysis and a linear programming method: application to the Coastal Zone of Roscoff (France). **Remote Sensing of Environment**, New York, v. 64, p. 153-165, 1998.

BAPTISTA, G. M. M. **Mapeamento e quantificação da relação mineralógica caulinita/(caulinita+gibbsita) de solos tropicais, por meio dos dados do sensor hiperespectral AVIRIS (JPL/NASA)**. 2001. 139 f. Tese (Doutorado) – Universidade de Brasília, Brasília.

BOARDMAN, J. W.; KRUSE, F. A. Automated spectral analysis: a geological example using AVIRIS data, north Grapevine Mountains, Nevada. In: THEMATIC CONFERENCE ON GEOLOGIC REMOTE SENSING, 10., 1994, Ann Arbor, MI. **Proceedings...** Ann Arbor: ERIM, 1994. v. 1, p. 407-418.

BOARDMAN, J. W.; KRUSE, F. A.; GREEN, R. O. Mapping target signatures via partial unmixing of AVIRIS data. In: GREEN, R. O. (ed.), **Summaries of the Fifth JPL Airborne Earth Science Workshop**. Pasadena: NASA/JPL, 1995, v. 1, p. 23-26 (JPL Publication, 95-1).

BRYANT, R. G. Validated linear mixture modeling of Landsat TM data for mapping evaporite minerals on a playa surface: methods and applications. **International Journal of Remote Sensing**, Londres, v. 17, n. 2, p. 315-330, 1996.

CARVALHO, O. A. **Avaliação e desenvolvimento de métodos de processamento de imagens hiperespectrais**: análise em depósito de níquel (Niquelândia, GO). 2000. 241 f. Tese (Doutorado) – Universidade de Brasília, Brasília.

COCHRANE, M. A.; SOUZA, C. M. Linear mixture model classification of burned forest in the Eastern Amazon. **International Journal of Remote Sensing**, Londres, v. 19, n. 17, p. 3433-3440, 1998.

COCHRANE, M. A.; ALENCAR, A.; SCHULZE, M. D.; SOUZA JÚNIOR, C. M.; NEPSTAD, D. C.; LEFEBVRE, P.; DAVIDSON, E. A. Positive feedbacks in the fire dynamics of closed canopy tropical forests. **Science**, v. 284, p. 1832-1834, June 1999.

CROSS, A. M.; SETTLE, J. J.; DRAKE, N. A.; PAIVINEN, R. T. M. Subpixel measurement of tropical forest cover using AVHRR data. **International Journal of Remote Sensing**, Londres, v. 12, n. 5, p.1119-1129, 1991.

DEFRIES, R. S.; HANSEN, M. C.; TOWSHEND, J. R. G. Global continuous fields of vegetation characteristics a linear mixture model applied to multi-year 8 km AVHRR data. **International Journal of Remote Sensing**, Londres, v. 21, n. 6- 7, p. 1389-1414, 2000.

DETMENDY, D. M.; PACE, W. H. A model for spectral signature variability for mixtures. In: SHAHROKHI, F. (Ed.). **Remote Sensing of Earth Resources**. Tullahoma: University of Tennessee, 1972. v. 1, p. 596-620.

DRAKE, N. A.; MACKIN, S.; SETTLE, J. J. Mapping vegetation, soils, and geology in semiarid shrublands using spectral matching and mixture modeling of SWIR AVIRIS imagery. **Remote Sensing of Environment**, New York, v. 68, p. 12-25, 1999.

EERENS, H.; KEMPENEERS, P.; PICCARD, I.; VERHEIJEN, Y. Crop Monitoring and Yield Forecasting with NOAA-AVHRR or SPOT-VEGETATION. **Vlaamse Instelling voor Technologisch Onderzoek** (VITO), Belgium, Expertisecentrum voor Teledetectie & Atmosferische Processen (TAP), 2000.

FARRAND, H. W. Sub-pixel detection and mapping of spectrally unique materials on Mars using ISM data. In: WORKSHOP ON SPECTROSCOPY OF THE MARTIAN SURFACE. **What next?** Houston: Lunar and Planetary Institute, 1999. p. 10-11.

FARRAND, W. H.; GADDIS, L. R. Subpixel detection of pyroclastic materials in Clementine UVVI data. In: WORKSHOP ON NEW VIEWS OF THE MOON II: UNDERSTANDING THE MOON THROUGH THE INTEGRATION OF DIVERSE DATASET. Flagstaff, AZ, 1999. p. 22-24.

FARAKLIOTI, M.; PETROU, M. Recovering more classes than available bands for sets of mixed pixels in satellite images. **Image and Vision Computing**, v. 18, p. 705-713, 2000.

FERREIRA, M. E.; FERREIRA, L. G.; SANO, E. E.; SHIMABUKURO, Y. E. Uso do modelo linear de mistura espectral para o mapeamento sistemático e operacional do bioma cerrado: possibilidades, implicações e procedimentos metodológicos. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., 2003, Belo Horizonte, MG. **Anais...** São José dos Campos: INPE, 2003. p. 657-664.

FERREIRA, M. E.; SANO, E. E.; FERREIRA, L. G.; MENESES, P. R. Preliminary insights on the use of a linear mixture model for vegetation mapping in the Brazilian Cerrado. In: SIMPOSIO LATINOAMERICANO DE PERCEPCIÓN REMOTA Y SISTEMAS DE INFORMACIÓN ESPACIAL, 10., 2002, Cochabamba, Bolívia. **Anais...** Bogotá: SELPER, 2002. 1 CD-ROM.

FOODY, G. M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, New York, v. 80, p. 185-201, 2002.

GALVÃO, L. S. Métodos para análise de espectros de reflectância. In: MENESES, P. R.; MADEIRA NETTO, J.S. (Org.). **Sensoriamento remoto: reflectância dos alvos naturais**. Brasília: UnB; Planaltina, DF: Embrapa Cerrados, 2001. cap. 7, p. 225-247.

GALVÃO, L. S. Espectro e imagens. In: MENESES, P. R.; MADEIRA NETTO, J. S. (Org.). **Sensoriamento remoto: reflectância dos alvos naturais**. Brasília: UnB; Planaltina, DF: Embrapa Cerrados, 2001. cap. 8, p. 251-262.

GARCÍA-HARO, F. J.; GILABERT, M. A.; MELIÁ, J. Extraction of endmembers from spectral mixtures. **Remote Sensing of Environment**, New York, v. 68, p. 237-253, 1999.

GILABERT, M. A.; GARCÍA-HARO, F. J.; MELIÁ, J. A mixture modeling approach to estimate vegetation parameters for heterogeneous canopies in remote sensing. **Remote Sensing of Environment**, New York, v. 72, p. 328-345, 2000.

GOETZ, A. F. H.; KINDEL, B. Comparison of unmixing results derived from AVIRIS, high and low resolution, and HYDICE images at Cuprite, NV. In: GREEN, R.O. (ed.), **Summaries of the Eighth JPL Airborne Earth Science Workshop**. Pasadena: NASA/JPL, 1999, v. 1, p. 151-159 (JPL Publication, 99-17).

GREEN, R. O.; CRAIG, M. D. Analysis of aircraft spectrometer data with logarithmic residuals. In: GREEN, R.O. (ed.), **Summaries of the First JPL Airborne Earth Science Workshop**. Pasadena: NASA/JPL, 1985, v. 1, p. 111-119 (JPL Publication, 85-41).

HOLBEN, B. N.; SHIMABUKURO, Y. E. Linear mixing model applied to coarse spatial resolution data from multispectral satellite sensors. **International Journal of Remote Sensing**, Londres, v. 14, p. 2231-2240, 1993.

HORNSTRA, T.; MAAS, H-G.; DE JONG, S. **Classification of spectroscopical imagery by combining spatial and spectral information: the SSC method**. Amsterdam: ISPRS, v. 33, 2000.

HOROWITZ, H. M.; NALEPKA, R. F.; HYDE, P. D.; MORGANSTERN, J. P. **Estimating the proportion of objects within a single resolution element of a multispectral scanner.** Ann Arbor: University of Michigan, 1971. Contract NAS-9-9784.

HUANG, C.; TOWNSHEND, J. R. G.; LIANG, S.; KALLURI, S. N. V.; DEFRIES, R. S. Impact of sensor's point spread function on land cover characterization: assessment and deconvolution. **Remote Sensing of Environment**, New York, v. 80, p. 203-212, 2002.

KAUTH, R. J.; LAMBEK, P. F.; RICHARDSON, W.; THOMAS, G. S.; PENTLAND, A. P. Feature extraction applied to agricultural crops as seen by Landsat. In: LACIE SYMPOSIUM, 1979, Houston, TX. **Proceedings...** Houston: NASA, p. 705-721, 1979.

KERDILES, H.; GRONDONA, M. O. NOAA-AVHRR NDVI decomposition and subpixel classification using linear mixing in the Argentina Pampa. **International Journal of Remote Sensing**, London, v. 16, n. 7, p. 1303-1325, 1995.

KLINK, C. A. Relação entre o desenvolvimento agrícola e a biodiversidade. In: PEREIRA, R.C.; NASSES, L.C.B. (Ed.). SIMPÓSIO INTERNACIONAL DE SAVANAS TROPICAIS, 1., 1996, Brasília. **Biodiversidade e produção sustentada de alimentos e fibras no Cerrados.** Brasília: DF, Embrapa- CPAC, 1996. p. 25-27.

KRUSE, F. A.; HUNTINGTON, J. H. The 1995 AVIRIS geology group shoot. In: GREEN, R.O. (ed.), **Summaries of the Sixth JPL Airborne Earth Science Workshop.** Pasadena: NASA/JPL, 1996, v. 1, p. 155-166 (JPL Publication, 96-4).

KRUSE, F. A.; HUNTINGTON, J. H.; GREEN, R. O. Results from the 1995 AVIRIS geology group shoot: In: INTERNATIONAL AIRBORNE REMOTE SENSING CONFERENCE AND EXHIBITION, 2., 1996, Ann Arbor, MI. **Proceedings...** Ann Arbor: ERIM, 1996. v. 1, p. 211-220.

KUSTAS, W. P.; NORMAN, J. M. Evaluating the effects of subpixel heterogeneity on pixel average fluxes. **Remote Sensing of Environment**, New York, v. 74, p. 327-342, 2000.

LOBELL, D. B.; ASNER, G. P.; LAW, B. E.; TREUHAFT, R. N. Subpixel canopy cover estimation of coniferous forests in Oregon using SWIR imaging spectrometry. **Journal of Geophysical Research**, v. 106 (D6), p. 5151-5160, 2001.

LOBELL, D. B.; ASNER, G. P.; LAW, B. E., TREUHAFT, R. N. View angle effects on canopy reflectance and spectral mixture analysis of coniferous forests using AVIRIS. **International Journal of Remote Sensing**, v. 23, n.11, p. 2247-2262, 2002

MASELLI, F. Definition of spatially variable spectral endmembers by locally calibrated multivariate regression analyses. **Remote Sensing of Environment**, v. 75, p. 29-38, 2001.

MARTIN, E. W. Measurement of Impervious Surface Area from Landsat Thematic Mapper Data using Spectral Mixture Analysis. Seattle: CommEn Space (The Community and Environment Spatial Analysis Center), **Proceedings...** March 2000. Disponível em: [www.commenspace.org](http://www.commenspace.org). Acesso em: 11 de abril 2003.

MAAS, S. J. Linear mixture modeling approach for estimating cotton canopy ground cover using satellite multispectral imagery. **Remote Sensing of Environment**, New York, v. 72, p. 304-308, 2000.

MAUSEL, P. W. Characteristics and techniques of computer-assisted processing of spectral data. In: HOLZ, R.K. (Ed.). **The surveillant sciense: remote sensing of environment**. 2. ed. New York: John Wiley & Sons, 1985. 413 p.

MCGWIRE, K.; MINOR, T.; FENSTERMAKER, L. Mixture Modeling for quantifying sparse vegetation cover in arid environments. **Remote Sensing of Environment**, New York, v. 72, n. 360-374, 2000.

MIURA, T.; HUETE, A.R.; FERREIRA, L.G.; SANO, E.E. Discrimination and biophysical characterization of Cerrado physiognomies with EO-1 hyperspectral Hyperion. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., 2003, Belo Horizonte, MG. **Anais...** São José dos Campos: INPE, 2003. p.1077-1082.

MULDER, N. J.; ABKAR, A. A. A comparison of least-squares and Bayesian minimum risk edge parameter estimation. **Pattern Recognition Letters**, v. 20, p. 1397-1405, 1999.

NOLIN, A. W.; FARRAND, W. H. Multispectral mapping of the Martian polar caps. In: INTERNATIONAL CONFERENCE ON MARS, 1999, Pasadena, CA. **Proceedings...** Pasadena: [s.n.], 1999.

NOVO, E. M.; SHIMABUKURO, Y. E. Spectral mixture analysis of inland tropical waters. **International Journal of Remote Sensing**, London, v. 15, n. 6, p. 1351-1356, 1994.

NOVO, E. M.; SHIMABUKURO, Y. E. Identification and mapping of the Amazon habitats using a mixing model. **International Journal of Remote Sensing**, v. 18, n. 3, p. 663-670, 1997.

OKIN, W. J.; OKIN, G. S.; ROBERTS, D. A.; MURRAY, B. **Multiple endmember spectral mixture analysis**: endmember choice in an arid shrub land. [S.l.]: University of California, 1999.

PAINTER, T. H.; ROBERTS, D. A.; GREEN, R. O.; DOZIER, J. Automated subpixel snow parameter mapping with AVIRIS data. In: GREEN, R.O. (ed.), **Summaries of the Seventh JPL Airborne Earth Science Workshop**. Pasadena: NASA/JPL, 1998.

PENN, B. S. Using simulated annealing to obtain optimal linear end-member mixtures of hyperspectral data. **Computer and Geosciences** (*in press*).

PIWOWAR, J. M.; DEREK, R. P.; LEDREW, E. Temporal mixture analysis of Arctic Sea ice imagery: a new approach for monitoring environmental change. **Remote Sensing of Environment**, New York, v. 63, p.195-207, 1998.

RADELOFF, V. C.; MLADENOFF, D. J.; BOYCE, M. S. Detecting jack pine budworm defoliation using spectral mixture analysis: separating effects from determinants. **Remote Sensing of Environment**, New York, v. 69, p.156-169, 1999.

RAY, T. W.; MURRAY, B. C. Nonlinear spectral mixing in desert vegetation. **Remote Sensing of Environmental**, New York, v. 55, n. 59-64, 1996.

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**, New York, v. 65, p. 267-279, 1998.

ROBERTS, D. A.; YAMAGUCHI, Y.; LYON, R. J. P. Calibration of airborne imaging spectrometer data to percent reflectance using field measurements. In: INTERNATIONAL SYMPOSIUM ON REMOTE SENSING OF ENVIRONMENT, 19., 1985, Ann Arbor, MI. **Proceedings...** Ann Arbor: [s.n.], 1985.

ROGAN, J.; FRANKLIN, J.; ROBERTS, D. A. A comparison of methods for monitoring multitemporal vegetation change using Thematic Mapper imagery. **Remote Sensing of Environment**, New York, v. 80, p. 143-156, 2002.

SABOL JÚNIOR, D. E.; GILLESPIE, A. R.; ADAMS, J. B.; SMITH, M. O.; TUCKER, C. J. Structural stage in Pacific Northwest forest estimated using simple mixing models of multispectral images. **Remote Sensing of Environment**, New York, v. 80, p. 1-16, 2002.

SCHOWENGERDT, R. A. **Remote sensing: models and methods for image processing**. 2. ed. San Diego: Academic Press, 1997. 522 p.

SCHWEIK, C. M.; GREEN, G. M. The use of spectral mixture analysis to study human incentives, actions, and environmental outcomes. **Social Science Computer Review**, Thousand Oaks, v. 17, n. 1, p. 40-63, 1999.

SHIMABUKURO, Y. E.; DUARTE, V.; MELLO, E. M. K.; MOREIRA, J. C. **Apresentação da metodologia de criação do PRODES digital**. São José dos Campos: INPE, 2000. 36 p. (INPE-7520-PUD/41).

SHIMABUKURO, Y. E.; MELLO, E. M. K.; MOREIRA, J. C.; DUARTE, V. **Segmentação e classificação da imagem sombra do modelo de mistura para mapear desflorestamento na Amazônia**. São José dos Campos: INPE, 1997, 16 p. (INPE-6147-PUD/029).

SHIMABUKURO, Y. E.; NOVO, E. L. M.; MERTES, L. K. Amazon river mainstream floodplain Landsat TM digital mosaic. **International Journal of Remote Sensing**, Londres, v. 23, n. 1, p. 57-69, 2002.

SHIMABUKURO, Y. E.; NOVO, E. L. M.; PONZONI, F. J. Índice de vegetação e modelo linear de mistura espectral no monitoramento da região do Pantanal. **Pesquisa Agropecuária Brasileira**, Brasília, v. 33, p. 1729-1737, 1998.

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**, New York, v. 29, n. 1, 1991.

SHIMABUKURO, Y. E.; SMITH, J. A. Fraction images derived from Landsat TM and MSS data for monitoring reforested areas. **Canadian Journal of Remote Sensing**, Ottawa, v. 21, n. 1, p. 67-74, 1995.

SHIMAZAKI, Y.; TATEISHI, R. Land cover mapping using spectral and temporal linear mixing model at Lake Baikal Region. In: ASIAN CONFERENCE ON REMOTE SENSING, 22., 2001, Singapura. **Proceedings...** Singapura: [s.n.], 2001.

SMALL, C. Estimation of urban vegetation abundance by spectral mixture analysis. **International Journal of Remote Sensing**, London, v. 22, n. 7, p. 1305-1334. 2001.

SMITH, M. O.; USTIN, S. L.; ADAMS, J. B.; GILLESPIE, A. R. Vegetation in desert: I. A regional measure of abundance from multispectral images. *Remote Sensing of Environmental*, New York, v. 31, p. 1-26. 1990

SOMMER, S.; HILL, J.; MÉGIER, J. The potential of remote sensing for monitoring rural land use changes and their effects on soil conditions. **Agriculture, Ecosystems and Environment**, v. 67, p. 197-209, 1998.

SOUZA JÚNIOR, C.; BARRETO, P. An alternative approach for detecting and monitoring selectively logged forest in the Amazon. **International Journal of Remote Sensing**, Londres, vol. 21, n. 1, p. 173-179, 2000.

STAID, M.; PIETERS, C. M. A re-evaluation of lunar basalt types through spectral analysis of fresh mare craters. In: LUNAR AND PLANETARY SCIENCE CONFERENCE, 29., 1998, Houston, TX. **Proceedings...** Houston: [s.n.], 1998.

SZYMANSKI, J. J.; BOREL, C. C.; HARBERGER, Q. O.; SMOLARKIEWICZ, P.; THEILER, J. Subpixel temperature retrieval with multispectral sensors. Presented at Algorithms for Multispectral & Hyperspectral Imagery (SPIE 3717), **Aerosense 99**, Orlando, FL, April, 1999.

TAN, Q., LIN, H. Vegetation spectral feature extraction model. GISdevelopment.net, Asian Association on Remote Sensing (AARS) / Asian Conference on Remote Sensing (ACRS), Hyperspectral & Data Acquisition Systems, 2000. Disponível em: <http://www.gis/development/aars/acrs/2000>. Acesso em: 17 de dezembro 2002.

TSENG, YI-HSING. Spectral mixture analysis of hyperspectral data. GISdevelopment.net, Asian Association on Remote Sensing (AARS) / Asian Conference on Remote Sensing (ACRS), Hyper Spectral Image Processing, 1999. Disponível em: <http://www.gis/development/aars/acrs/1999>. Acesso em: 17 de dezembro de 2002.

VERHOEYE, J.; DE WULF, R. Land cover mapping at sub-pixel scales using linear optimization techniques. **Remote Sensing of Environmental**, New York, v. 79, p. 96-104, 2002.

VERONA, J. D.; SHIMABUKURO, Y. E.; SANTOS, J. R. Detecção de mudanças em áreas sob influência da Floresta Nacional do Tapajós-PA, utilizando o modelo linear de mistura espectral. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 10., 2001, Foz do Iguaçu-PR. **Anais...** São José dos Campos: INPE, 2001. p. 1773-1780.

ZHU, L.; TATEISHI, R. Application of linear mixture model to time series of AVHRR NDVI data. In: ASIAN CONFERENCE ON REMOTE SENSING, 22., 2001, Singapura. **Anais...** Singapura: [s.n.], 2001.

**ANEXO D - Novo mapa de vegetação do Parque Nacional de Brasília (PNB), impresso no tamanho A3.**