



**UNIVERSIDADE DE BRASÍLIA  
INSTITUTO DE GEOCIÊNCIAS**

**Análise do Modelo Linear de Mistura Espectral na  
Discriminação de Fitofisionomias do Parque Nacional  
de Brasília (Bioma Cerrado)**

**DISSERTAÇÃO DE MESTRADO N° 172**

**MANUEL EDUARDO FERREIRA**

**Brasília, DF**

**2003**

UNIVERSIDADE DE BRASÍLIA  
INSTITUTO DE GEOCIÊNCIAS

Análise do Modelo Linear de Mistura Espectral na  
Discriminação de Fitofisionomias do Parque Nacional de  
Brasília (Bioma Cerrado)

DISSERTAÇÃO DE MESTRADO Nº 172

MANUEL EDUARDO FERREIRA

Orientador:

Dr. Edson Eyji Sano (Embrapa Cerrados)

Examinadores:

Dr. Paulo Roberto Meneses (IG - UnB)

Dr. Yosio Edemir Shimabukuro (INPE)

Brasília, DF

Maio de 2003

Dissertação Submetida ao Instituto de Geociências, Departamento de Geologia Geral e  
Aplicada da Universidade de Brasília, em cumprimento a requisito parcial para  
obtenção do Título de Mestre em Geologia

Autor:

Manuel Eduardo Ferreira

Banca Examinadora:

Dr. Edson Eyji Sano

---

Orientador

Dr. Paulo Roberto Meneses

---

Membro da Banca

Dr. Yosio Edemir Shimabukuro

---

Membro da Banca

Brasília, DF  
20 de maio de 2003

## AGRADECIMENTOS

Ao exímio pesquisador e amigo Dr. Edson Eyji Sano, por sua orientação, suporte e ensinamentos, essenciais na concretização desta etapa.

Ao pesquisador Dr. Paulo Roberto Meneses que, com sabedoria e clareza, despertou-me o interesse pelo Sensoriamento Remoto, repassando-me, desde os tempos da graduação, os fundamentos desta ciência.

Ao pesquisador Dr. Yosio Edemir Shimabukuro, pelas valiosas discussões sobre Modelo Linear de Mistura Espectral, e por compor, junto com o Dr. Paulo Roberto Meneses, a banca examinadora.

Ao pesquisador Dr. Laerte Guimarães Ferreira, pelos “insights”, discussões e companheirismo de sempre. Seu entusiasmo e rigor científico impulsionaram esta pesquisa.

Ao pesquisador Dr. George Eiten, pelas enriquecedoras discussões acerca da vegetação de Cerrado no Parque Nacional de Brasília.

Ao Instituto de Geociências - UnB, juntamente com o seu corpo docente, técnico e administrativo, que tão bem me acolheram e apoiaram neste período.

Ao Laboratório de Biofísica Ambiental da Embrapa - CPAC, em especial ao Heleno S. Bezerra, por seu apoio na atualização do mapa de vegetação do PNB.

À administração do Parque Nacional de Brasília, pelo apoio aos trabalhos de campo, em especial ao Elmo Monteiro (Chefe do PNB) e Christiane Horowitz.

Ao TBRS (Terrestrial Biophysics and Remote Sensing) - Universidade do Arizona, e LBA (*Large Scale Biosphere-Atmosphere Experiment in Amazonia*), pelos dados de sensoriamento remoto cedidos a esta pesquisa.

Aos colegas do Mestrado e Doutorado, companheiros nas longas jornadas de estudo.

Ao Conselho Nacional de Desenvolvimento Científico (CNPq), pelo fomento a esta pesquisa.

## DEDICATÓRIA

À minha família,  
em especial aos meus pais,  
Laerte Guimarães Ferreira e Libânia Rabello Ferreira,  
pela ética e perseverança a mim transmitida.

## SUMÁRIO

<b>LISTA DE FIGURAS.....</b>	<b>viii</b>
<b>LISTA DE TABELAS .....</b>	<b>xii</b>
<b>RESUMO.....</b>	<b>xiv</b>
<b>ABSTRACT .....</b>	<b>xv</b>
<b>CAPÍTULO 1 - INTRODUÇÃO .....</b>	<b>1</b>
1 - Considerações Iniciais.....	1
1.1 - Objetivos .....	4
<b>CAPÍTULO 2 - MODELO LINEAR DE MISTURA ESPECTRAL .....</b>	<b>5</b>
2.1 - MLME vs. Classificadores Convencionais .....	5
2.2 - MLME vs. Índices de Vegetação .....	8
2.3 - Fundamentos do Modelo Linear de Mistura Espectral .....	9
2.3.1 - Aplicações Gerais do MLME .....	15
2.3.2 - Etapas para Aplicação do MLME.....	18
<b>CAPÍTULO 3 - MATERIAIS E MÉTODOS .....</b>	<b>33</b>
3.1 - Área de Estudo .....	33
3.2 - Atualização do Mapa de Vegetação do PNB .....	40
3.3 - Geração das Imagens Fração.....	43
3.3.1 - Modelos Lineares.....	44
3.3.2 - Elaboração das Bibliotecas Espectrais ( <i>Imagem e Referência</i> ) .....	45
3.3.3 - Uso da Técnica de Fração de Ruído Mínimo ( <i>Minimum Noise Fraction</i> ).....	48
3.4 - Análise Estatística dos Dados .....	49
3.4.1 - Amostras .....	49

3.4.2 - Análise Discriminante e Separabilidade entre Classes.....	51
<b>CAPÍTULO 4 - RESULTADOS E DISCUSSÕES .....</b>	<b>53</b>
4.1 - Mapa de Vegetação Atualizado do PNB.....	53
4.2 - Potencial das Imagens Fração para o Mapeamento do Cerrado.....	57
4.2.1 - Modelo Linear Geral ( <i>vegetação, solo e sombra</i> ) .....	57
4.2.2 - Modelo Linear Específico.....	68
4.3 - Interferência Atmosférica no MLME.....	77
<b>CAPÍTULO 5 - CONSIDERAÇÕES FINAIS .....</b>	<b>80</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>85</b>
<b>ANEXOS.....</b>	<b>97</b>
<b>ANEXO A - Trabalho apresentado no XI SBSR (abril de 2003) .....</b>	<b>98</b>
<b>ANEXO B - Trabalho apresentado no X SELPER (nov. de 2002) .....</b>	<b>106</b>
<b>ANEXO C - Base bibliográfica sobre MLME e vegetação (1971-2003) .....</b>	<b>117</b>
<b>ANEXO D - Novo Mapa de Vegetação do PNB (tamanho A3) .....</b>	<b>127</b>

## LISTA DE FIGURAS

1.1 -	Estrutura vegetacional do Cerrado.....	2
1.2 -	Área ocupada pelo bioma Cerrado no Brasil, e a sua atual taxa de conversão motivada pela criação de pastagens e agricultura.....	3
2.1 -	Imagem do Parque Nacional de Brasília, submetida ao MLME (Imagem Fração <i>vegetação</i> ) e a uma classificação supervisionada ( <i>MaxVer</i> ). Na Imagem Fração, a variação na escala de cinza indica, de forma contínua, a proporção de um determinado alvo (ex. Mata de Galeria).....	7
2.2 -	Representação física de um <i>pixel</i> misturado, devido à presença de dois tipos de materiais no GIFOV do sensor .....	10
2.3 -	(a) O <i>pixel</i> (linha vermelha) se encontra na fronteira de alvos diferentes. (b) Diferentes materiais contidos em um único pixel .....	10
2.4 -	(a) Geometria de reflexão em um plantio. (b) Variação da radiância espectral em função dos diferentes ângulos zenitais (solares).....	11
2.5 -	Curvas de reflectância da vegetação verde, vegetação seca (não-fotossintética), solo exposto e água.....	12
2.6 -	Comportamento espectral de três classes de vegetação, típicas do bioma Cerrado: Cerrado <i>sensu stricto</i> , Campo Sujo e Campo Limpo, obtidas por espectrorradiometria de campo no Parque Nacional de Brasília (época seca). A área circulada indica a confusão espectral destas classes nas regiões do vermelho e infravermelho próximo .....	13
2.7 -	Imagens Fração <i>solo</i> , <i>vegetação</i> e <i>sombra</i> (água) do Parque Nacional de Brasília, com a respectiva imagem erro.....	15
2.8 -	Método geral, com as etapas obrigatórias (caixa tracejada na cor vermelha) e complementares, para a aplicação de um Modelo Linear de Mistura Espectral em dados multiespectrais ou hiperespectrais.....	19
2.9 -	Espectro solar com as bandas de absorção/interferência atmosférica .....	21
2.10 -	Influência da atmosfera na trajetória da radiação eletromagnética entre a fonte e o sensor .....	22
2.11 -	Representação gráfica da Análise por Componentes Principais em duas dimensões. Os eixos originais da imagem (bandas 1 e 2) são rotacionados, redistribuindo os <i>pixels</i> (elipse) sobre um novo sistema de eixos, formado pelas Componentes Principais 1 e 2 .....	25
2.12 -	Distribuição dos autovalores ( <i>eigenvalues</i> ) após realização da ACP e do MNF, para as bandas 1-5 e 7 do sensor ETM+ .....	27

2.13 - A primeira fileira de imagens corresponde às bandas 1-5 e 7 do sensor ETM+, Parque Nacional de Brasília (julho de 2001). A segunda fileira corresponde às imagens resultantes da ACP. A terceira fileira corresponde às imagens resultantes da transformação MNF. Note que os ruídos ficam segregados a partir da MNF 4 e da PC 5, enquanto que a dimensionalidade dos dados fica restrita para as primeiras MNFs e PCs .....	28
2.14 - Imagem resultante do <i>Índice de Pureza dos Pixels (Pixel Purity Index - PPI)</i> , representando <i>pixels</i> espectralmente puros, e sobreposição destes <i>pixels</i> após o uso de um limite mínimo e máximo, visando a seleção de <i>endmembers</i> em áreas específicas da imagem.....	29
2.15 - Distribuição dos <i>pixels</i> no espaço amostral vermelho-infravermelho próximo, onde a proximidade dos extremos favorece a busca por componentes espectralmente mais puros, como demonstrado pelo comportamento dos espectros.....	31
2.16 - <i>Simplex</i> de frações em um caso tridimensional, onde <i>Bf1</i> , <i>Bf2</i> e <i>Bf3</i> são as bases ortogonais para três <i>endmembers</i> , atendendo às restrições do método (Equação 2.7).....	32
3.1 - Imagem do Parque Nacional de Brasília (composição colorida RGB 543 julho de 2001), obtida pelo satélite Landsat 7 ETM+.....	34
3.2 - Mapa climático do PNB.....	35
3.3 - Dados de precipitação total (mm) no Parque Nacional de Brasília, para os anos de 2001 (azul) e 2002 (verde). Estação pluviométrica de Santa Maria - CAESB, Latitude Sul 15° 40' 00" e Longitude Oeste 47° 57' 57" .....	36
3.4 - Mapa de hidrografia do PNB e entorno.....	36
3.5 - Mapa de solos do PNB .....	38
3.6 - Mapa das unidades geológicas no PNB.....	39
3.7 - Cenas do satélite IKONOS cobrindo cerca de 61% da área do PNB (composição RGB 123).....	40
3.8 - Atualização do mapa de vegetação do PNB, por meio das cenas ETM+ e IKONOS .....	41
3.9 - Incursões no Parque Nacional de Brasília, durante a realização do novo mapa de vegetação (out./2002) .....	43
3.10 - Imagem ETM+ do Parque Nacional de Brasília, com e sem os alvos Mata de Galeria, solo exposto e água, seguida pela nova distribuição dos <i>pixels</i> no espaço vermelho (x) - infravermelho próximo (y) .....	46

3.11 - Biblioteca espectral referente ao modelo linear geral, para as imagens ETM+ Valor Digital e Reflectância.....	46
3.12 - Ilustração do espectrorradiômetro utilizado na pesquisa, modelo Field-Spec Pro FR (350 - 2500 nm), produzido pela Analytical Spectral Devices (ASD Inc.). .....	47
3.13 - Procedimentos realizados no Parque Nacional de Brasília para a análise das fitofisionomias Campo Limpo, Campo Sujo e Cerrado <i>sensu stricto</i> (modelo linear específico), por meio de espectrorradiometria aérea.....	48
3.14 - Seleção das curvas espectrais obtidas para as fitofisionomias Campo Limpo, Campo Sujo e Cerrado <i>sensu stricto</i> (modelo linear específico), a partir dos dados de espectrorradiometria aérea gerados no Parque Nacional de Brasília.....	49
3.15 - Imagem MNF (RGB 123) do Parque Nacional de Brasília, com as curvas espectrais para os <i>endmembers</i> Campo Limpo, Campo Sujo e Cerrado <i>sensu stricto</i> no espaço MNF e no ETM+ .....	50
3.16 - Amostras de <i>pixels</i> obtidas nas diversas categorias de análise. VD = Valor Digital, R = Reflectância.....	51
4.1 - Exemplo de ajustes vetoriais realizados para o novo mapa de vegetação nas classes temáticas <i>Solo Exposto, Mata de Galeria, Cerrado sensu stricto</i> e <i>Campo Limpo com Murundum</i> , utilizando imagens IKONOS (1 m e 4 m de resolução espacial). Os vetores vermelhos correspondem às áreas corrigidas (mapa atualizado); os vetores azuis correspondem às falhas no antigo mapeamento .....	53
4.2 - Comparação visual entre os dois mapas de vegetação do PNB: (A) mapeamento antigo (FUNATURA-1995), e (B) mapeamento atual (2002).....	55
4.3 - Novo mapa de vegetação do Parque Nacional de Brasília. ....	56
4.4 - Imagens Frações do PNB, resultantes do modelo linear geral. IF RGB: Veg./Solo/Sombra.....	59
4.5 - IF Vegetação e Solo, seguido pela identificação visual das principais fitofisionomias do bioma Cerrado.....	60
4.6 - Comparação do mapa de vegetação com as IF RGB Veg./Solo/Sombra (modelo linear geral) .....	61
4.7 - IF do PNB, resultantes do modelo linear específico, com <i>endmembers</i> obtidos diretamente na imagem ETM+. IF RGB: CSS/CL/CS. A legenda “sem dados” indica as áreas de MG, solo exposto e água, mascaradas nesta análise .....	69

4.8 -	Imagens Frações do PNB, resultantes do modelo linear específico, com <i>endmembers</i> obtidos por espectrorradiometria de campo. IF RGB: CSS/CL/CS. A legenda “sem dados” indica as áreas de MG, solo exposto e água, mascaradas nesta análise.....	70
4.9 -	Comparação entre a IF RGB (modelo linear específico) e o mapa de vegetação atualizado do PNB .....	71
4.10 -	Comparação visual entre as IF (RGB) geradas a partir do MLME geral e específico. Observa-se um destaque maior das classes de Cerrado com as imagens obtidas pelo MLME específico .....	72

## LISTA DE TABELAS

3.1 -	Propriedades das classes de Cerrado encontradas no PNB .....	34
3.2 -	Características do Domínio Poroso .....	39
3.3 -	Características gerais dos sensores Landsat ETM+ e IKONOS .....	42
3.4 -	Categorias de imagens, modelos lineares, fonte de <i>endmembers</i> e processamentos utilizados para análise do MLME no Parque Nacional de Brasília .....	50
4.1 -	Classes temáticas presentes no antigo e no novo mapeamento do PNB, com a respectiva área (hectares e %) .....	54
4.2 -	Análise Discriminante para as Imagens Fração “Valor Digital” (IF-VD) .....	63
4.3 -	Análise Discriminante para as Imagens Fração “Reflectância” (IF-R) ....	63
4.4 -	Análise Discriminante para a cena ETM+ (bandas 1-5 e 7) .....	64
4.5 -	Análise Discriminante para a imagem NDVI .....	64
4.6 -	Matriz “F” para as Imagens Fração “Valor Digital” (IF-VD) .....	65
4.7 -	Matriz “F” para as Imagens Fração “Reflectância” (IF-R) .....	65
4.8 -	Matriz “F” para a cena ETM+ (bandas 1-5 e 7) .....	66
4.9 -	Matriz “F” para a imagem NDVI .....	67
4.10 -	Análise Discriminante para as Imagens Fração <i>Referência</i> .....	73
4.11 -	Análise Discriminante para as Imagens Fração <i>Imagem</i> .....	73
4.12 -	Análise Discriminante para a cena ETM+ (bandas 1-5 e 7) .....	74
4.13 -	Análise Discriminante para as Imagens Fração <i>MNF</i> .....	75
4.14 -	Matriz “F” para as Imagens Fração <i>Referência</i> .....	75
4.15 -	Matriz “F” para as Imagens Fração <i>Imagem</i> .....	76
4.16 -	Matriz “F” para a cena ETM+ (bandas 1-5 e 7) .....	76
4.17 -	Matriz “F” para as Imagens Fração <i>MNF</i> .....	77
4.18 -	Teste-t realizado com a Imagem Fração Água - VD e R .....	79

4.19 - Teste-t realizado com a Imagem Fração Solo - VD e R.....	79
4.20 - Teste-t realizado com a Imagem Fração Vegetação - VD e R .....	79

## RESUMO

O bioma savânico, localmente conhecido como Cerrado, compreende um mosaico de vegetação verticalmente estruturado pelos estratos herbáceo, arbustivo e arborecente. Presente em 25% território nacional (2 milhões de km<sup>2</sup>), e em 45% da América do Sul, este ecossistema desempenha um importante papel no fluxo de energia, água e carbono da região. Apesar disto, estima-se que 40% da cobertura original de Cerrado no país já tenham sido convertidas em pastagens cultivadas, áreas agrícolas e urbanas. Dentro deste contexto, esta pesquisa investigou o potencial do Modelo Linear de Mistura Espectral (MLME) para o mapeamento das principais fitofisionomias de Cerrado (Campo Limpo, Campo Sujo, Campo Cerrado e Cerrado *sensu stricto*). Os objetivos específicos foram: avaliar um conjunto de diferentes *endmembers*, assim como a contaminação atmosférica, no desempenho do MLME neste bioma. O estudo foi conduzido no Parque Nacional de Brasília, uma área com aproximadamente 30.000 ha, ao norte do Distrito Federal (15° 35' - 15° 45' latitude sul e 47° 53' - 48° 05' longitude oeste). O MLME foi aplicado sobre uma cena do sensor ETM+ (órbita 221; ponto 71) de 20 de julho de 2001 (estação seca), com e sem correção atmosférica. Dois modelos de mistura foram testados: um geral, cujos *endmembers* foram a vegetação verde, solo e sombra (substituído pela água nesse estudo), e um específico, cujos *endmembers* foram o Campo Limpo, Campo Sujo e o Cerrado *sensu stricto*. Os *endmembers* foram adquiridos diretamente da imagem e por meio de espectrorradiometria de campo no PNB (espectros de referência), realizada também em julho de 2001. A análise visual indicou uma boa concordância entre os dados de verdade terrestre (mapa de vegetação) e as Imagens Fração, as quais foram capazes de discriminar os principais domínios de Cerrado, com proporções variando de 0,7 a 1,0. As análises estatísticas demonstraram a existência de uma confusão espectral mais intensa entre o Campo Sujo e o Campo Cerrado em todas as categorias de dados analisadas, causada pela similaridade dessas duas fitofisionomias, em termos de estrutura e cobertura verde. Por outro lado, o MLME obteve um grau de separabilidade maior do que as imagens NDVI e ETM+ (bandas 1-5 e 7), tornando possível um mapeamento mais preciso para a região. Por último, foi observado que o potencial do MLME, na discriminação das classes de Cerrado, não aumentou com a correção dos efeitos atmosféricos, previamente realizada na cena ETM+. Mais especificamente, este resultado demonstra que as análises com o MLME podem ser realizadas com uma demanda computacional menor, aumentando assim a operacionalidade do método no monitoramento ambiental. No entanto, foram observadas diferenças significativas nos valores médios das classes de Cerrado, nas respectivas Imagens Fração (valor digital e reflectância), mostrando que a correção atmosférica é importante na realização de Análises de Mistura Temporal.

## ABSTRACT

The savanna biome, locally known as Cerrado, comprises a vertically structured mosaic of herbaceous, arbustive, and arborescent strata. This ecosystem covers approximately 25% of Brazil and 45% of South America, playing an important role in the energy, water and carbon fluxes on region. It is estimated that about 40% of the Cerrado land cover has already been converted into cultivated pastures, agricultural crops, and urban areas. This research evaluated the usefulness of the Spectral Linear Mixing Model (SLMM) for mapping the major Cerrado physiognomies (Cerrado grassland, shrub Cerrado, wooded Cerrado, and Cerrado woodland). The specific goals were: to evaluate a different set of endmembers and the impact of atmospheric contamination on the model output. The study was conducted at the Brasilia National Park (BNP), an area of approximately 30,000 hectares, located in the northern Federal District, Brazil (15°35' and 15°45' south latitude and 47°53' and 48°05' west longitude). The SLMM was performed over a Landsat ETM+ scene (path 221; row 71), obtained on July 20<sup>th</sup> 2001 (dry season), with and without atmospheric correction. Two models were applied: one representing a general model (endmembers = green vegetation, soil and shade, in this case, replaced by water), and the other, representing a specific model (endmembers = Cerrado grassland, shrub Cerrado and Cerrado woodland). The endmembers were acquired from both the image and aerial spectroradiometer over the BNP (July 2001). The visual analysis showed a good agreement between the ground truth data (vegetation map) and the fraction images, which were capable of discriminating the major Cerrado domains, with proportions ranging from 0.7 to 1.0. The statistical analysis demonstrated a spectral confusion between Campo Sujo and Campo Cerrado for all data set because of their similarity in terms of structure and green cover. The SLMM presented a higher separability than NDVI or ETM+ data set (bands 1-5 e 7). The SLMM capability to discriminate the Cerrado vegetation did not increase with the atmospheric correction. However, there were considerable differences in the average values for each class in their respective fraction images, showing that the atmospheric correction is important when multitemporal mixture analysis is performed.

# CAPÍTULO 1

## INTRODUÇÃO

### 1- Considerações Iniciais

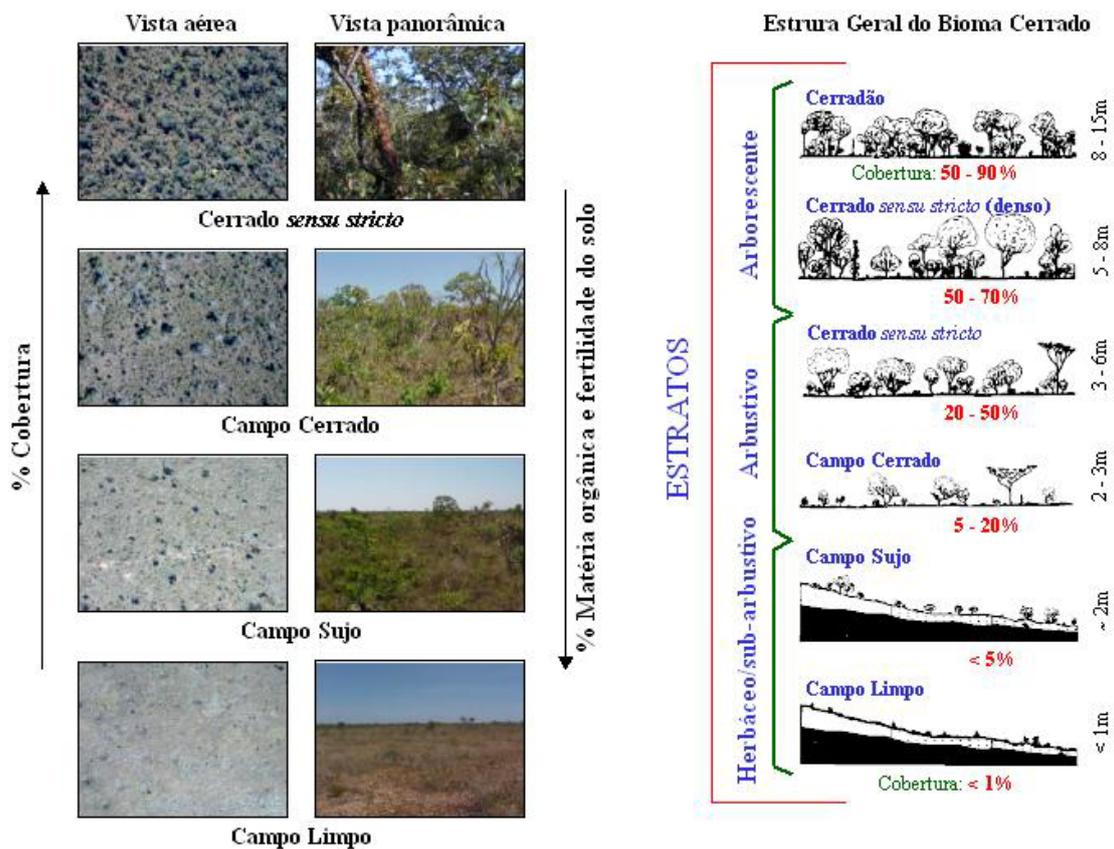
O ambiente savânico no Brasil, conhecido localmente como Cerrado, pode ser descrito como um mosaico de vegetação, verticalmente estruturado por espécies herbáceas, arbustivas e arborescentes (**Figura 1.1**). Este gradiente natural é determinado, entre outros fatores, pela disponibilidade de água e fertilidade do solo (Pivello e Coutinho, 1996), marcado também pela sazonalidade da estação chuvosa, concentrada na região entre os meses de outubro a março (Dias, 1992).

Presente em 25% do território nacional (2 milhões de km<sup>2</sup>) e em 45% da América do Sul, esse bioma desempenha um importante papel no balanço de energia, água e carbono da região, atuando como um sumidouro de gases de efeito estufa, tal como o CO, CO<sub>2</sub> e CH<sub>4</sub> (Monteiro, 1995; Silva, 1999). Sua elevada biodiversidade, atualmente estimada em seis mil espécies vasculares (Mendonça et al., 1998), é favorecida pela presença de três das maiores bacias hidrográficas da América do Sul (Tocantins, São Francisco e Prata), além de uma extensa diversidade de solos, geologia e queimadas naturais (Eiten, 1972).

Apesar da importância sócio-ambiental, o Cerrado encontra-se ainda pouco valorizado em termos de conservação, apresentando apenas 1,7% de sua área assegurada na forma de parques ou reservas (Brasil, 2003). Estima-se que atividades como a pecuária e a agricultura sejam responsáveis, até o momento, pela conversão de aproximadamente 40% de sua área original (Klink, 1996; Mittermayer et al., 1999; Sano et al., 2002) (**Figura 1.2**). A degradação, muitas vezes causada por razões culturais (por exemplo, uso indiscriminado de queimadas), geográficas (terras planas para plantios) e econômicas (proximidade de mercados consumidores), acabam por induzir o surgimento de distúrbios ambientais graves, com reflexo imediato na flora e fauna da região.

O sensoriamento remoto, tido como uma fonte contínua e regular para a obtenção de dados da superfície terrestre, pode prover um monitoramento sistemático desse

bioma, como o que vem sendo realizado pelo PRODES<sup>1</sup> Digital (Shimabukuro et al., 2000; Duarte et al., 2003) na região Amazônica, por exemplo. Entretanto, pesquisas recentes sobre o mapeamento do Cerrado, utilizando dados de sensoriamento remoto obtidos por sensores ópticos e de radar, têm demonstrado algumas restrições quanto à discriminação de fitofisionomias encontradas nessa região (Sano et al., 2001; Ferreira et al., 2003a). Normalmente, observa-se uma confusão espectral entre as classes gramíneo-lenhosas e arbustivas (Campo Limpo e Campo Sujo), como também nas classes com predominância arbórea (Campo Cerrado e Cerrado *sensu stricto*), dificultando a obtenção de mapeamentos mais precisos. Soma-se a este fato, o uso de métodos convencionais para o processamento de imagens de satélite, muitos dos quais desenvolvidos para a análise de dados multiespectrais.



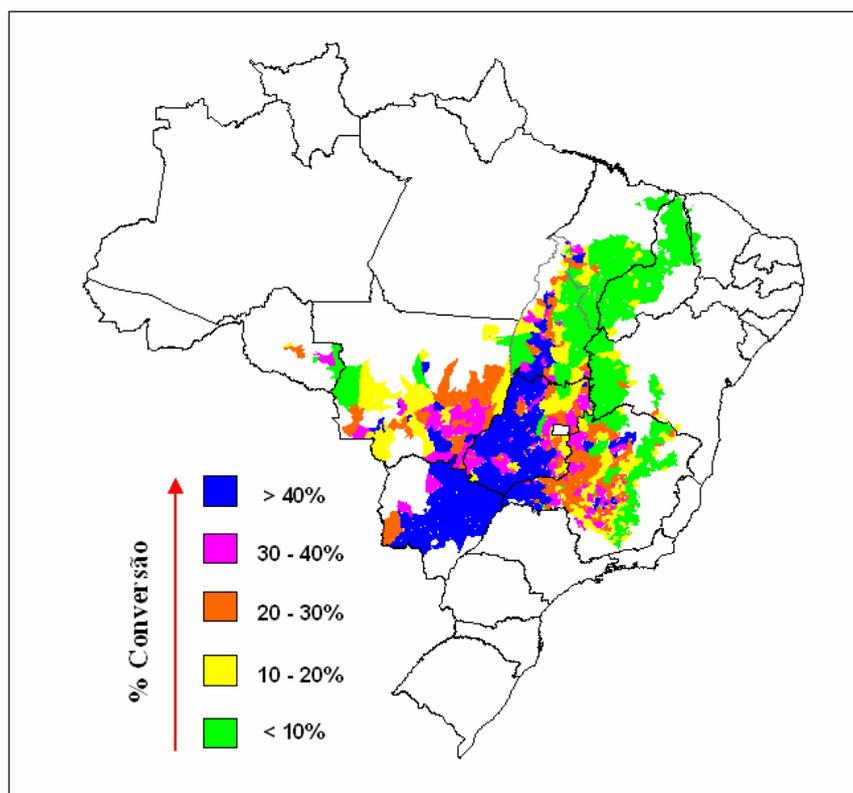
**Figura 1.1.** Estrutura vegetal do Cerrado.

Com o advento dos sensores hiperespectrais, a bordo de aeronaves ou satélites, uma nova concepção sobre o manuseio de dados de sensoriamento remoto foi

<sup>1</sup> Projeto de Estimativa do Desflorestamento Bruto da Amazônia (versão digital).

estabelecida, principalmente para as pesquisas com fins ambientais. A análise de alvos como a vegetação ou solo, antes mais fundamentada em métodos visuais de interpretação, passou a ser realizada em conjunto com a manipulação de curvas espectrais destes materiais. Novas técnicas de processamento foram desenvolvidas a fim de se extrair, de forma hábil e prática, as informações contidas em mais de uma centena de bandas disponibilizadas por estes sensores (Adams et al., 1989).

Dentre estas técnicas, destaca-se o uso do Modelo Linear de Mistura Espectral (MLME) que, em linhas gerais, visa decompor uma imagem em frações (por exemplo, solo, vegetação e sombra), com base no comportamento espectral dos materiais considerados puros (*endmembers*), encontrados em cada *pixel* da cena. Dessa forma, o modelo pode detectar, por exemplo, alterações na cobertura vegetal, considerando a proporção dos componentes ao nível de *sub-pixel* (Holben e Shimabukuro, 1993; Shimabukuro et al., 1998; Schweik e Green, 1999).



**Figura 1.2.** Área ocupada pelo bioma Cerrado no Brasil, e a sua atual taxa de conversão motivada pela criação de pastagens e agricultura. Fonte: Sano et al. (2002).

Apesar de ter seu uso vinculado às aplicações espectrorradiométricas (hiperespectrais), os modelos lineares de mistura espectral vêm sendo utilizados com sucesso em imagens multiespectrais, citando-se, por exemplo, a viabilidade do método na detecção de mudanças na paisagem (ex. desmatamento) e nas pesquisas relacionadas com a mineralogia (Adams et al., 1995; Bryant, 1996).

Esta pesquisa situa-se no âmbito do projeto LBA (*Large Scale Biosphere-Atmosphere Experiment in Amazonia*), cujos experimentos no Cerrado vêm sendo conduzidos, dentre outras áreas de menor extensão, no Parque Nacional de Brasília. A necessidade de um monitoramento sistemático deste bioma, por meio do uso efetivo e operacional do sensoriamento remoto, motivou a condução deste estudo, com o qual espera-se contribuir para um melhor acompanhamento ambiental da região.

## **1.1 - Objetivos**

O objetivo geral desta pesquisa é analisar a aplicação do Modelo Linear de Mistura Espectral para a discriminação das principais fitofisionomias do Parque Nacional de Brasília (bioma Cerrado), utilizando dados obtidos pelo sensor Landsat ETM+ no período da seca (julho/2001). Os objetivos específicos incluem:

- a) elaboração de um novo mapa de vegetação do Parque Nacional de Brasília;
- b) definição de um conjunto apropriado de *endmembers* para modelar as misturas espectrais existentes na vegetação do Parque Nacional de Brasília;
- c) avaliação do uso de *endmembers* obtidos diretamente na imagem, bem como aqueles definidos a partir de espectrorradiometria de campo; e
- d) avaliação dos efeitos da contaminação atmosférica na aplicação destes modelos de mistura espectral.

## CAPÍTULO 2

### MODELO LINEAR DE MISTURA ESPECTRAL

#### 2.1 - MLME vs. Classificadores Convencionais

A classificação digital de imagens pode ser definida como um procedimento computacional voltado para a extração de informações de uma superfície (cobertura e uso do solo), com base nos valores de radiância dos alvos em diferentes comprimentos de onda, identificando-os em categorias baseadas na similaridade espectral. Os métodos de classificação podem ser divididos em dois grandes grupos: os *supervisionados* e os *não-supervisionados*. No primeiro, são utilizadas informações independentes para definir as categorias ou classes temáticas. Essas informações podem ser representadas por “assinaturas” espectrais dos alvos, bem como amostras de *pixels* obtidas em áreas conhecidas na cena, comumente chamadas de “áreas de treinamento”. Nesse grupo estão, por exemplo, os algoritmos *MaxVer*, *Paralelepípedo*, *Mínima Distância* e *Distância de Mahalanobis*.

No segundo grupo, apenas as propriedades estatísticas da imagem são consideradas para a classificação dos *pixels*. Tais classes são, portanto, definidas automaticamente, embora haja uma certa interação com o analista, o qual pode indicar quais concentrações de *pixels* (*clusters*) devem ser tratadas como grupos distintos. Em termos computacionais, esta é a forma mais rápida de classificação, utilizada principalmente quando há uma ausência de informações independentes (ex. áreas de treinamento), ou quando a não-subjetividade/padronização são fatores primordiais na análise. Nesse grupo encontram-se, por exemplo, os algoritmos *IsoSeg* (ou *IsoData*) e o *K-Médias*.

Esses dois grupos de classificação (supervisionados e não-supervisionados) podem ainda ser divididos em métodos *paramétricos* e *não-paramétricos*. No primeiro caso, o algoritmo se baseia na distribuição estatística das classes (ex. distribuição gaussiana), onde parâmetros como vetor médio, desvio padrão e matriz de covariância são exigidos para a classificação (Schowengerdt, 1997). Algoritmos paramétricos, muito utilizados com imagens multiespectrais, são o *MaxVer*, *Paralelepípedo*, *Mínima Distância*, *Distância de Mahalanobis*, *IsoSeg*, e o *K-Médias*.

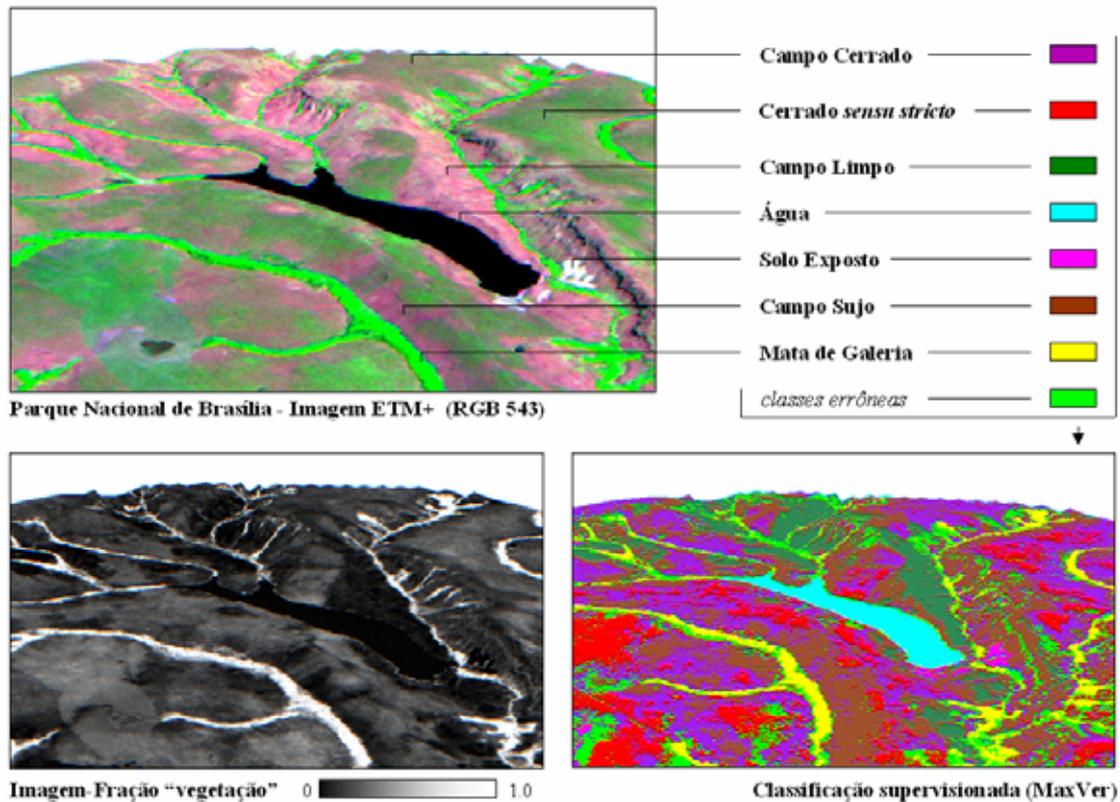
Com os algoritmos não-paramétricos, a análise de distribuição probabilística dos *pixels* recebe uma ênfase menor. Neste caso, a avaliação dos dados ocorre de forma integral, onde a informação espectral identifica as diferentes feições na imagem (Sabins, 1978; Mausel, 1985). Dois exemplos comuns são os classificadores por fatiamento (Schowengerdt, 1997) e por redes neurais artificiais (Tafner, 1998).

O problema é que nesta classificação, tida como convencional, é comum ocorrer uma estimativa incorreta para algumas classes temáticas, devido à existência de *pixels* misturados, não representados por nenhuma das classes previamente definidas no processamento (Aguiar et al., 1999). Outros erros são atribuídos à baixa resolução espacial, radiométrica e espectral da imagem, ou ao próprio desconhecimento da área de estudo por parte do analista.

Dentro dessa abordagem, uma discussão importante se faz sobre a questão da “classificação suave” (*soft classification*) versus “classificação rígida” (*hard classification*). A atual idéia de mapeamento temático presume que cada ponto na superfície possa ser categorizado por meio destes algoritmos classificadores do tipo *likelihood*, isto é, por probabilidade. Entretanto, são vários os fatores que impedem tal feito, entre estes a resolução dos sensores remotos frente à variação e complexidade dos alvos naturais e artificiais. Com isto, uma grande quantidade de dados é ignorada com representações relativamente simplificadas da paisagem. Teoricamente, em sensoriamento remoto, é possível identificar até  $2^{QK}$  categorias de informação (Schowengerdt, 1997) em um conjunto de dados ( $Q = \text{bits por pixel por banda}$ ; e  $K = \text{bandas}$ ).

Na chamada “classificação rígida” o limite de decisão no espaço de feições é bem definido, onde cada *pixel* assume uma única identificação por processamento. Na “classificação suave” este *pixel* pode apresentar múltiplos identificadores ou *labels* (ex. método *fuzzy* de classificação). Apesar do MLME não ser enquadrado como um método de classificação de imagens, é justamente neste aspecto que ele se difere dos demais métodos convencionais de classificação. Na verdade, seu propósito principal não é a obtenção de classes temáticas, onde os *pixels* são orientados de acordo com uma probabilidade de ocorrência, mas sim extrair as proporções dos materiais contidos em cada elemento da cena, também em função do comportamento espectral do alvo. Como resultado, obtém-se algo semelhante a uma “classificação suave” para cada componente

analisado, onde áreas claras ou mais escuras na imagem indicam, respectivamente, uma maior ou menor proporção do alvo (**Figura 2.1**). Pode-se dizer, então, que o MLME representa um novo conceito de análise, ao nível de *subpixel*, onde é possível estabelecer uma nova regra para o mapeamento, não mais em função de limites rígidos (fronteiras entre alvos distintos), mas sim considerando a proporção física do alvo ao longo de toda a área analisada.



**Figura 2.1.** Imagem do Parque Nacional de Brasília, submetida ao MLME (Imagem Fração *vegetação*) e a uma classificação supervisionada (*MaxVer*). Na Imagem Fração, a variação na escala de cinza indica, de forma contínua, a proporção de um determinado alvo (ex. Mata de Galeria).

Dependendo das propriedades geográficas da área de estudo, tais classificadores (ex. *Mínima Distância*, *MaxVer* e *IsoSeg*) podem obter resultados semelhantes àqueles encontrados com o uso de um MLME. Entretanto, além de destacar um alvo de forma contínua, através da geração de Imagens Fração (IF), os valores de proporção obtidos com o modelo de mistura indicam uma relação física com a área, ao invés de apenas uma escala de valores digitais (0 - 255) (Holben e Shimabukuro, 1993; Shimabukuro e

Smith, 1995; Zhu e Tateishi, 2001). No caso de uma IF *vegetação*, por exemplo, esta pode ser interpretada em termos de suas variáveis ecológicas, podendo auxiliar na obtenção de Índices de Área Foliar (Gilabert et al., 2000).

Contudo, na opção por uma técnica de mapeamento (convencional ou não), deve-se levar em consideração o grau de acurácia versus a demanda / complexidade computacional. Neste caso, o propósito da análise e as facilidades do processamento devem também orientar a escolha do método.

## 2.2 - MLME vs. Índices de Vegetação

Os índices de vegetação buscam combinar, sob a forma de razões, as informações contidas na radiância refletida pelos dosséis, nas regiões do vermelho e infravermelho próximo do espectro eletromagnético. No comprimento de onda do visível (bandas 1, 2 e 3 do sensor ETM+) esta radiância é marcada por um processo de absorção, ocasionado pela presença de pigmentos fotossintetizantes na vegetação sadia (clorofila e outros). Já no infravermelho próximo, esta relação entre a radiância refletida e a biomassa verde é diretamente proporcional, podendo variar de acordo com a quantidade de folhas, distribuição e arranjo espacial do dossel (Ponzoni, 2001).

Com base neste comportamento espectral, o NDVI (*Normalized Difference Vegetation Index*), ou Índice de Vegetação da Diferença Normalizada (Jackson e Huete, 1991; Bannari et al., 1995) (**Equação 2.1**), foi pioneiro na obtenção de estimativas de biomassa e Índice de Área Foliar (IAF). A aplicação desse índice em imagens orbitais obtidas pelo sensor AVHRR (*Advanced Very High Resolution Radiometer*), e ultimamente pelo sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*) (Ferreira e Huete, 2002), vem auxiliando no monitoramento contínuo da cobertura vegetal, em escalas global e regional. Algumas variações do NDVI encontram-se atualmente implementadas, gerando novos índices que minimizam os efeitos do solo (SAVI - *Soil Adjusted Vegetation Index*) e dos aerossóis (EVI - *Enhanced Vegetation Index*) (Huete et al., 2002) (**Equações 2.2 e 2.3**). Informações adicionais sobre NDVI e EVI poderão ser encontradas em

$$NDVI = \frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + \rho_{Red}} \quad (2.1)$$

$$SAVI = \frac{\rho_{NIR} - \rho_{Red}}{(\rho_{NIR} + \rho_{Red} + L)} \times (1 + L) \quad (2.2)$$

$$EVI = \frac{(\rho_{NIR} - \rho_{Red})}{L + \rho_{NIR} + C_1 \rho_{Red} - C_2 \rho_{Blue}} \times G \quad (2.3)$$

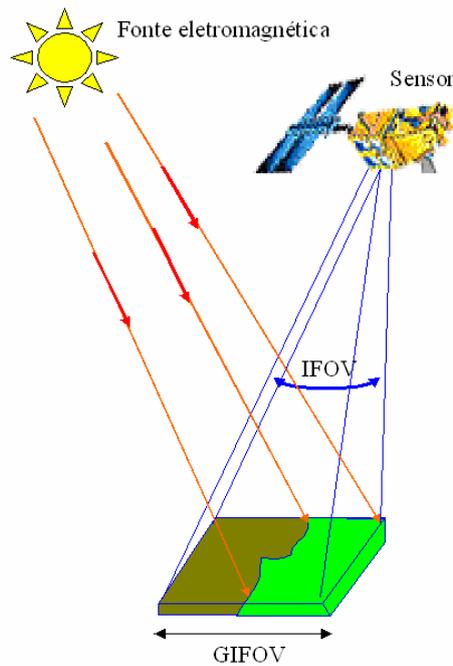
onde  $\rho_{NIR}$  e  $\rho_{Red}$  correspondem às bandas do infravermelho próximo (NIR – Near Infrared) e vermelho (R – Red), em nível de reflectância (correção atmosférica) ou em valor digital (0 - 255).  $L$  é um fator de calibração que leva em consideração os efeitos do solo na resposta espectral do dossel.  $C_1$  e  $C_2$  correspondem ao peso do canal azul para a correção dos aerossóis no sinal do canal vermelho e  $G$  é um fator de ganho do sensor, igual a 2,5.

Em termos visuais, a imagem NDVI é semelhante à Imagem Fração (IF) *vegetação* e, dependendo da área de estudo e do sensor utilizado, podem apresentar elevada correlação entre os *pixels*, como demonstrado por Holben e Shimabukuro (1993). Em outras palavras, as duas imagens apresentam um parâmetro físico a respeito da vegetação. Em ambientes com estrutura vegetacional complexa, caso do Pantanal, o MLME demonstra ser mais sensível às diferenças na vegetação do que as imagens NDVI (Shimabukuro et al., 1998). Soma-se a este fato a presença das Imagens Fração *solo* e *sombra*, geradas para a mesma área, trazendo informações complementares que auxiliam, por exemplo, na análise do desflorestamento, com base na proporção de solo exposto, ou no mapeamento das áreas de rebrotas, com base na proporção de sombra, associada com a estrutura (fase de desenvolvimento) da cobertura vegetal (Adams et al., 1995; Sabol et al., 2002).

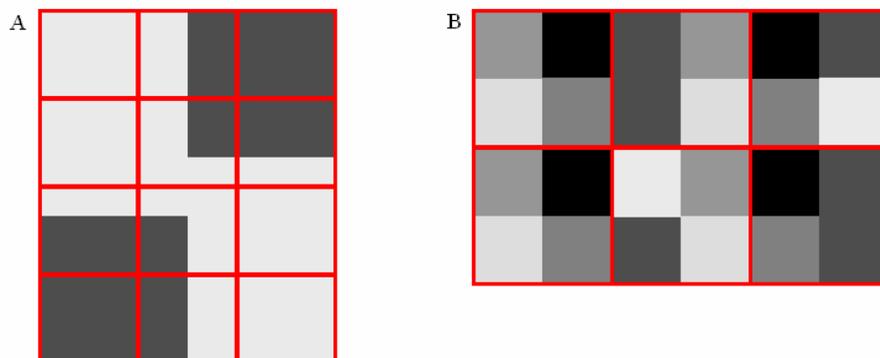
### 2.3 - Fundamentos do Modelo Linear de Mistura Espectral

Imagens de sensoriamento remoto quase sempre apresentam uma combinação de *pixels* puros e misturados (maioria). Dependendo da resolução espacial do sensor ou do GIFOV (*Ground Instantaneous Field Of View*), os materiais na superfície podem ser menores do que um único elemento de cena da imagem. Desta forma, a radiância observada em um dado ponto é resultado de uma mistura espectral originada pela

resposta de cada um destes componentes contidos no *pixel* (ex. vegetação + solo + sombra). Outra situação comum é quando esse *pixel* encontra-se no limite entre dois ou mais materiais diferentes (Shimabukuro e Smith, 1995). As **Figuras 2.2** e **2.3** ilustram tais fatores para a mistura. Em ambas as situações, a radiância dos alvos é combinada, dificultando a sua classificação. O MLME se propõe a modelar esta condição de mistura.

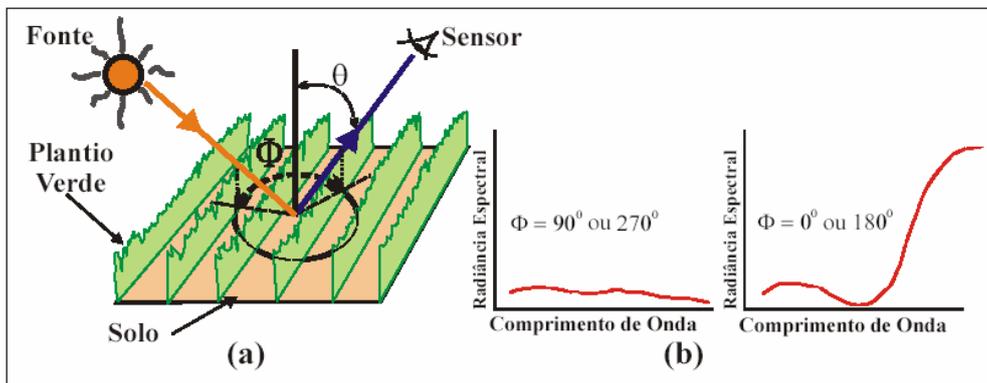


**Figura 2.2.** Representação física de um *pixel* misturado, devido à presença de dois tipos de materiais no GIFOV do sensor.



**Figura 2.3.** (A) O *pixel* (linha vermelha) se encontra na fronteira de alvos diferentes. (B) Diferentes materiais contidos em um único *pixel*.

Segundo Piwowar et al. (1998), apesar das resoluções espaciais dos sensores orbitais terem aumentado substancialmente nos últimos anos, a maioria dos dados ainda apresenta uma característica espectralmente misturada, já que a variação espacial dos fenômenos naturais cresce à medida que a escala aumenta. Também contribuem à mistura no sinal, principalmente entre *pixels*, fatores espúrios à obtenção das imagens, em particular aqueles originados a partir da contaminação atmosférica, da variação na geometria de aquisição dos dados pelo sensor, assim como nas diferenças de iluminação na superfície, devido aos aspectos topográficos da região (sombra) (**Figura 2.4**).



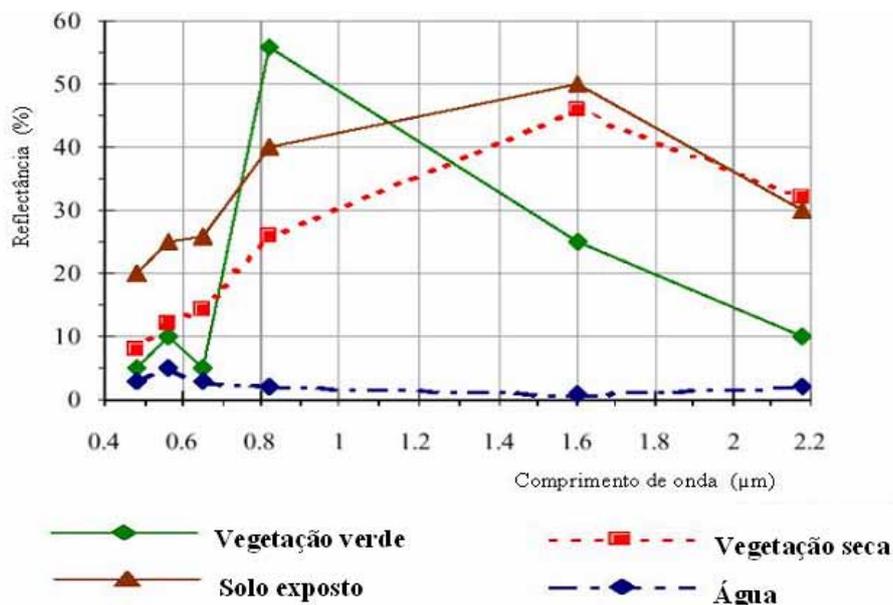
**Figura 2.4.** (a) Geometria de reflexão em um plantio. (b) Variação da radiância espectral em função dos diferentes ângulos zenitais (solares).

Todos os materiais na natureza apresentam, em um determinado comprimento de onda do espectro eletromagnético, um comportamento espectral próprio ao interagir com os fótons de luz. Assim ocorre, por exemplo, para o solo exposto, vegetação verde (fotossinteticamente ativa) e seca, e água (ou sombra) (**Figura 2.5**). Em alguns casos, esta diferenciação torna-se mais difícil, principalmente pela proximidade e semelhança na resposta espectral. Tal fato é observado em algumas classes de Cerrado, cuja confusão espectral é mais elevada (**Figura 2.6**).

Frente a este problema, o MLME visa identificar a contribuição de cada alvo presente nos *pixels* de uma cena, permitindo que uma imagem de satélite seja analisada de forma “suave” e precisa, na escala de *subpixel* (Schowengerdt, 1997; Schweik e Green, 1999). O termo “suave” vem do conceito de *soft classification* (classificação suave), onde os *pixels* não são necessariamente identificados como pertencentes a uma

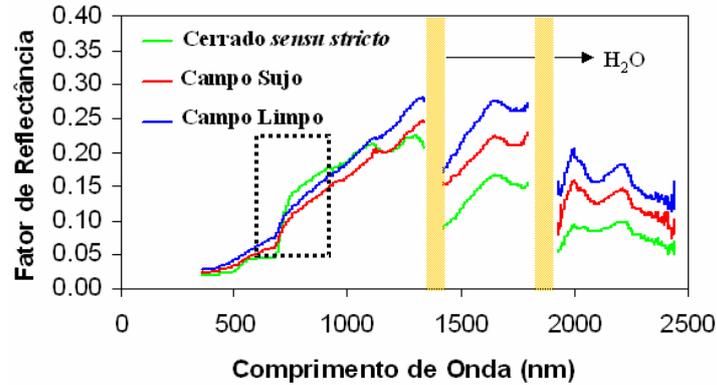
determinada classe temática, mas sim pela maior ou menor proporção dos componentes analisados pelo modelo de mistura.

Este modelo fundamenta-se no pressuposto de que um espectro misturado (diferentes alvos no campo de visão do sensor), numa imagem qualquer pode ser modelado através de uma combinação linear de espectros puros, conhecidos por *endmembers* (Roberts et al., 1998). Nestas condições, para qualquer imagem, 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 e Smith, 1991; Schowengerdt, 1997; Shimabukuro et al., 1998; Shimazaki e Tateishi, 2001). Portanto, os *endmembers* referem-se ao conjunto de espectros “puros” que serão utilizados em um modelo de mistura e que, quando combinados por regra apropriada, são capazes de reproduzir os demais espectros encontrados na imagem (Adams et al., 1989). Segundo Detchmendy e Pace (1972) *apud* Aguiar et al. (1999), o modelo linear foi desenvolvido com este propósito de compreender as variações encontradas nas assinaturas espectrais de diversos materiais, o que de certa forma pode ser interpretado como uma função de proporção dos *endmembers* contidos em cada *pixel* da cena.



**Figura 2.5.** Curvas de reflectância da vegetação verde, vegetação seca (não-fotossintética), solo exposto e água. Modificada de Shimazaki e Tateishi (2001).

Outros objetivos do MLME referem-se à redução da dimensionalidade dos dados em uma imagem com  $n$  bandas, tornando-a apropriada para um novo processamento (ex. classificação não-supervisionada), e o realce dos alvos de interesse, ambos obtidos pela geração de Imagens Fração (Aguiar et al., 1999; Verona et al., 2001).



**Figura 2.6.** Comportamento espectral de três classes de vegetação, típicas do bioma Cerrado: Cerrado *sensu stricto*, Campo Sujo e Campo Limpo, obtidas por espectrorradiometria de campo no Parque Nacional de Brasília (época seca). A área circulada indica a confusão espectral destas classes na região do vermelho e infravermelho próximo.

As Imagens Fração para os respectivos *endmembers* podem ser obtidas através da aplicação do modelo geral de mistura apresentado na **Equação 2.4**. A **Equação 2.5** refere-se ao termo de erro da primeira equação, correspondendo aos valores residuais presentes em cada *pixel* e não solucionados (ou ajustados) pelo método de análise proposto (Schweik e Green 1999; Defries et al., 2000). O ajuste do modelo também pode ser avaliado pelo erro da raiz média quadrática (RMSE), expressa na **Equação 2.6** (Roberts et al., 1998).

$$r_i = \sum_{j=1}^n (a_{ij} x_j) + e_i \quad (2.4)$$

$$e_i = r_i - \sum_{j=1}^n (a_{ij} x_j) \quad (2.5)$$

$$RMSE = \sqrt{\sum_{j=1}^n (e_i)^2 / j} \quad (2.6)$$

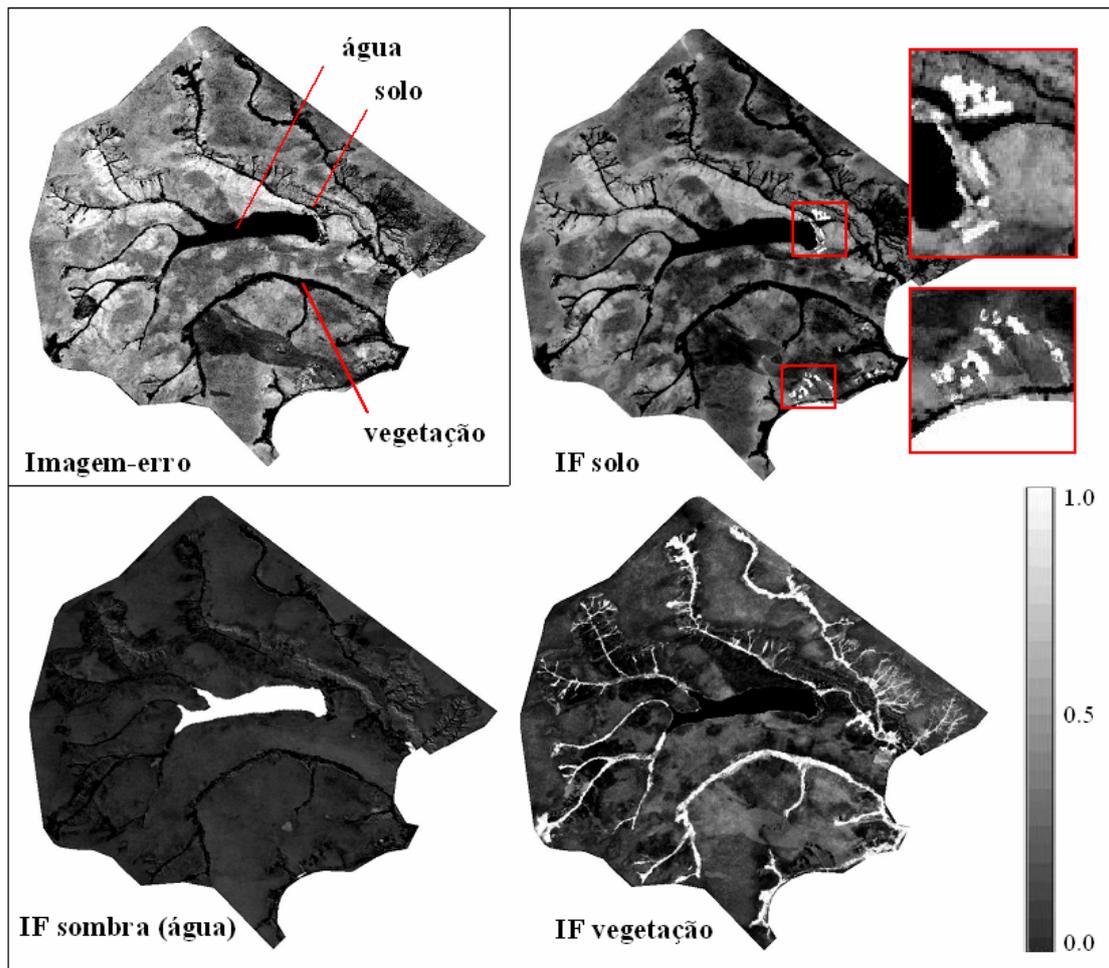
onde  $r_i$  = reflectância de um *pixel* observada na banda  $i$ , contendo um ou mais componentes;  $j = 1, 2, 3, \dots, n$  (número de componentes);  $a_{ij}$  = reflectância do componente  $j$  na banda espectral  $i$ ;  $x_j$  = proporção do componente  $j$  (*endmember*) dentro do *pixel*;  $e_i$  = termo de 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 modelo deve seguir as restrições apresentadas na **Equação 2.7**, que orientam a análise das proporções de cada componente amostrado na imagem. As Imagens Fração podem ser estimadas por diferentes métodos, sendo os mais conhecidos o **CLS** (*Constrained Least Square*) e o **WLS** (*Weighted Least Square*), ambos voltados para minimizar a soma dos quadrados dos erros (ou valores residuais), sujeitos a aparecer devido às restrições impostas abaixo (Shimabukuro e Smith, 1991; Holben e Shimabukuro, 1993; Aguiar et al., 1999).

$$0 \leq x_j \leq 1 \text{ e } \sum x_j = 1 \quad (2.7)$$

Dessa forma, os valores nas Imagens Fração (bandas sintéticas) podem variar de 0 (*pixels* escuros) a 1 ou 100% (*pixels* claros), indicando, respectivamente, a menor e a maior proporção do componente identificado nas Imagens Fração.

A imagem erro ou imagem RMSE (*Root Mean Square Error*), obtida do processamento com o MLME, tem como função principal indicar a qualidade dos *endmembers* utilizados no modelo. A análise desta imagem se dá de forma inversa às IF. *Pixels* escuros indicam baixo valor de RMSE, ou seja, *pixels* modelados corretamente, enquanto que *pixels* brilhantes demonstram um valor mais alto de RMSE, provavelmente causado pelo uso de *endmembers* inapropriados ao modelo de mistura. Normalmente, as áreas realçadas nas Imagens Fração ficam escuras na imagem erro e vice-versa (**Figura 2.7**). Outros fatores contribuem para que os valores de erro sejam mais elevados, tal como na ausência de um importante *endmember* para modelar o *pixel*, na medida em que a proporção de um determinado material não tenha sido reconhecida pelos *endmembers* inseridos numa primeira tentativa.



**Figura 2.7.** Imagens Fração *solo*, *vegetação* e *sombra* (água) do Parque Nacional de Brasília, com a respectiva imagem erro.

### 2.3.1 - Aplicações Gerais do MLME

Os conceitos de mistura espectral e de proporção de *endmembers* foram introduzidos nos estudos com imagens multiespectrais ainda no início dos anos 1970 (Horowitz et al., 1971 *apud* Adams et al., 1995), sendo, desde então, rapidamente difundidos e aprimorados. Uma das primeiras aplicações com o modelo linear ocorreu no campo da Astronomia e Geologia, onde se buscava aprimorar os mapeamentos de depósitos minerais e recursos hídricos possivelmente presentes na superfície de outros corpos do sistema solar (Schweik e Green, 1999). Ainda hoje, o MLME tem sido aplicado neste campo de pesquisa, sobretudo em análises da superfície do planeta Marte (Staid e Pieters, 1998; Farrand, 1999; Nolin e Farrand, 1999; Farrand e Gaddis, 1999).

Ultimamente, com a crescente necessidade de mapeamentos mais precisos a respeito dos recursos naturais terrestres, sobretudo da vegetação, os modelos lineares passaram a ser utilizados com uma maior frequência (Zhu e Tateishi, 2001), substituindo ou complementando outros métodos de processamento de imagens, tal como os índices de vegetação (ex. NDVI, SAVI, EVI) e demais técnicas de classificação digital, com algoritmos supervisionados e não-supervisionados. Neste sentido, variantes do MLME vêm sendo aplicadas com sucesso no mapeamento de espécies vegetais, áreas degradadas e mineralógicas (Bryant, 1996; Asner e Lobell, 2000; Rogan et al., 2002), inclusive em regiões cobertas por neve e gelo, visando a detecção de mudanças climáticas (Painter et al., 1998; Piwowar et al., 1998).

O uso desses modelos tem se estendido também, com resultados bastante satisfatórios, para o monitoramento de queimadas e desmatamentos na Amazônia, como demonstrado por Cochrane e Souza (1998), e Souza e Barreto (2000). Um desses projetos, realizados pelo INPE (Instituto Nacional de Pesquisas Espaciais), é o PRODES Digital (Projeto de Estimativa do Desflorestamento Bruto da Amazônia), o qual vem empregando o MLME em imagens Landsat para o mapeamento de áreas desflorestadas nesta região, com atualização anual do banco de dados (Shimabukuro et al., 1997 e 2000). No setor agrícola, o MLME vem sendo utilizado para distinguir com maior precisão as áreas de culturas (ex. algodão) daquelas ocupadas por solo e sombra. Obtém-se, assim, uma estimativa mais confiável da área de plantio e de sua respectiva produtividade (Maas, 2000).

No caso do monitoramento do Cerrado, o MLME tem sido considerado como uma ferramenta viável na detecção de mudanças na vegetação. Seu potencial para discriminar as principais fitofisionomias desse bioma foi demonstrado por Holben e Shimabukuro (1993), Ferreira et al. (2002), Ferreira et al. (2003b) e Miura et al. (2003). Em outros biomas não menos complexos, como o Pantanal Mato-grossense (Shimabukuro et al., 1998) e áreas desérticas ou semidesérticas (Drake et al., 1999; Okin et al., 1999), foi verificada a eficácia do MLME no mapeamento da cobertura vegetal, onde as Imagens Fração, geradas com diferentes sensores multiespectrais e hiperespectrais, diferenciaram bem os componentes *solo exposto*, *vegetação* e *sombra*.

## **Análise de Mistura Temporal**

A Análise de Mistura Temporal (AMT) segue os fundamentos do MLME, sendo, porém, implementada com imagens orbitais obtidas em diferentes épocas. Na AMT, o conjunto de  $n$  dados multitemporais assume a condição de  $n$  bandas multiespectrais. Essas imagens podem ser agrupadas numa escala que vai da maior para a menor quantidade de dados disponíveis para um determinado componente, em função do mês ou do ano de aquisição da imagem (Piwowar et al., 1998). A vantagem dessa técnica é a elaboração de um mapeamento com nível de acurácia elevado, em função dos princípios do MLME, porém, contemplando uma análise multitemporal. O AMT tem sido utilizado em séries temporais de imagens registradas pelo NOAA AVHRR, em escalas global ou regional, identificando bem as proporções de áreas florestais (Zhu e Tateishi, 2001).

Por outro lado, o MLME também pode ser utilizado individualmente em cada imagem. Assim, as Imagens Fração resultantes são analisadas com base em técnicas envolvendo, por exemplo, matemáticas de bandas (ex. imagem diferença) ou a realização de fusão ou mosaicos. Contudo, nesse tipo de análise, não é indicado o uso de espectros obtidos de imagens não-calibradas radiometricamente. Tal fato se deve às mudanças espectrais nos *endmembers* derivados de imagem para imagem. Neste caso, os *endmembers* de referência devem ser baseados em dados adquiridos em laboratório ou em campo.

## **Análise de Mistura Espectral com Múltiplos Endmembers**

Uma outra aplicação derivada do MLME é a análise de mistura espectral com múltiplos *endmembers*, conhecida também como MESMA (*Multiple Endmember Spectral Mixture Analysis*) (Roberts et al., 1998). Esta técnica visa corrigir algumas limitações observadas nos modelos lineares mais simples, que utilizam apenas um grupo de *endmembers*. Uma destas limitações refere-se ao fato de que tais modelos não estão preparados para contemplar, simultaneamente, os diferentes materiais presentes num *pixel* com a variabilidade espectral destes ao longo da imagem (contraste espectral de um material). Isto equivale a dizer que um conjunto de *endmembers* pode ser apropriado para modelar uma determinada porcentagem de *pixels* ao invés da cena inteira.

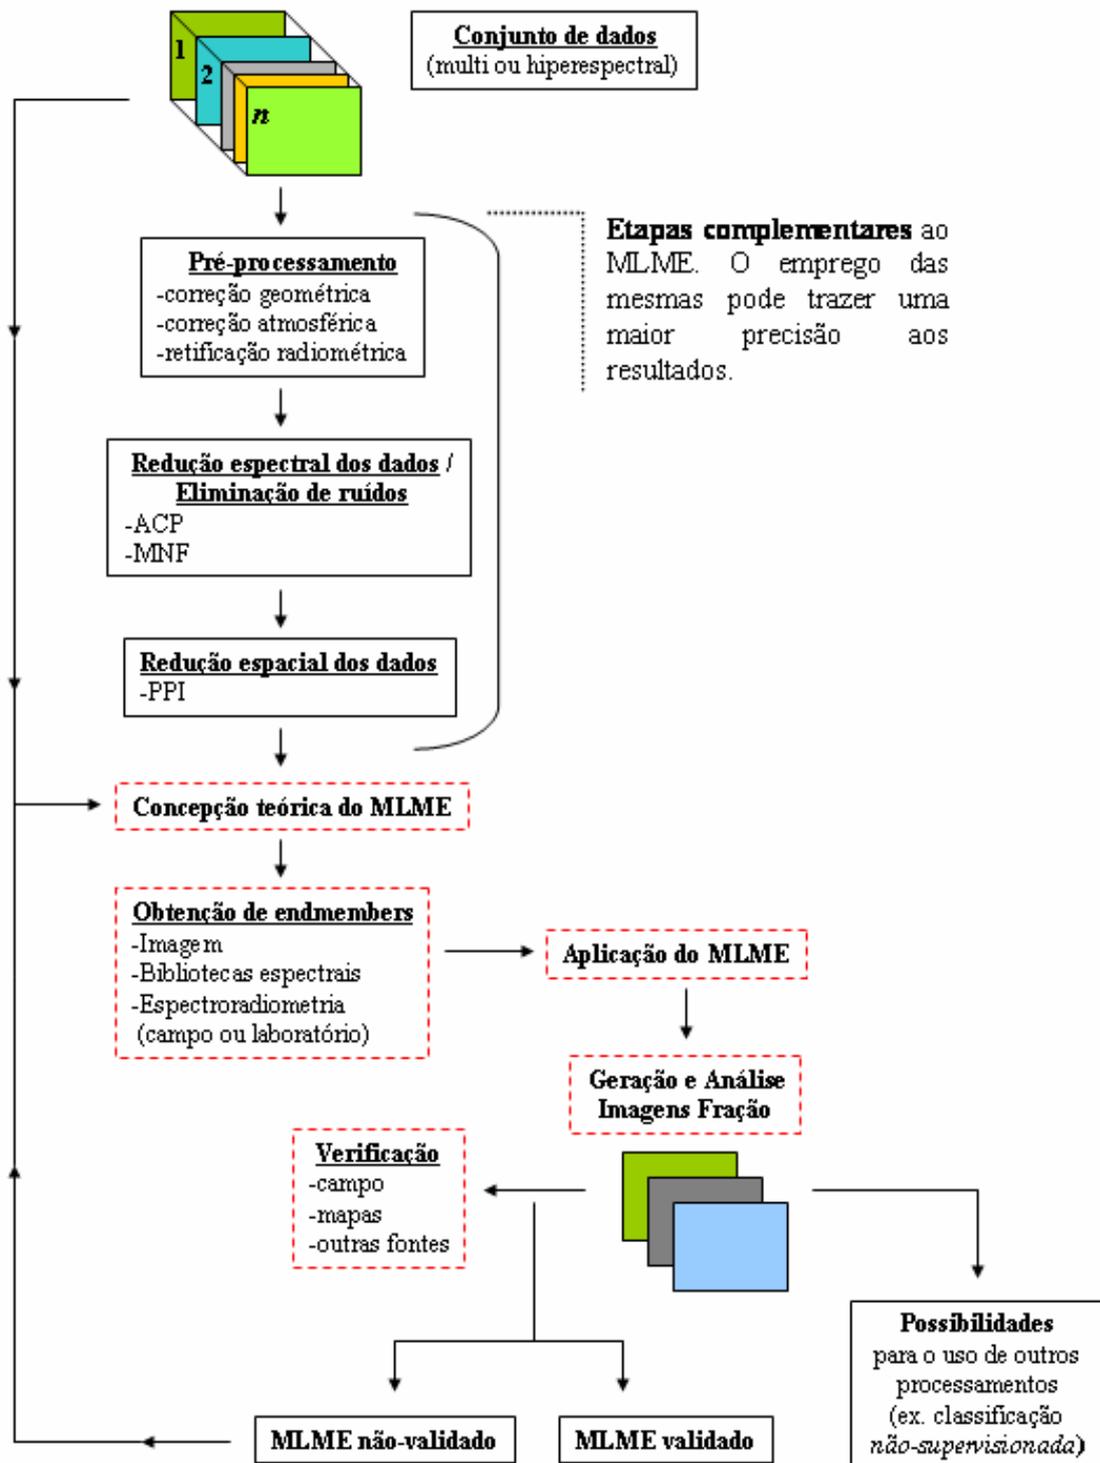
Relacionado a este fato, está a acurácia de uma Imagem Fração, que será mais alta quando um número exato de componentes puros, requeridos para discriminar esta variabilidade espectral, for utilizado no modelo. Dessa forma, a ausência de um ou mais *endmembers* aumentará o RMS, criando uma Imagem Fração “falha”; por outro lado, o excesso de *endmembers* poderá realçar os ruídos instrumentais e a contaminação atmosférica, gerando novamente uma Imagem Fração “falha”, comumente caracterizada por proporções negativas dos alvos.

A MESMA permite, de forma interativa, variar o número e o tipo de *endmembers* para cada *pixel* da imagem, aumentando o potencial de mapeamento. O objetivo é ajustar um conjunto ótimo de modelos (ex. dois ou três modelos, com quatro *endmembers* cada), capazes de extrair as feições com um menor RMS. Esta técnica tem sido testada tanto em alvos naturais (ex. vegetação, solo) (Roberts et al., 1998; Okin et al., 1999) como em alvos não-naturais (ex. asfalto), apresentando uma grande flexibilidade no mapeamento destes ambientes.

### 2.3.2 - Etapas para Aplicação do MLME

Um MLME pode ser utilizado para uma gama de pesquisas, indo desde o acompanhamento de áreas desmatadas até a busca por mineralizações na superfície de rochas e solos. Esta diversidade de produtos envolve etapas diferenciadas na aplicação do modelo de mistura, de acordo também com a necessidade de cada análise. Dessa forma, serão abordadas as etapas obrigatórias e as complementares ao método. Estas são as seguintes (**Figura 2.8**):

- a) pré-processamento (correção atmosférica / retificação radiométrica da imagem original - imagem-referência);
- b) redução da dimensionalidade dos dados, através da Análise por Componentes Principais (ACP), e/ou Eliminação de Ruídos (*Minimum Noise Fraction* - MNF);
- c) utilização de um *Índice de Pureza dos Pixels* (*Pixel Purity Index* - PPI);
- d) concepção teórica do Modelo Linear de Mistura Espectral;
- e) obtenção de um conjunto de *endmembers* adequados a este modelo; e
- f) geração e análise das Imagens Fração (IF) / verificação (verdade terrestre).



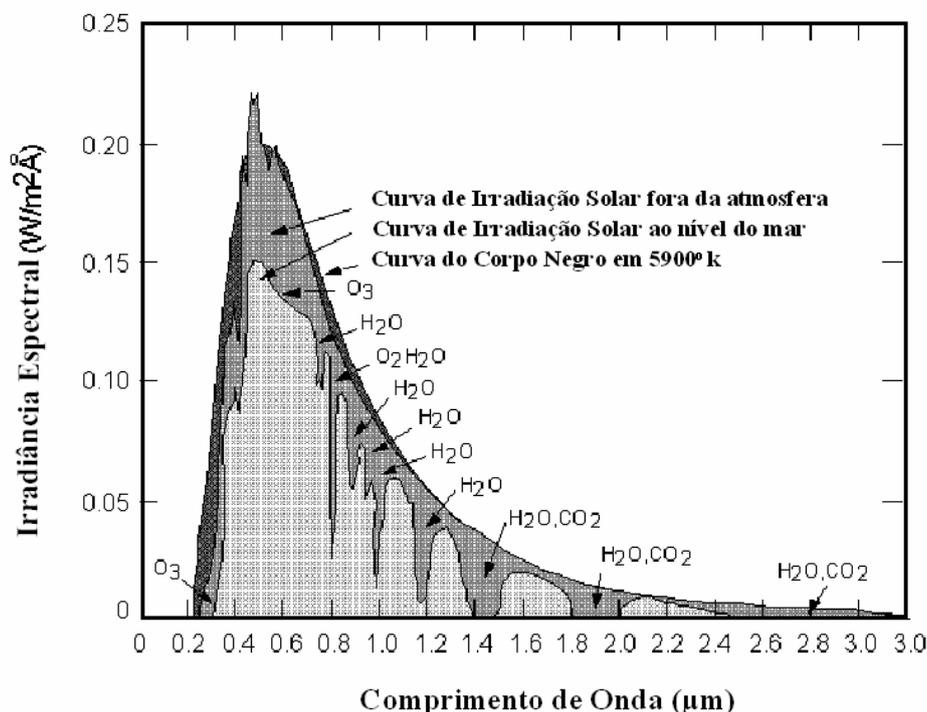
**Figura 2.8.** Método geral, com as etapas obrigatórias (caixa tracejada na cor vermelha) e complementares, para a aplicação de um Modelo Linear de Mistura Espectral em dados multiespectrais ou hiperespectrais.

Cada uma destas etapas (**Figura 2.8**) é discutida nos parágrafos seguintes:

### **Correção Atmosférica**

A correção atmosférica em imagens de satélite não é uma etapa obrigatória para a aplicação do MLME, embora a conversão dos dados, originalmente em valores digitais (0 - 255), para níveis de radiância e posteriormente para níveis de reflectância seja necessária nos seguintes casos (Shimabukuro e Smith, 1991; Galvão, 2001a): a) quando diferentes imagens, obtidas por diferentes sensores, são combinadas em um processamento. Isto se deve ao fato de cada sensor, assim como cada banda deste, apresentar um padrão de calibração para realizar a conversão da medida de radiância do alvo para o formato digital; b) quando no modelo de mistura linear são utilizados *endmembers* obtidos por espectrorradiometria de campo ou a partir de bibliotecas espectrais elaboradas em laboratório (*endmembers* de referência), tal como a biblioteca espectral do Serviço Geológico dos Estados Unidos (USGS). Estes *endmembers* normalmente são apresentados como padrão de reflectância dos alvos, necessitando que os dados (imagem) estejam neste formato para que haja a possibilidade de comparação; e c) em qualquer análise temporal ou análise de áreas diferentes, considerando que as condições atmosféricas são diferentes no momento em que a cena é obtida pelo sensor. Neste caso, exige-se uma normalização dos dados por meio de técnicas de correção atmosférica e/ou retificação radiométrica.

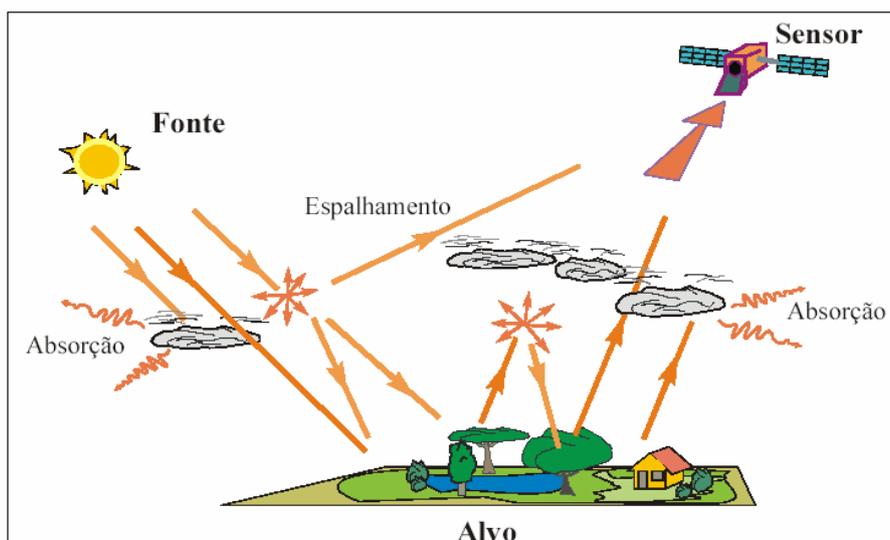
Independente da forma de obtenção dos *endmembers*, por vezes obtidos da própria imagem ou a partir de espectros de referência, diversos trabalhos destacam a conversão dos dados para níveis de reflectância ou reflectância aparente, antes da aplicação do MLME (Shimabukuro e Smith, 1995; Roberts et al., 1998; Shimabukuro et al., 1998; Aguiar et al., 1999; Rogan et al., 2002). Em tese, estes dados de sensoriamento remoto devem sempre ser convertidos para valores livres das condições atmosféricas no momento do imageamento, corrigindo-se, assim, a contaminação causada pelas diferenças de iluminação, aerossóis e gases (ex. vapor d'água), bem como a dispersão e absorção da radiação eletromagnética entre o sensor e a superfície (**Figuras 2.9 e 2.10**). Como resultado desta correção, obtém-se curvas espectrais mais próximas da reflectância real dos alvos, as quais são, de fato, uma medida física dos materiais sensorizados.



**Figura 2.9.** Espectro solar com as bandas de absorção/interferência atmosférica.

Por outro lado, o processo de correção atmosférica pode ser bastante complexo, exigindo informações como condições climáticas, irradiância solar e de calibração do sensor, no exato momento de obtenção das imagens (Schowengerdt, 1997). A título de exemplo, pode-se citar o método “6S” (*Second Simulation of the Satellite Signal in the Solar Spectrum*), um modelo de transferência radioativa utilizado para vários sensores que, dentre os diversos passos exigidos, necessita de uma estimativa sobre a fina camada de aerossóis presentes nas bandas ópticas do espectro (Ouaidrari e Vermote, 1999; Radeloff et al., 1999).

Outras metodologias de calibração radiométrica, apresentadas por Green e Craig (1985), Roberts et al. (1985), Markham e Barker (1986), e empregadas em processamentos com o MLME (Shimabukuro e Smith, 1995; Bajjouk et al., 1998; Roberts et al., 1998; Shimabukuro et al., 1998; Aguiar et al., 1999; Drake et al., 1999), utilizam modelos de atmosfera e/ou dados de calibração para um determinado sensor (ganhos e *offsets*), facilitando a conversão dos dados originais (valores digitais) para radiância ou reflectância aparente.



**Figura 2.10.** Influência da atmosfera na trajetória da radiação eletromagnética entre a fonte e o sensor. Fonte: Moreira (2002).

Alguns programas computacionais (ex. ATREM, EFFORT) também implementados em sistemas de processamento de imagens, executam a correção dos efeitos atmosféricos ou dos ruídos introduzidos pelo sensor durante o imageamento. No caso do ATREM, são utilizados modelos de irradiância solar e transmitância para um determinado comprimento de onda do espectro eletromagnético.

### Retificação Radiométrica

Algumas técnicas em imagens orbitais, conhecidas por retificação radiométrica, têm sido utilizadas com a finalidade de equiparar a qualidade dos dados em uma análise multitemporal, evitando, por outro lado, o emprego de extensos métodos exigidos numa correção atmosférica. Duas destas técnicas se destacam, ora pela praticidade ora pela confiabilidade nos resultados. A primeira, e a mais simples, é conhecida por Ajustes de Histogramas (*Histogram Matching*). Trata-se de uma técnica estatística, baseada numa distribuição cumulativa dos dados, que visa equalizar o histograma de uma ou várias imagens utilizando uma imagem-referência, normalmente corrigida atmosféricamente.

A segunda técnica, geralmente empregada em mosaicos de imagens para extensas áreas como a planície Amazônica (Shimabukuro et al., 2002) ou na avaliação das mudanças na cobertura vegetal ao longo do tempo (Adams et al., 1995), baseia-se na

metodologia proposta por Hall et al. (1991) e visa, sobretudo, corrigir as diferenças radiométricas entre cenas de uma série temporal. Esse procedimento envolve, inicialmente, uma transformação de imagens denominada *Tasseled Cap* ou Transformação “*Kauth-Thomas*”. A partir desta transformação, três novas imagens são geradas (*brightness*, *greenness* e *third*), sendo que duas são aproveitadas nesta técnica: a imagem *brightness* (máximo brilho) e a *greenness* (máxima atividade fotossintética). A partir da análise do espaço bidimensional de distribuição dos *pixels* para essas duas imagens, pode-se avaliar a necessidade de uma retificação radiométrica na cena escolhida.

Caso essas distribuições nos valores dos *pixels*, provenientes da imagem referência e das demais imagens sujeitas à retificação, estejam sobrepostas, a necessidade de retificação radiométrica é nula. Caso contrário, intervalos de *pixels* claros e escuros deverão ser selecionados no próprio diagrama de *pixels*, observando-se a posição destes nas respectivas cenas. Estes intervalos de valores serão utilizados para o cálculo do valor médio dos alvos claros (ex. solo) e escuros (ex. água) (valor de reflectância, radiância, ou valor digital) destas imagens. De acordo com Verona et al. (2001), esta transformação linear ajusta as duas imagens considerando o ângulo solar, as condições e atenuações atmosféricas, além da calibração do sensor. O modelo utilizado para o processo de retificação é demonstrado nas **Equações 2.8, 2.9 e 2.10**.

$$T = m_i + b_i \quad (2.8)$$

$$m_i = \frac{Br_i - Dr_i}{Bs_i - Ds_i} \quad (2.9)$$

$$b_i = \frac{Dr_i Bs_i - Ds_i Br_i}{Bs_i - Ds_i} \quad (2.10)$$

onde:  $Br_i$  = média dos pontos claros (brilho) na imagem-referência;  $Dr_i$  = média dos pontos escuros na imagem-referência;  $Bs_i$  = média dos pontos claros (brilho) na imagem sujeita à retificação;  $Ds_i$  = média dos pontos escuros na imagem sujeita à retificação, para todas as bandas ( $i$ ).

## **Redução Espectral dos Dados/Eliminação de Ruídos**

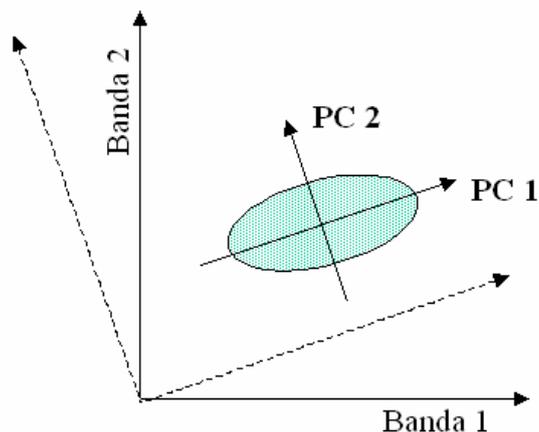
Imagens multiespectrais ou hiperespectrais normalmente apresentam uma elevada correlação entre bandas. Este fato é gerado pela existência de uma correlação espectral entre os materiais imageados, pela sobreposição das bandas do sensor e pela topografia (Schowengerdt, 1997). No primeiro caso, a correlação ocorre devido à baixa reflectância da vegetação ao longo do espectro visível da luz, gerando uma assinatura espectral similar entre as bandas do visível.

No caso da sobreposição de bandas, esta pode ser minimizada durante a concepção do sensor, mas dificilmente poderá ser evitada por completo. Por último, o sombreamento topográfico, comum em áreas montanhosas e com baixo ângulo solar, apresenta praticamente a mesma resposta em todas as bandas da região óptica do espectro, sendo um componente dominante na correlação entre bandas.

A Análise por Componentes Principais (ACP) é uma das formas de se eliminar a correlação nos dados originais, podendo ser compreendida como uma transformação (rotação) no espaço multidimensional da imagem, onde a matriz de variância dos dados é preservada, sendo comprimida em poucas dimensões. Ocorre, assim, um agrupamento das informações, a partir da soma da variância (autovalores) de cada Componente Principal (CP), ao longo do seu novo eixo de coordenadas (Crosta, 1992; Schowengerdt, 1997) (**Figura 2.11**).

As Componentes Principais, resultantes dessa transformação, são ordenadas em ordem crescente, do maior para o menor valor de variância. No caso de imagens multiespectrais, as CP 1, 2 e 3 concentram a maior parte das informações (~98%), antes distribuídas nas  $n$  bandas da imagem original.

Este método estatístico vem sendo empregado também no estudo direto de curvas espectrais, coletadas com um espectrorradiômetro de campo ou de laboratório. Assim, em casos onde há uma grande quantidade de espectros a serem analisados e comparados entre si, a Análise por Componentes Principais pode eliminar as informações redundantes contidas na semelhança destes espectros coletados em uma determinada área de estudo (Galvão, 2001b).



**Figura 2.11.** Representação gráfica da Análise por Componentes Principais em duas dimensões. Os eixos originais da imagem (bandas 1 e 2) são rotacionados, redistribuindo os *pixels* (elipse) sobre um novo sistema de eixos, formado pelas Componentes Principais 1 e 2.

Uma técnica de processamento semelhante à Análise por Componentes Principais, e comumente aplicada às imagens hiperespectrais, é a transformação conhecida por *Minimum Noise Fraction* (MNF) ou Componentes Principais com Ajuste de Ruídos (*Noise - Adjusted Principal Components*) (Green et al., 1988; Lee et al., 1990; Schowengerdt, 1997).

Os ruídos são interferências causadas pelo próprio sensor, na saída do sinal, havendo diversas representações para estes. Podem ser identificados por *pixels* com valor zero; linhas de *pixels* ruins; riscos brancos na imagem (*striping*), causados por diferenças de calibração e resposta entre os detectores de um sensor; e ruídos de banda causados durante o movimento do espelho do sensor, quando este se depara com um alto contraste de radiância na superfície (Schowengerdt, 1997).

Dessa forma, a transformação MNF é utilizada com dois fins: a) segregar os ruídos presentes nos dados originais, e b) determinar a dimensionalidade dos dados, agrupando as informações em um pequeno conjunto de bandas, com base na matriz de variância ou autovalores. Para isto, são realizadas duas transformações, ao invés de uma, como ocorre na ACP. A primeira transformação, baseada na matriz de covariância estimada para os ruídos, descorrelaciona e re-escala os ruídos inerentes aos dados da imagem, anulando a covariância destes entre as bandas. O segundo passo é o mesmo realizado na ACP, ou seja, uma análise dos dados com base na variância entre bandas. A

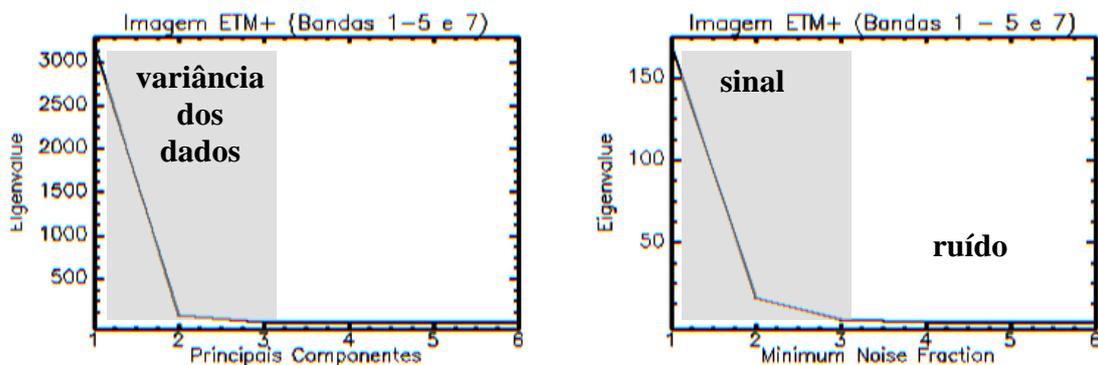
nova série de imagens, resultante da transformação MNF, é organizada em ordem crescente, de acordo com a razão sinal-ruído, da maior para a menor. A aplicação desta técnica pode trazer resultados mais fidedignos a um processamento envolvendo a análise espectral, além de reduzir os requerimentos computacionais nas etapas subsequentes a este processamento (Boardman e Kruse, 1994; Kruse e Huntington, 1996). A **Figura 2.12** ilustra os gráficos com os autovalores (*eigenvalues*) referentes às transformações ACP e MNF. A **Figura 2.13** exemplifica a alta correlação existente entre as bandas originais no espectro refletido e o agrupamento destas informações a partir do uso de ambas as técnicas.

Alguns trabalhos destacam a utilização da ACP e do MNF em análises de mistura espectral (Bajjouk et al., 1998; Drake et al., 1999; García-Haro et al., 1999; Goetz e Kindel, 1999, Ferreira et al., 2002b), ao invés de bandas originais, ressaltando quatro vantagens: 1) as Componentes Principais são linearmente independentes, eliminando qualquer redundância devido à correlação entre bandas; 2) a maior parte dos dados é preservada; 3) com a compressão dos dados, a exigência computacional é menor, trazendo maior agilidade ao processamento; 4) a extração de assinaturas espectrais dos *endmembers* em diagramas de *pixels* (três diagramas para três PC's) torna-se viável.

Bajjouk et al. (1998), avaliando a quantificação das frações de cobertura na escala de *subpixel*, por meio de Análise por Componentes Principais e métodos lineares, demonstraram que entre 10 e 13 bandas espectrais do radiômetro CASI (*Compact Airborne Spectrographic Imager*), o número de Componentes Principais (PCs) conservadas e componentes puros identificados permaneceu constante em três e seis, respectivamente, podendo se distinguir entre quatro a seis tipos de alvos. Com quatro a sete bandas deste mesmo sensor, a primeira e a segunda PC normalmente acumulam cerca de 98% dos dados, reduzindo o número de componentes puros passíveis de serem discriminados para três ou quatro. O aumento de 10 para 13 bandas no processamento não implicou na identificação de um maior número de *endmembers*, mas sim em uma maior acurácia das frações de cobertura geradas pelo MLME. Isto se deve ao aumento da discriminação espectral entre as feições com um maior número de bandas envolvidas no processamento.

A utilização da ACP ou MNF não é, entretanto, um passo fundamental para a execução da análise de mistura espectral. Segundo Shimabukuro (comunicação

peçoal), o próprio modelo linear realiza uma compressão dos dados originais, sendo inclusive um dos objetivos deste método. Aguiar et al. (1999) destacaram que o modelo de mistura pode ser usado como um método alternativo para a fase de redução dos dados em um processo de classificação, porém, apresentando duas vantagens sobre os métodos tradicionais (ACP e análise canônica): em termos qualitativos, as bandas sintéticas geradas pelo MLME normalmente proporcionam uma melhor discriminação visual dos alvos, devido a uma composição colorida com maior qualidade; em segundo, as classes nas Imagens Fração não são descritas em função da resposta espectral, mas em termos de um conceito físico (proporção de cada alvo na superfície) mais bem assimilado pelos analistas.



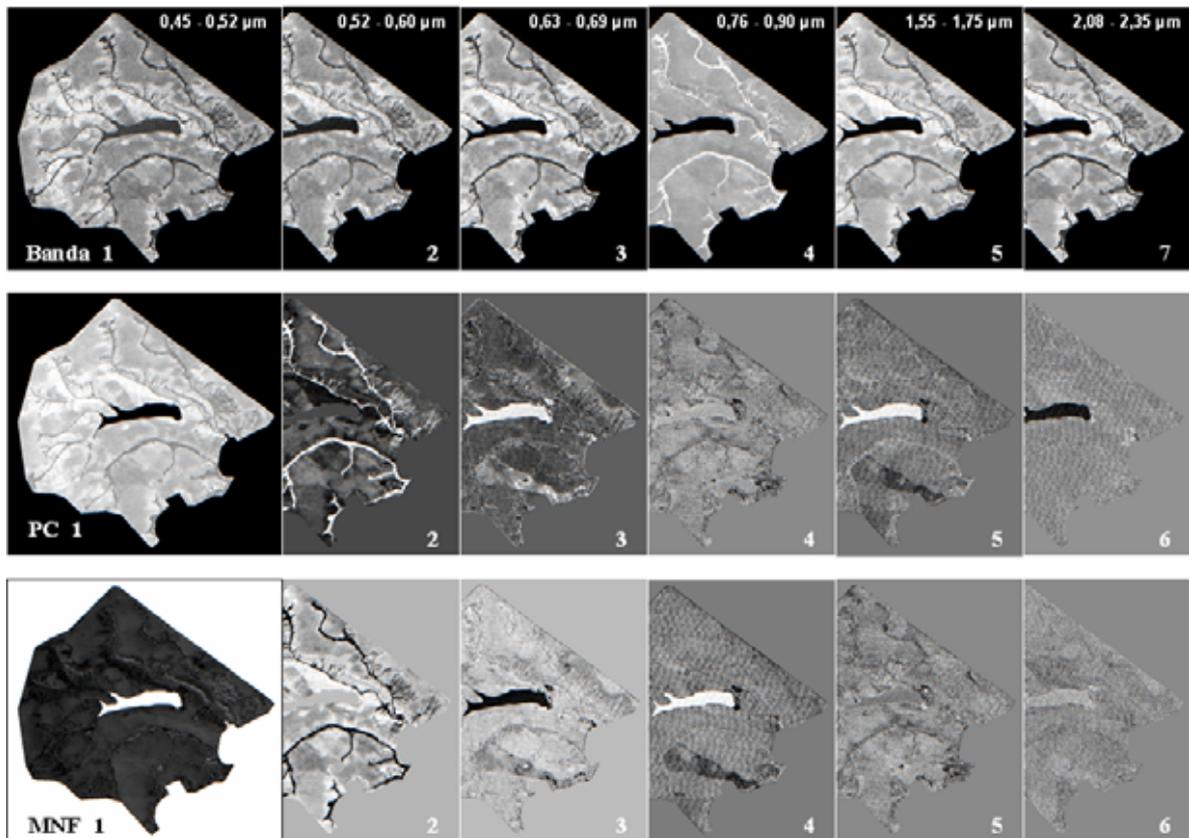
**Figura 2.12.** Distribuição dos autovalores (*eigenvalues*) após realização da ACP e do MNF, para as bandas 1-5 e 7 do sensor ETM+.

### Redução Espacial dos Dados

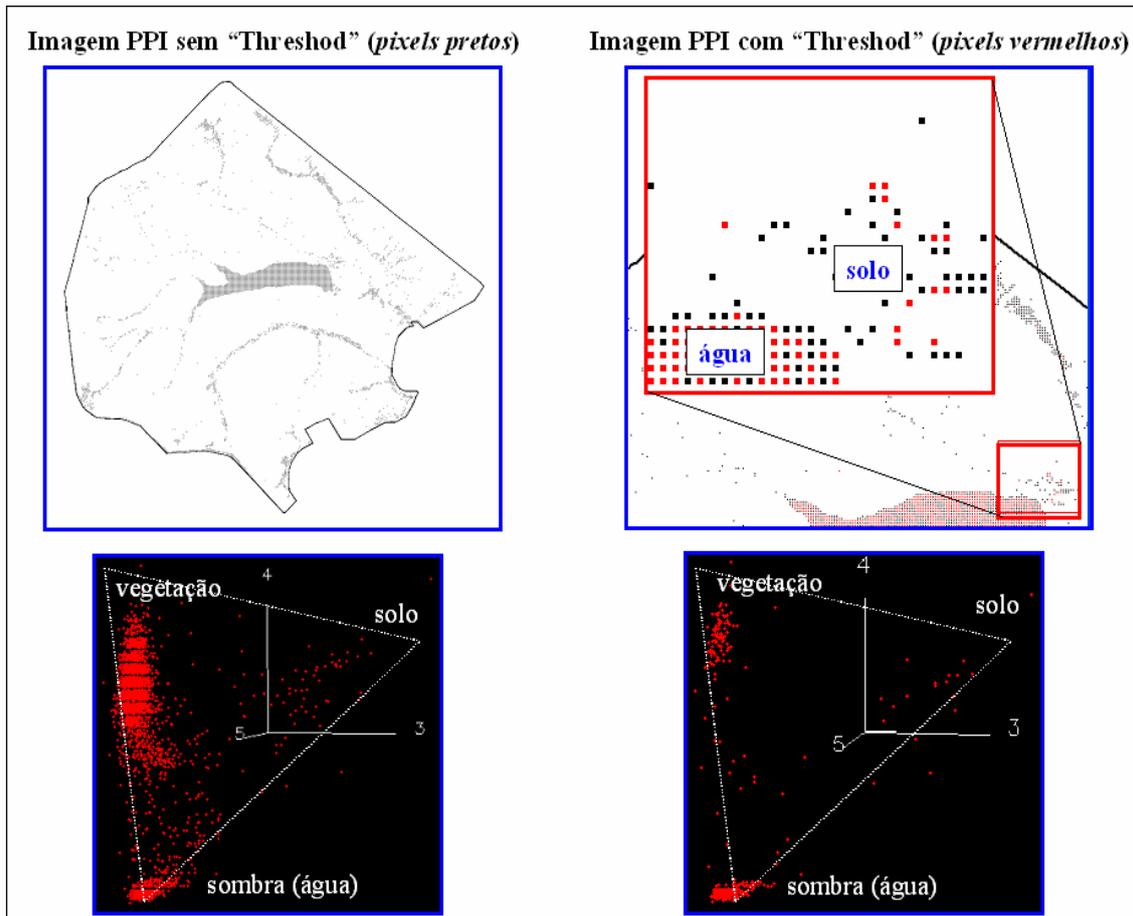
Enquanto o MNF ou a ACP realizam uma redução dos dados ao nível espectral, o *Índice de Pureza do Pixel (Pixel Purity Index - PPI)* reduz o número de *pixels* em imagens multiespectrais ou hiperespectrais. O PPI é normalmente empregado após o uso de uma das transformações espectrais mencionadas acima e tem por objetivo selecionar os *pixels* que sejam espectralmente mais puros (sem mistura espectral) (Boardman et al., 1995), estimando o número de vezes em que estes “aparecem” nos extremos de uma projeção *n*-dimensional da imagem (espaço espectral). Quanto maior a presença do *pixel* nestes extremos, maior será o valor atribuído a este na imagem PPI (*pixels* com maior brilho), indicando, por sua vez, um índice de pureza superior (**Figura 2.14**). Através de

um limiar ou fatiamento por densidade, é possível, então, considerar somente os *pixels* espectralmente puros (valor PPI mais elevado), facilitando a busca de *endmembers*.

Embora esta técnica figure mais como um complemento ao MLME, sua eficácia é demonstrada em alguns estudos de mapeamento de minerais (Boardman et al., 1995; Carvalho, 2000; Baptista, 2001) e monitoramento de cortes seletivos na Floresta Amazônica (Souza e Barreto, 2000), refinando a busca por *endmembers*. Normalmente, o uso do PPI é orientado para áreas com pouca informação, onde a busca por componentes puros na imagem é dificultada.



**Figura 2.13.** A primeira fileira de imagens corresponde às bandas 1-5 e 7 do sensor ETM+, Parque Nacional de Brasília (julho de 2001). A segunda fileira corresponde às imagens resultantes da ACP. A terceira fileira corresponde às imagens resultantes da transformação MNF. Note que os ruídos ficam segregados a partir da MNF 4 e da PC 5, enquanto que a dimensionalidade dos dados fica restrita para as primeiras MNFs e PCs.



**Figura 2.14.** Imagem resultante do *Índice de Pureza dos Pixels (Pixel Purity Index - PPI)*, representando os *pixels* espectralmente puros, e sobreposição destes *pixels* após o uso de um limite mínimo e máximo, visando a seleção de *endmembers* em áreas específicas da imagem.

### Concepção teórica do Modelo Linear de Mistura Espectral

A escolha de um modelo de mistura linear, apesar de ser uma etapa aparentemente simples, tem elevada importância para o prosseguimento da análise e, conseqüentemente, para o sucesso do processamento. Essa fase, mais teórica do que prática, diz respeito à elaboração de um modelo de mistura que atenda aos objetivos da pesquisa. Em outras palavras, significa compreender a paisagem a ser analisada em termos de sua estrutura, forma e distribuição. Como exemplo, pode-se citar imagens de áreas florestadas, onde a vegetação densa, o solo exposto e parcelas com sombra figuram como possíveis *endmembers* para um processamento (Aguiar et al., 1999).

Considera-se, portanto, que a maioria dos *pixels* irá conter, em maior ou menor proporção, a presença dos componentes amostrados.

A **Equação 2.11** exemplifica um simples modelo linear de mistura espectral, simulando três componentes: vegetação densa, solo e sombra. Uma discussão sobre os modelos utilizados nesta pesquisa é apresentada no Capítulo 3 (Materiais e Métodos).

$$r_i = (a \cdot a_i) + (b \cdot b_i) + (c \cdot c_i) + erro_i \quad (2.11)$$

onde:

$r_i$  = resposta espectral do *pixel* na banda  $i$ ;

$a$  = proporção de vegetação densa;

$b$  = proporção de solo exposto;

$c$  = proporção de sombra;

$a_i$  = resposta espectral do componente vegetação densa na banda  $i$ ;

$b_i$  = resposta espectral do componente solo exposto na banda  $i$ ;

$c_i$  = resposta espectral do componente sombra na banda  $i$ ;

$erro_i$  = valores residuais (*pixels* não modelados devido às restrições do método) na banda  $i$ ; e

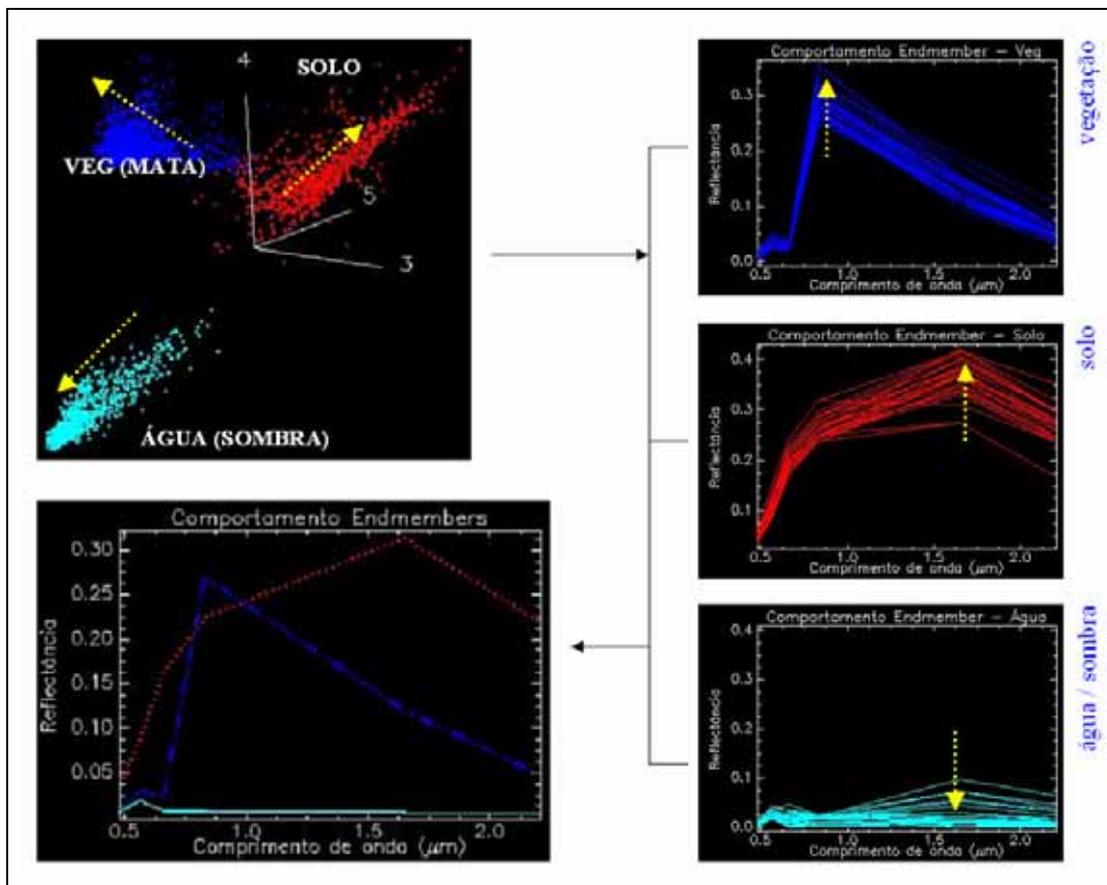
$i$  = bandas 1, 2, 3, 4, 5 e 7 do sensor ETM+.

### **Obtenção de *Endmembers***

Definido o modelo de mistura, prossegue-se com a obtenção de amostras de componentes puros ou *endmembers*. Tais componentes podem ser adquiridos de três maneiras (Roberts et al., 1998; Schweik e Green, 1999): bibliotecas espectrais elaboradas a partir de espectrorradiometria de campo ou laboratório; bibliotecas espectrais elaboradas a partir de estudos anteriores com MLME; ou a partir de *pixels* considerados “puros” para um determinado alvo, selecionados na própria imagem. Normalmente, a última opção é a mais empregada, considerando a dificuldade de encontrar um espectro puro, adequado ao objetivo da pesquisa, em uma biblioteca

espectral padrão; outro fator desfavorável é o elevado custo de um espectrorradiômetro de campo, cujo uso nem sempre é possível. Uma biblioteca espectral tida como ideal possui *endmembers* que, quando combinados linearmente, podem gerar todos os outros espectros contidos em uma imagem.

Nos casos em que a seleção de *endmembers* for realizada em um espaço amostral de *pixels* (ex. vermelho-infravermelho próximo), o analista deve se orientar pelo fato de que os componentes puros normalmente estão localizados nos extremos desta distribuição. Esta condição é conhecida também por “*simplex*”, com uma forma geométrica de um triângulo (Bajjouk et al., 1998). As **Figuras 2.15 e 2.16** ilustram esta regra.

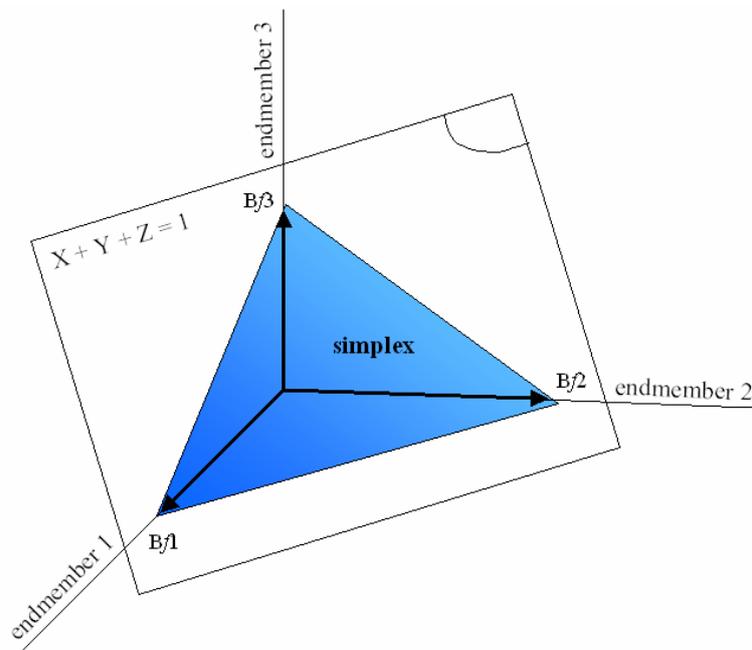


**Figura 2.15.** Distribuição dos *pixels* no espaço amostral vermelho- infravermelho próximo, onde a proximidade dos extremos favorece a busca por componentes espectralmente mais puros, como demonstrado pelo comportamento dos espectros.

De acordo com Schweik e Green (1999), no caso do sensor Landsat ETM+, o número de *endmembers* utilizados em um MLME não deve ultrapassar a quatro, devido

à alta correlação entre as bandas do espectro refletido. Uma regra estabelece esta relação entre o número de bandas ( $m$ ) disponíveis e os componentes puros ( $n$ ) possíveis de serem “desmisturados” pelo modelo linear:

- a)  $m = n$ : o sistema linear é “resoluto” ou decidido, onde uma solução é possível;
- b)  $m > n$ : uma solução é possível para um dado conjunto de *endmembers*, com um melhor ajuste dos dados. Os métodos CLS ou WLS podem ser empregados;
- c)  $m < n$ : há mais variáveis desconhecidas do que bandas, sem solução para o sistema.



**Figura 2.16.** Simplex de frações em um caso tridimensional, onde Bf1, Bf2 e Bf3 são as bases ortogonais para três *endmembers*, atendendo às restrições do método (Equação 2.7). Modificada de Bajjouk et al. (1998).

## CAPÍTULO 3

### MATERIAIS E MÉTODOS

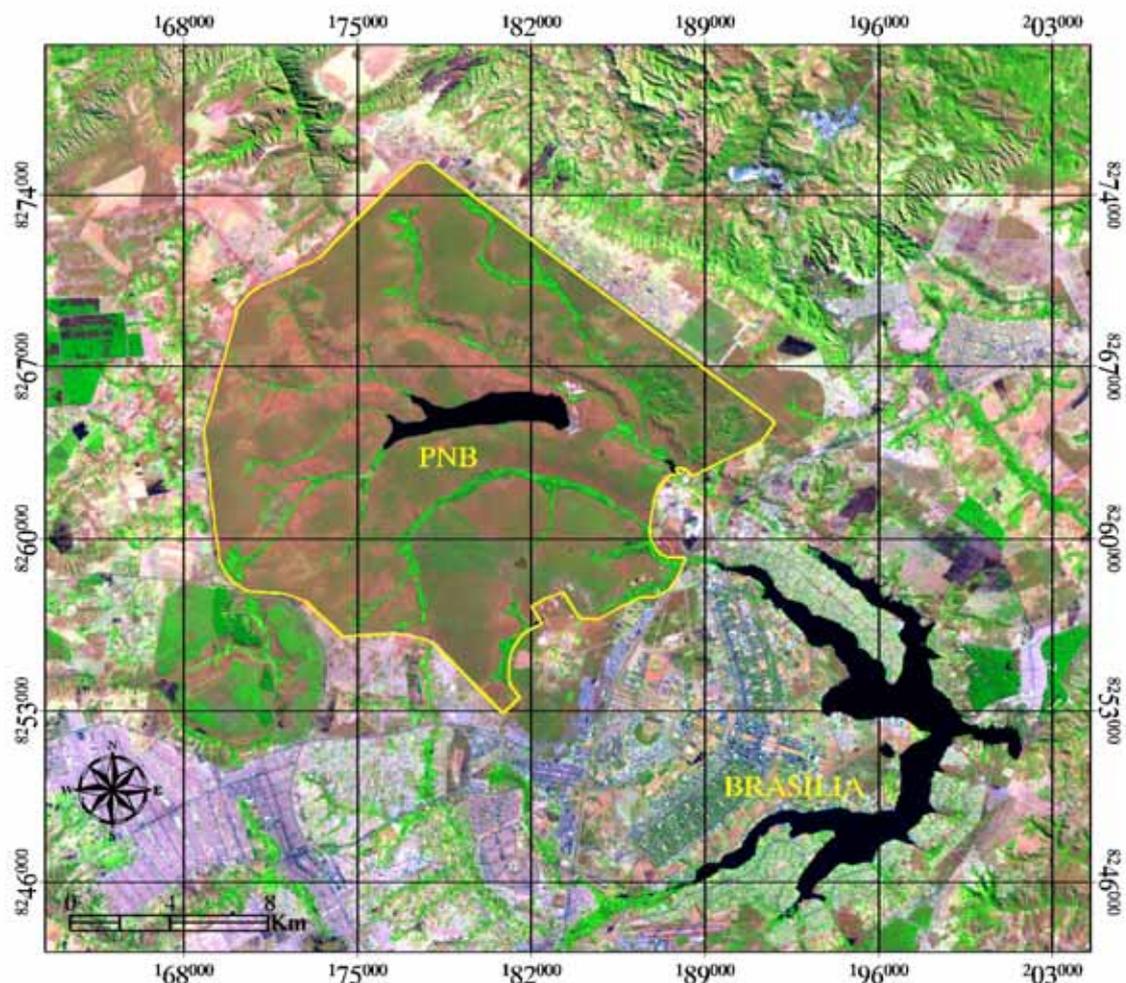
#### 3.1 - Área de Estudo

A área-teste para a análise do MLME no Cerrado foi o Parque Nacional de Brasília (PNB), selecionada pelos seguintes fatores: área relativamente extensa e preservada, com as principais fitofisionomias de Cerrado (Campo Limpo, Campo Sujo, Campo Cerrado, Cerrado *sensu stricto* e Mata de Galeria); disponibilidade de dados, incluindo espectrorradiometria de campo (espectros de referência) e imagens de satélite (cenas IKONOS e Landsat); e proximidade da cidade de Brasília, auxiliando as incursões à área de estudo, bem como na comparação de resultados com a realidade observada em campo.

O PNB (**Figura 3.1**), com uma extensão aproximada de 30 mil hectares, figura como a unidade de conservação de maior destaque no Distrito Federal. Tal importância se deve à presença de inúmeras espécies representativas da fauna e flora do bioma Cerrado, assim como importantes mananciais hídricos, responsáveis pelo abastecimento de água em Brasília.

No PNB estão reunidas as principais fitofisionomias do bioma Cerrado, subdivididas em três estratos vegetacionais, de acordo com a classificação definida por Ribeiro e Walter (1998): Campo Limpo (CL) e Campo Sujo (CS) (estrato herbáceo-arbustivo); Campo Cerrado (CC) e Cerrado *sensu stricto* (CSS) (estrato arbóreo); e Mata de Galeria (MG) (estrato arbóreo). O Cerradão, classe pertencente ao estrato arbóreo do Cerrado, não é encontrado no parque. A **Tabela 3.1** apresenta algumas propriedades das respectivas classes de vegetação.

Segundo a carta climática do Distrito Federal, a região do Parque Nacional de Brasília está submetida, basicamente, a dois tipos de clima, definidos de acordo com a temperatura local (classificação de Köppen) (**Figura 3.2**): o Cwa, tropical de altitude com temperatura do mês mais frio a 18° C, e média do mês mais quente superior a 22° C (cotas altimétrica de 1000 a 1200 metros); e o Cwb, tropical de altitude com temperatura do mês mais frio inferior a 18° C, e média do mês mais quente inferior a 22° C (cotas altimétricas acima de 1.200 metros).



**Figura 3.1.** Imagem do Parque Nacional de Brasília (composição colorida RGB 543, julho de 2001), obtida pelo satélite Landsat 7 ETM+.

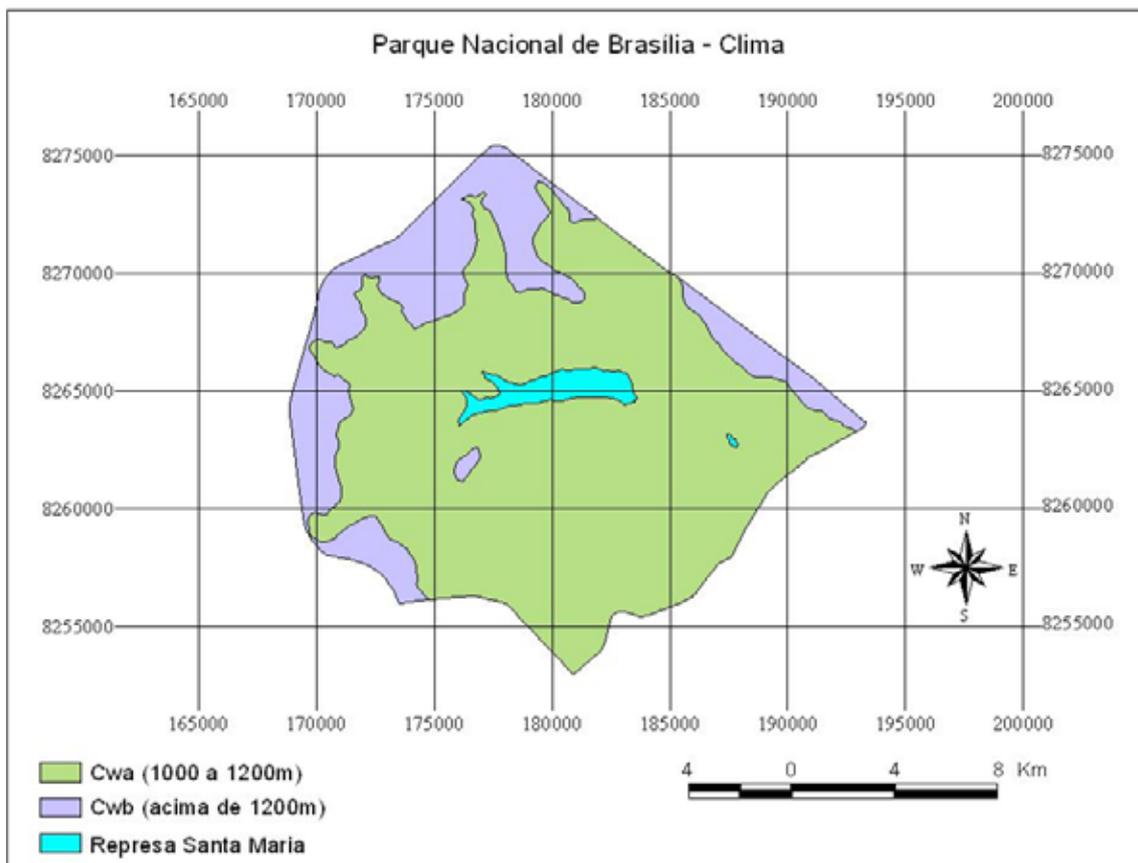
**Tabela 3.1.** Propriedades das classes de Cerrado encontradas no PNB.

Formação do Cerrado <sup>a</sup>	Características da paisagem	Cobertura arbórea (%) <sup>b</sup>	Altura média das árvores (m) <sup>b</sup>
Campo Limpo	Campo aberto	< 1	-
Campo Sujo	Campo aberto com arbustos espaçados	< 5	2
Campo Cerrado	Arbustos com árvores espaçadas	5-20	2-3
Cerrado <i>sensu stricto</i>	Mistura de campo, arbustos e árvores com mais de sete metros	20-50	3-6
Mata de Galeria	Vegetação densa, sempre verde, principalmente ao longo de cursos d'água	40-70% na estação seca; 50-90% na estação chuvosa	20-30

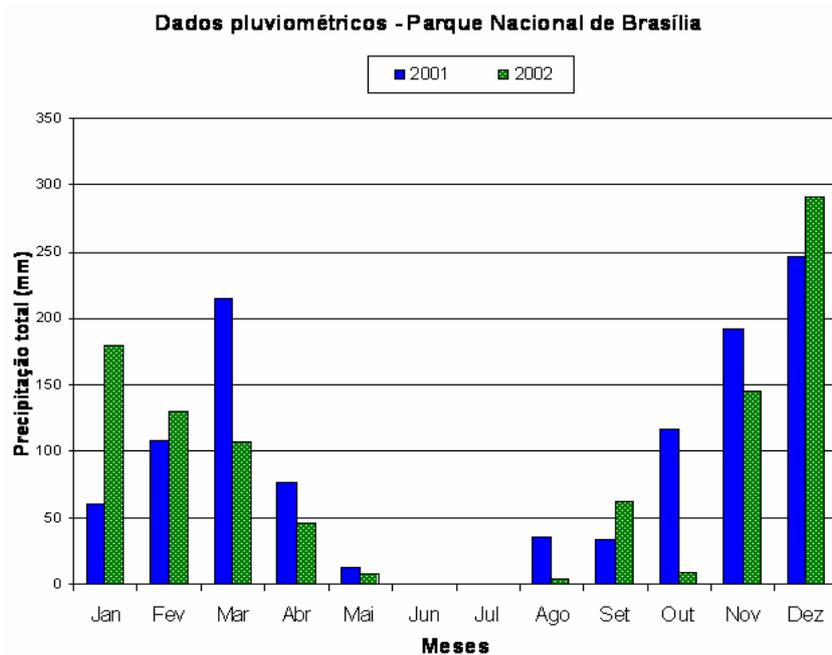
<sup>a</sup> Sistema de classificação / <sup>b</sup> valores propostos por Ribeiro e Walter (1998).

A precipitação no PNB segue um padrão característico do centro-oeste brasileiro, isto é, chuvas nos meses de outubro a março, com máxima nos meses de dezembro e janeiro. A época seca se estende pelos meses de abril a setembro, sendo junho e julho os meses mais críticos (**Figura 3.3**). A ausência de nuvens, principalmente em julho, foi um dos motivos para a aquisição de uma imagem Landsat 7 ETM+ (utilizada nos processamentos) para o mesmo período em 2001.

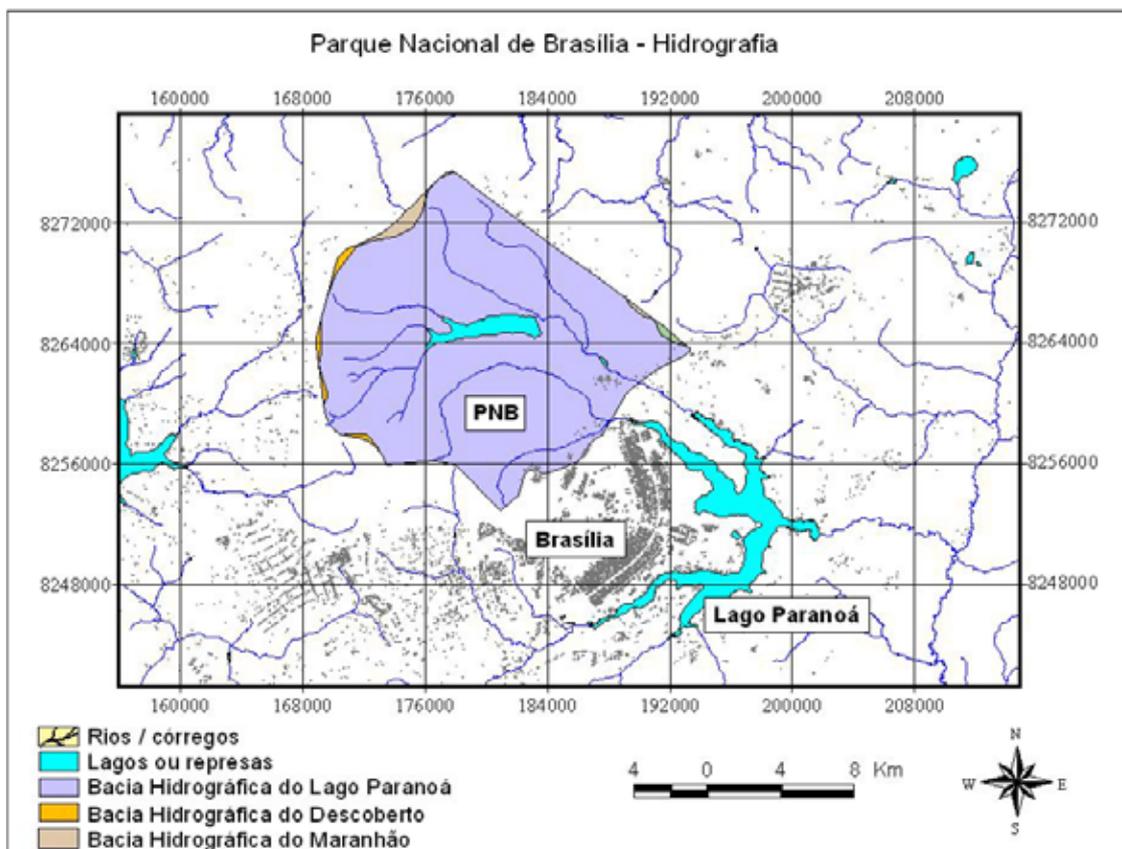
O Parque Nacional de Brasília está situado em um divisor de águas entre as Bacias Amazônica e Paraná (cota altimétrica de 1.000 metros), numa área de importantes nascentes (Guimarães, 2000), praticamente dentro da bacia hidrográfica do Lago Paranoá. Outras duas bacias são encontradas nas bordas do parque: a Bacia do Descoberto e a Bacia do Maranhão. Alguns cursos d'água na região sul do parque desembocam no Lago Paranoá, como o Córrego do Acampamento, Ribeirão do Bananal e Ribeirão do Torto (**Figura 3.4**).



**Figura 3.2.** Mapa climático do PNB. Fonte (base cartográfica digital): CODEPLAN (1996).



**Figura 3.3.** Dados de precipitação total (mm) no Parque Nacional de Brasília, para os anos de 2001 (azul) e 2002 (verde). Estação pluviométrica de Santa Maria - CAESB, Latitude Sul 15° 40' 00" e Longitude Oeste 47° 57' 57".



**Figura 3.4.** Mapa de hidrografia do PNB e entorno. Fonte (base cartográfica digital): CODEPLAN (1996).

Os principais grupos de solos encontrados no PNB são os Latossolos Vermelho-Escuro e Vermelho-Amarelo (cerca de 38%), os Cambissolos (cerca de 22%) e os Solos Hidromórficos (Ramos, 1995) (**Figura 3.5**). Os demais grupos, como os Podzólicos hidromórficos, aparecem em trechos isolados.

Os Latossolos são solos profundos, caracterizados por uma textura argilosa ou média, porosos, e bastante permeáveis. No Cerrado em geral, o estrato arborescente está mais associado às áreas com um relevo plano a suavemente ondulado, encontrando-se fitofisionomias como o Cerradão, Cerrado *sensu stricto* e o Campo Cerrado (Pinheiro, 1999; Guimarães, 2000). Já os Cambissolos são pouco desenvolvidos (horizonte B câmbico e minerais primários), com baixa fertilidade e facilmente intemperizados. No PNB, este tipo de solo favorece o desenvolvimento de fisionomias do estrato herbáceo-arbustivo, como as classes Campo Limpo e Campo Sujo, por exemplo.

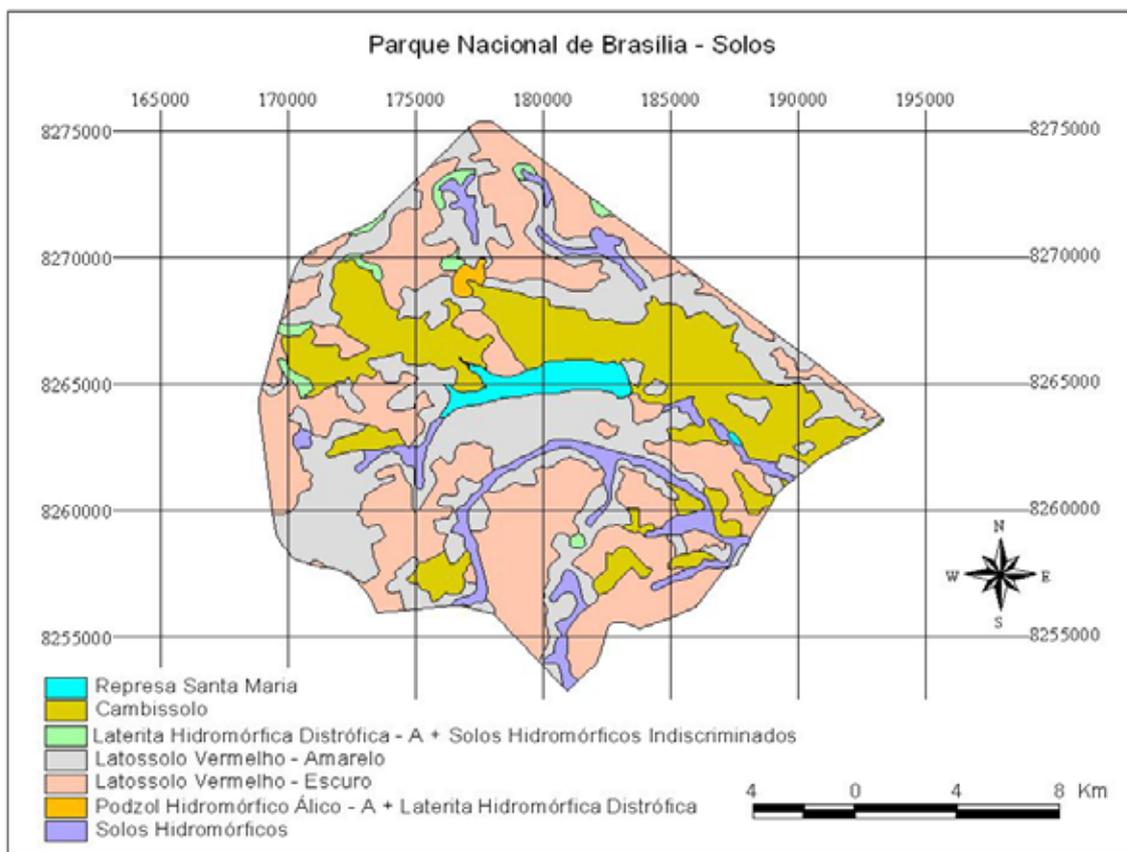
Finalmente, os solos hidromórficos são observados no PNB em torno de drenagens ou pequenos córregos, estando associados ao afloramento do lençol freático. Com um horizonte A bem desenvolvido, a vegetação nesse solo é marcada principalmente pela presença dos campos de murundus (pequenos morros, cobertos com vegetação rala, e com o solo rebaixado em volta, devido ao maior acúmulo de água), associada com outras classes de Cerrado, tal como o Campo Limpo, Campo Limpo Úmido e Campo Sujo.

O Distrito Federal é caracterizado pela presença de rochas metamórficas (baixo grau de metamorfismo), com coberturas de solos, diferenciando dois grandes grupos de aquíferos: domínio poroso e domínio fraturado. As aluviões e a cobertura detrítico-laterítica/Latossolos caracterizam o meio poroso; já as rochas metamórficas, do Grupo Paranoá, compõem os subsistemas fraturados. A vazão de cada aquífero vai depender, por exemplo, do uso e ocupação do solo, do volume de precipitação, do relevo das bacias e da geomorfologia da região (Guimarães, 2000).

O Domínio Poroso na região do Parque Nacional de Brasília é dividido em quatro sistemas (Freitas-Silva, 1998): P1 e P2, que englobam toda a área do PNB; e P3 e P4, que ocorrem nas porções NW e NE do parque, respectivamente. As características deste domínio estão descritas na **Tabela 3.2**.

Em linhas gerais, a geologia no PNB é caracterizada por duas grandes unidades litofaciológicas, pertencentes à seqüência psamo-pelítica do Grupo Paranoá: uma litofácie basal (unidade das ardósias), constituída por sucessão composta predominantemente por ardósias, e uma litofácie de topo (unidade dos metarritmitos), caracterizada por metarritmitos com intercalações de quartzitos (Freitas-Silva e Campos, 1995).

A unidade das ardósias é pouco visível no PNB devido à sua baixa resistência aos processos de intemperismo na região. Fácies alteradas e parcialmente alteradas afloram, de forma descontínua, em voçorocas, e em algumas drenagens (localmente). Sobre esta unidade, desenvolvem-se espessos latossolos. O contato com a unidade dos metarritmitos ocorre próximo à Represa de Santa Maria, cuja fácies é recoberta na maior parte por Latossolos (**Figura 3.6**).

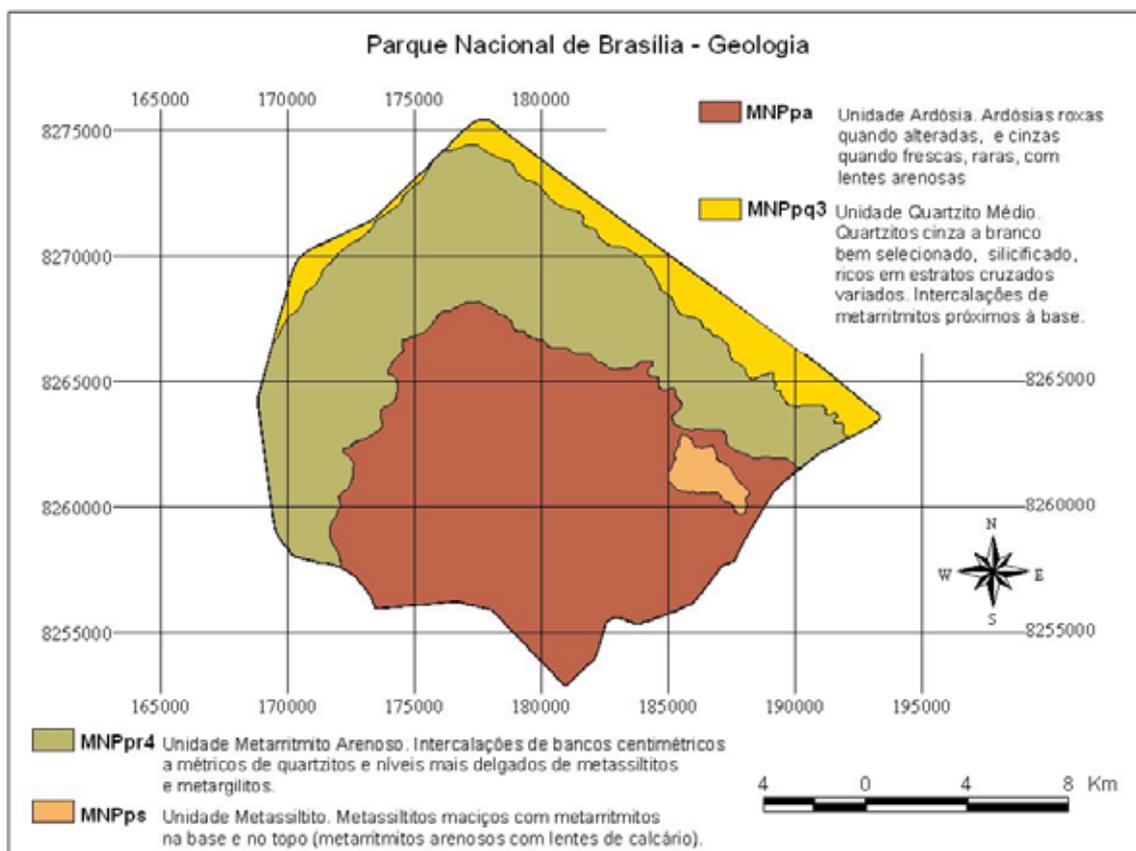


**Figura 3.5.** Mapa de solos do PNB. Fonte (base cartográfica digital): Embrapa Cerrados (1978).

**Tabela 3.2.** Características do Domínio Poroso.

Domínios	P1	P2	P3	P4
<b>Tipos de aquífero</b>	Intergranulares, contínuos, livres e de grande extensão lateral.	Intergranulares, contínuos, livres e de grande distribuição lateral.	Intergranulares, contínuos, livres, com distribuição lateral ampla.	Intergranulares, contínuos, livres e muito restritos lateralmente.
<b>Condutividade hidráulica</b>	Alta	Média	Baixa	Muito baixa
<b>Espessura média do saprólito (m)</b>	20	>20	<15	<1
<b>Vazão dos poços (l/h)</b>	<800	<800	<800	<800
<b>Importância hidrogeológica</b>	Elevada	Mediana	Pequena	Muito pequena
<b>Solos</b>	Latossolo Vermelho-Amarelo, textura média (arenosa) e areias quartzosas.	Latossolo Vermelho-Amarelo argiloso.	Latossolo Vermelho-Amarelo argiloso e localmente com Cambissolos.	Cambissolos litólicos rasos com fragmentos de xisto e filitos.

Fonte: Freitas-Silva (1998).



**Figura 3.6.** Mapa das unidades geológicas no PNB. Fonte (base cartográfica digital): Freitas-Silva e Campos (1995).

### 3.2 - Atualização do Mapa de Vegetação do PNB

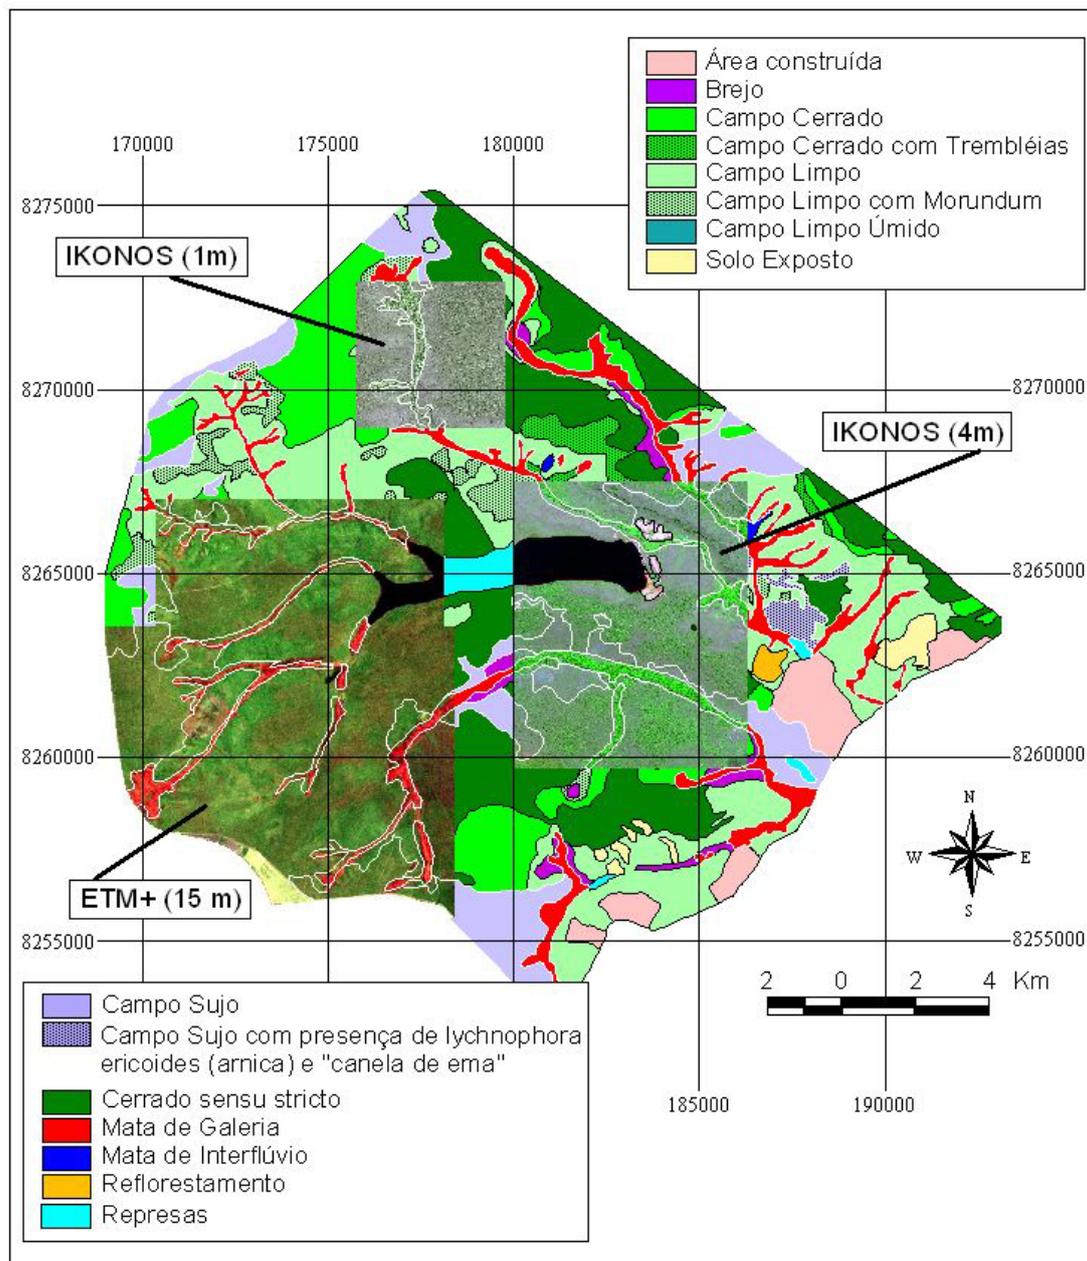
O atual mapa de vegetação do PNB foi utilizado como verdade terrestre nesta pesquisa, auxiliando na análise dos modelos lineares aplicados às imagens ETM+ no Cerrado. Em virtude disto, o antigo mapa de vegetação precisou ser atualizado, com a finalidade de garantir uma acurácia maior na verificação do Modelo Linear de Mistura Espectral.

Dois cenas do sensor orbital IKONOS-II (órbita 31 / ponto 72, junho de 2001) foram empregadas nesta atualização, cobrindo parcialmente as porções leste e oeste da área de estudo (**Figura 3.7**). Com resoluções espaciais de 1 metro (banda *pancromática*) e de 4 metros (bandas *azul, verde, vermelho e infravermelho próximo*), foi possível corrigir parte das falhas observadas no mapeamento anterior.



**Figura 3.7.** Cenas do satélite IKONOS cobrindo cerca de 61% da área do PNB (composição RGB 123).

Em virtude das duas cenas IKONOS, adquiridas pelo projeto LBA, cobrirem somente 61% da área do parque, utilizou-se uma terceira imagem adquirida pelo satélite Landsat ETM+ (221/71, setembro de 2001) para recobrir o restante da área a ser mapeada. A **Tabela 3.3** resume as características de ambos os sensores. Visando uma melhor definição das fitofisionomias de Cerrado, obteve-se ainda uma combinação das bandas 3, 4 e 5 (resolução espacial de 30 metros) com a banda 8 (banda pancromática, com resolução espacial de 15 metros) do sensor ETM+. A **Figura 3.8** ilustra a interpretação visual destas imagens e a vetorização das classes do mapa atual.



**Figura 3.8.** Atualização do mapa de vegetação do PNB, por meio das cenas ETM+ e IKONOS.

**Tabela 3.3.** Características gerais dos sensores Landsat ETM+ e IKONOS.

Landsat ETM+		Bandas	Resolução espectral	Resolução espacial	
<b>Resolução temporal</b>	16 dias	Visível	Azul	1) 0,45 - 0,52 $\mu\text{m}$	30 m
<b>Período</b>	98,9 min		Verde	2) 0,52 - 0,60 $\mu\text{m}$	30 m
<b>Altitude</b>	705 km		Verm.	3) 0,63 - 0,69 $\mu\text{m}$	30 m
<b>Inclinação</b>	98,5°	Infravermelho Próximo		4) 0,76 - 0,90 $\mu\text{m}$	30 m
<b>Órbita</b>	Sol-síncrona, descendente	Infravermelho Médio		5) 1,55 - 1,75 $\mu\text{m}$	30 m
<b>Passagem Pelo Equador</b>	10:00 h.	Infravermelho Termal		6) 10,4 - 12,5 $\mu\text{m}$	60 m
<b>Faixa de Imageamento</b>	170 km (comp.) x 183 km (largura)	Infravermelho Médio		7) 2,08 - 2,35 $\mu\text{m}$	30 m
		Pancromático		8) 0,50 - 0,90 $\mu\text{m}$	15 m

IKONOS		Canais	Resolução espectral	Resolução espacial	
<b>Resolução temporal</b>	~36 h. (multi-espectral) e 72 h. (Pan)	Visível	Azul	1) 0,45 - 0,52 $\mu\text{m}$	4 m
<b>Período</b>	98 min.		Verde	2) 0,52 - 0,60 $\mu\text{m}$	4 m
<b>Altitude</b>	681km		Verm.	3) 0,63 - 0,69 $\mu\text{m}$	4 m
<b>Inclinação</b>	98,1°	Infravermelho Próximo		4) 0,76 - 0,90 $\mu\text{m}$	4 m
<b>Órbita</b>	Sol-síncrona, descendente	Pancromático		5) 0,45 - 0,90 $\mu\text{m}$	1 m
<b>Passagem Pelo Equador</b>	-				
<b>Faixa de Imageamento</b>	13 km x 13 km				

Os dados vetoriais do mapeamento anterior foram utilizados como orientação aos ajustes realizados sobre as imagens de sensoriamento remoto, indicando a necessidade de alteração/complemento em cada polígono de vegetação.

Essa etapa de atualização contou também com incursões à área de estudo (**Figura 3.9**), onde foi verificada a interpretação visual provida por essas cenas de satélite. Ressalta-se aqui a importante contribuição do pesquisador **George Eiten** nos trabalhos

de campo, o qual indicou algumas das alterações apresentadas na classificação e na nomenclatura do atual mapa de vegetação. Parte dessas contribuições, essenciais na identificação de algumas fitofisionomias de Cerrado, estão presentes em Eiten (2001).



**Figura 3.9.** Incursões no Parque Nacional de Brasília, durante a realização do novo mapa de vegetação (out./2002).

### 3.3 - Geração das Imagens Fração

As Imagens Fração (IF) foram geradas a partir de uma cena ETM+ do Parque Nacional de Brasília, obtida em 20 de julho de 2001 (época seca), em escala de cinza e reflectância (correção atmosférica realizada com o método 6S). As restrições apresentadas na Equação 2.7 foram aplicadas no MLME, através do método WLS (*Weighted Least Square*), estimando-se a proporção para cada componente no *pixel*, de acordo com os modelos lineares apresentados neste estudo. Para evitar qualquer influência nos resultados, optou-se por não utilizar a mesma cena ETM+ empregada na atualização do mapa de vegetação (221/71, set./2001).

### 3.3.1 - Modelos Lineares

Dois modelos lineares foram utilizados na geração das IF. O primeiro modelo, geral, foi elaborado por *endmembers* obtidos na própria imagem, enquanto que o segundo modelo, específico, foi subdividido em dois grupos: *endmembers* obtidos na própria imagem, e por espectrorradiometria de campo (espectros de referência).

#### Modelo geral (Imagem)

O modelo geral foi constituído pelos componentes *vegetação*, *solo* e *sombra*. Toda imagem de sensoriamento remoto, com resolução espacial de média a alta (30 a 15 metros), apresenta diferentes proporções de vegetação e solo, com um componente *sombra* variando de acordo com as características estruturais do dossel. O componente *água* apresenta a mesma resposta espectral da *sombra*. Normalmente, a soma linear destes três *endmembers* contempla a variabilidade natural dos alvos numa imagem Landsat.

Este modelo foi aplicado na cena ETM+ com *pixels* na forma de valores digitais (VD) e reflectância (R) (bandas 1-5 e 7). Nesse caso, os objetivos foram avaliar o potencial do método na discriminação das fitofisionomias de Cerrado, além de verificar a intensidade da interferência atmosférica na geração das IF.

#### Modelo específico (Imagem e Referência)

Constituído pelos componentes *Campo Limpo*, *Campo Sujo* e *Cerrado sensu stricto*, o modelo específico baseia-se na hipótese de que este bioma é constituído pela mistura de três estratos fisionômicos (herbáceo, arbustivo e arbóreo), onde a maior ou menor proporção dos componentes representa uma base para a classificação das principais fitofisionomias do Cerrado (*Campo Limpo*, *Campo Sujo*, *Campo Cerrado* e *Cerrado sensu stricto*). Sendo assim, e de acordo com essa hipótese, uma imagem orbital do PNB poderia ser modelada com o emprego destes três *endmembers*.

Tal modelo foi aplicado apenas na cena ETM+ em nível de reflectância, com os alvos Mata de Galeria (vegetação densa), solo exposto e água (ou sombra) retirados da imagem por meio de máscaras. Foi restringido, assim, a aplicação do método às fitofisionomias de Cerrado com maior associação espectral, verificando-se o desempenho do MLME na discriminação dessas classes de vegetação. Ao mesmo

tempo, foram avaliadas as possíveis diferenças das IF obtidas com *endmembers* da própria imagem daquelas obtidas com *endmembers* de referência (espectrorradiômetro aerotransportado no PNB).

Em relação às máscaras, optou-se por um método cuja subjetividade fosse a menor possível, fundamentado em índices de vegetação (NDVI). Os seguintes intervalos foram utilizados: Mata de Galeria (0,65 a 0,92), solo exposto (0,023 a 0,17), água (0 a 0,02). Estes parâmetros referem-se ao sensor ETM+ da época seca e podem ser modificados por fatores intrínsecos e/ou espúrios ao imageamento, tal como ruídos, diferenças atmosféricas ou propriedades do alvo. A **Figura 3.10** ilustra a cena ETM+ com as respectivas máscaras, seguida pela nova distribuição dos *pixels* para esta análise, no espaço vermelho-infravermelho próximo.

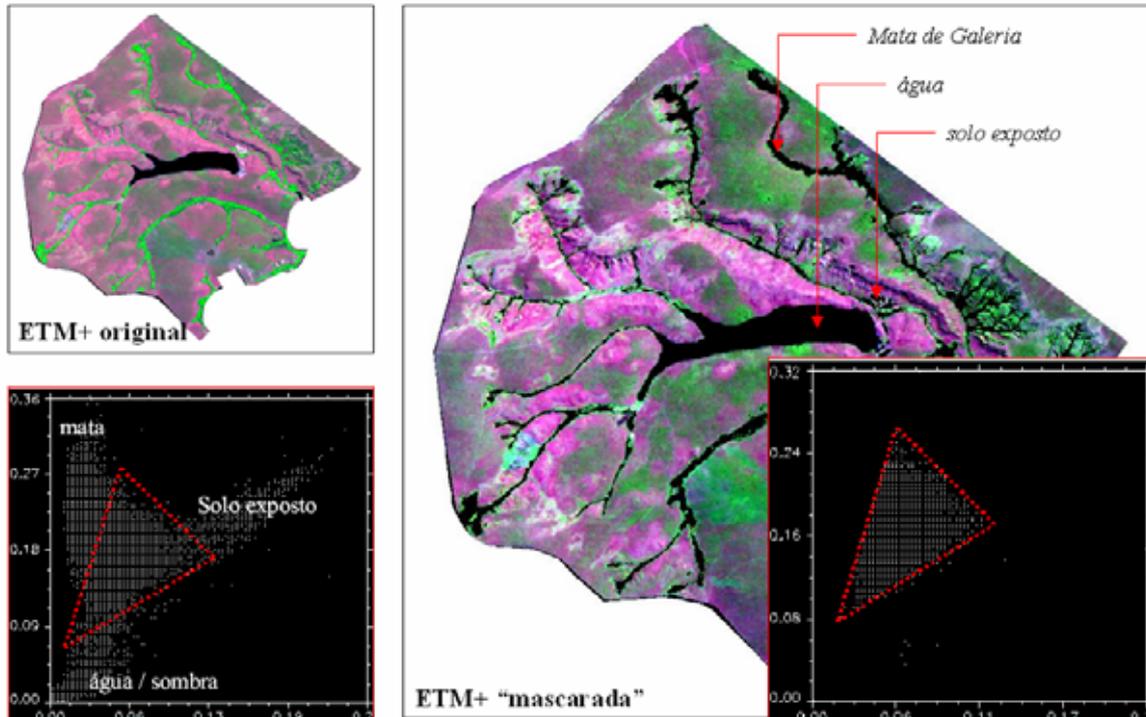
### 3.3.2 - Elaboração das Bibliotecas Espectrais (*Imagem e Referência*)

A biblioteca espectral relativa ao modelo linear geral foi elaborada com base na média de 100 *pixels* tidos como puros para cada componente, coletados diretamente nas imagens ETM+ Valor Digital (VD) e Reflectância (R), com a mesma localização em ambas as cenas. A seleção foi baseada nas características visuais do alvo e na distribuição dos *pixels* no espaço amostral vermelho - infravermelho próximo, considerando a teoria do “*simplex*” (Bajjouk et al., 1998).

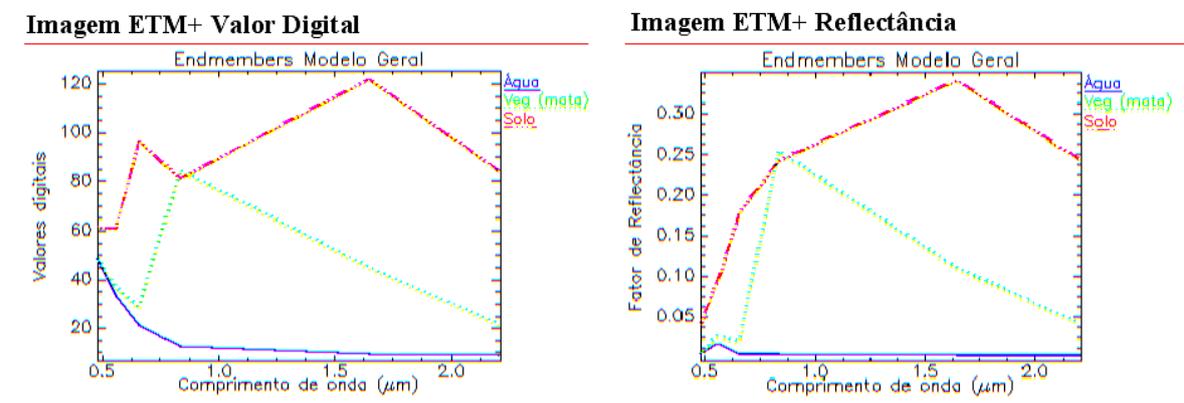
O componente *vegetação* foi amostrado em áreas com Mata de Galeria, por ser esta a classe de maior vigor vegetacional no PNB. Amostras dos componentes *solo* e *sombra* foram obtidas em áreas na imagem com solo exposto e água (represa Santa Maria), respectivamente. A **Figura 3.11** ilustra esta biblioteca espectral, com e sem correção atmosférica.

A segunda biblioteca espectral, referente ao modelo linear específico (Campo Limpo, Campo Sujo e Cerrado *sensu stricto*), foi elaborada por *endmembers* obtidos na própria imagem ETM+ Reflectância (com máscara), e por *endmembers* gerados através de espectrorradiometria aérea no PNB. Os procedimentos utilizados na seleção de amostras na imagem foram semelhantes aos do primeiro modelo, isto é, as curvas para cada componente foram originadas de uma média de 100 *pixels* considerados como puros. Uma coleta individual, com apenas um *pixel* “puro”, também foi realizada, a fim

de comparar os métodos de extração; neste caso, as curvas espectrais isoladas foram muito semelhantes aos espectros médios, porém, com uma dificuldade maior na busca por uma curva que melhor representasse o alvo.



**Figura 3.10.** Imagem ETM+ do Parque Nacional de Brasília, com e sem os alvos Mata de Galeria, solo exposto e água, seguida pela nova distribuição dos *pixels* no espaço vermelho (x) - infravermelho próximo (y).



**Figura 3.11.** Biblioteca espectral referente ao modelo linear geral, para as imagens ETM+ Valor Digital e Reflectância.

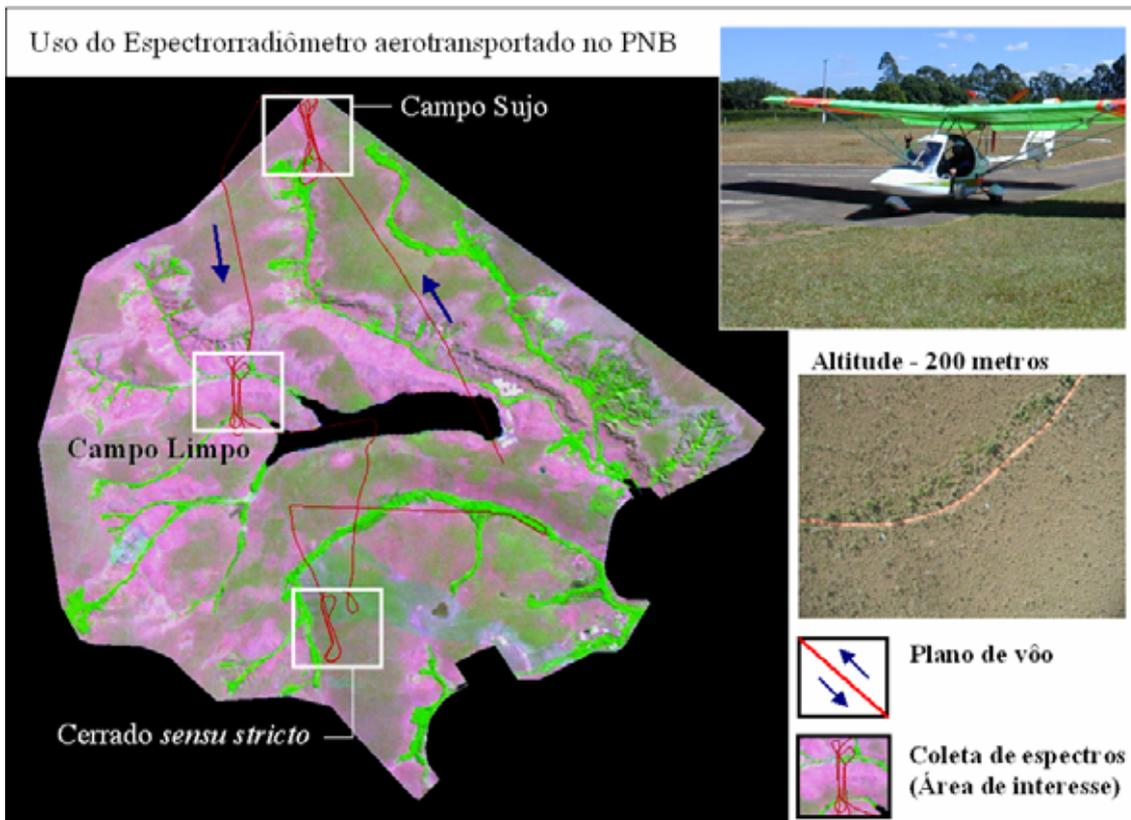
Os *endmembers* de referência foram originados por espectrorradiometria aérea no PNB (julho de 2001), sempre no período da manhã, observando-se a ausência de nuvens na área sobrevoada. O espectrorradiômetro utilizado foi o modelo portátil FieldSpec Pro FR (**Figura 3.12**), produzido pela Analytical Spectral Devices (ASD Inc., Boulder - Colorado, EUA). Este instrumento, a bordo de um ultraleve (**Figura 3.13**), registrou a resposta espectral da vegetação na faixa de 350 a 2500 nm., permanecendo a uma altitude constante de 200 metros.



**Figura 3.12.** Ilustração do espectrorradiômetro utilizado na pesquisa, modelo FieldSpec Pro FR (350 - 2500 nm), produzido pela Analytical Spectral Devices (ASD Inc.).

Em laboratório, os espectros foram selecionados de acordo com a localização dos alvos na cena ETM+ do parque (Campo Limpo, Campo Sujo e Cerrado *sensu stricto*), utilizando-se como guia os vetores do mapa de vegetação atualizado. Os espectros mais adequados (variando de 350 a 2.500 nm) foram convolvidos para as seis bandas do sensor ETM+ (bandas 1 - 5 e 7), compondo-se uma biblioteca espectral de referência (média dos espectros obtidos na área de estudo). A **Figura 3.14** ilustra esta etapa.

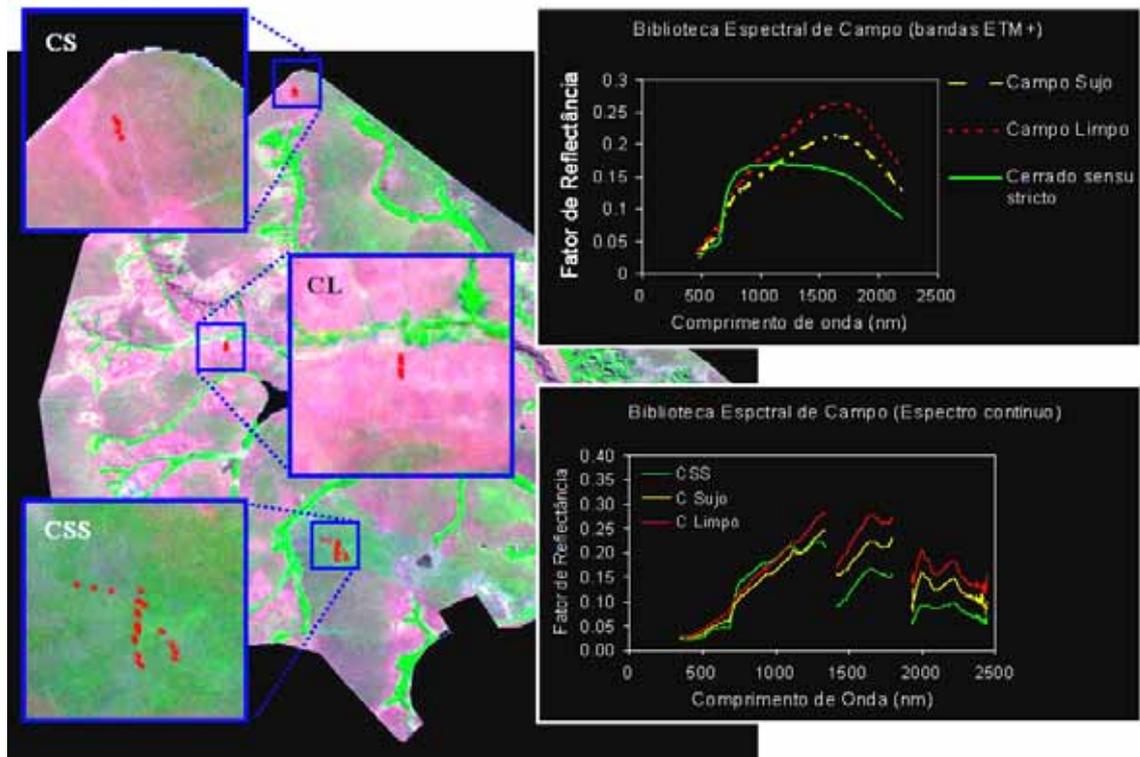
Em relação à data de obtenção dos dados de sensoriamento remoto, tanto para a imagem ETM+ como para as medidas espectrorradiométricas, optou-se pelo mês de julho (estação seca em Brasília), quando a contaminação atmosférica por vapor d'água (nuvens) é menor. Embora o Índice de Área Foliar decresça neste período de estiagem, tal fato não interfere na discriminação das classes de Cerrado, pois esta variação é proporcional a todas as fitofisionomias abordadas no estudo com o MLME (em média 20% para CL e CS; 12% para CC e CSS; e 5% para MG). Por outro lado, a imagem de satélite obtida durante a seca apresenta uma influência maior do solo, o que vem a contribuir para a geração e análise da respectiva Imagem Fração (*solo*).



**Figura 3.13.** Procedimentos realizados no Parque Nacional de Brasília para a análise das fitofisionomias Campo Limpo, Campo Sujo e Cerrado *sensu stricto* (modelo linear específico), por meio de espectrorradiometria aérea.

### 3.3.3 - Uso da Técnica de Fração de Ruído Mínimo (*Minimum Noise Fraction*)

Imagens fração do Parque Nacional de Brasília também foram geradas a partir de bandas sintéticas resultantes da técnica *Minimum Noise Fraction* (MNF). Neste caso, os *endmembers* Campo Limpo, Campo Sujo e Cerrado *sensu stricto* (modelo específico) foram obtidos na própria imagem MNF (seis bandas), utilizando-se uma composição colorida RGB das MNF 1, 2 e 3. O MLME foi aplicado em seguida, apenas para as MNF 1 e 2, onde estão concentrados cerca de 98% das informações inerentes à imagem original, sem ruídos. A **Figura 3.15** ilustra a imagem MNF, com a respectiva biblioteca espectral no espaço MNF (bandas 1 a 6) e no espaço original ETM+ (bandas 1-5 e 7). As categorias de imagens (dados de entrada), modelos lineares, grupos de *endmembers* e processamentos realizados estão agrupados na **Tabela 3.4**.

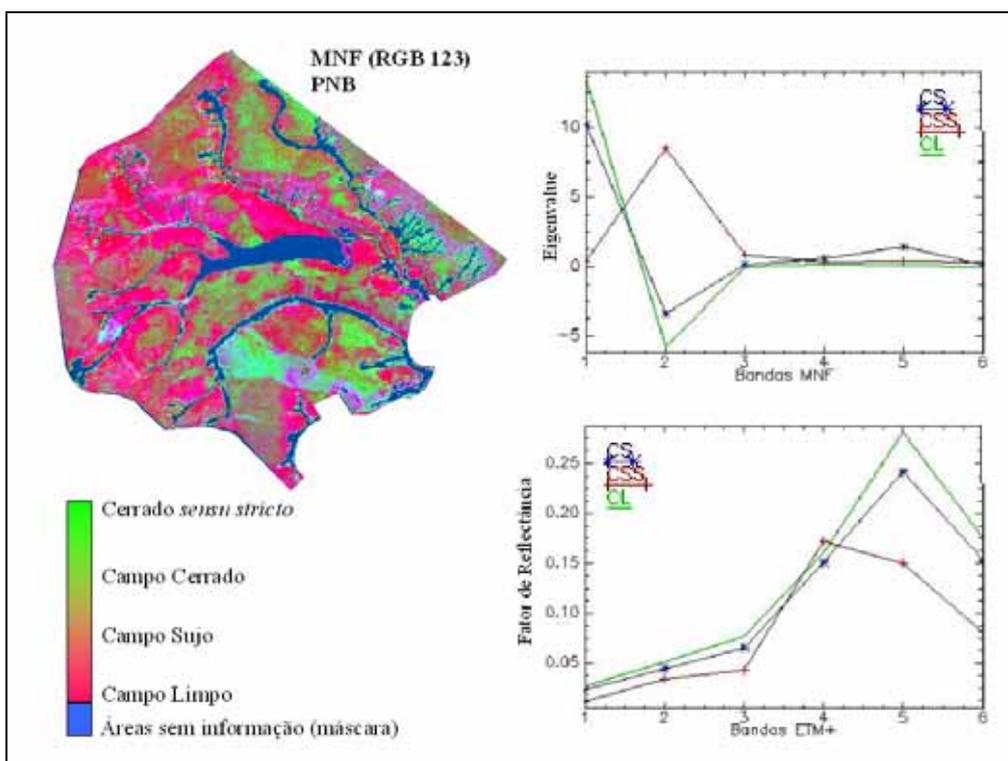


**Figura 3.14.** Seleção das curvas espectrais obtidas para as fitofisionomias Campo Limpo, Campo Sujo e Cerrado *sensu stricto* (modelo linear específico), a partir dos dados de espectrorradiometria aérea gerados no Parque Nacional de Brasília.

### 3.4 - Análise Estatística dos Dados

#### 3.4.1 - Amostras

Num primeiro momento, foram adquiridas, nas imagens ETM+ (bandas 1-5 e 7), Imagens Fração (VD e R) e imagem NDVI, 150 amostras de *pixels* por classe de vegetação (Campo Limpo - CL, Campo Sujo - CS, Campo Cerrado - CC, Cerrado *sensu stricto* - CSS, e Mata de Galeria - MG), 50 amostras para a classe Solo exposto e 50 amostras para a classe Água. A obtenção dessas amostras foi orientada pelo mapa de vegetação atualizado. Na imagem ETM+ *máscara*, e nas respectivas IF originadas desta cena, as 150 amostras de *pixels* ficaram restritas às classes CL, CS, CC e CSS (**Figura 3.16**).

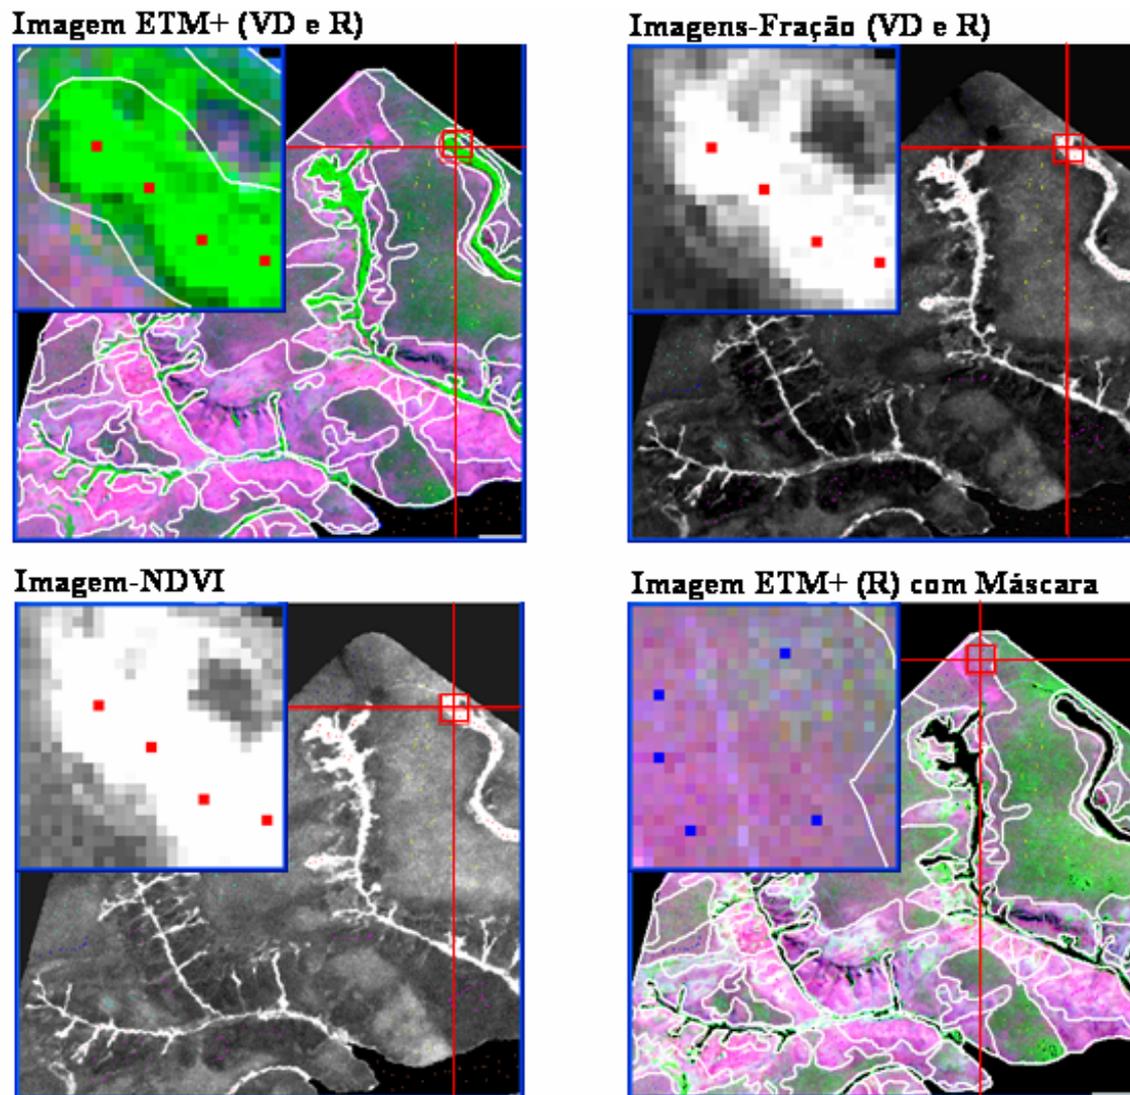


**Figura 3.15.** Imagem MNF (RGB 123) do Parque Nacional de Brasília, com as curvas espectrais para os endmembers Campo Limpo, Campo Sujo e Cerrado *sensu stricto* no espaço MNF e no ETM+.

**Tabela 3.4.** Categorias de imagens, modelos lineares, fonte de *endmembers* e processamentos utilizados para análise do MLME no Parque Nacional de Brasília.

Imagens (entrada)	Modelos Lineares			Processamentos		
	Geral	Específico		NDVI	MNF	Imagens -Fração
	Endmembers Imagem	Endmembers Imagem	Endmembers Referência			
ETM+ Valor Digital	x	-	-	x		x
ETM+ Reflectância	x	-	-	-	x	x
ETM+ R (máscara*)	-	x	x	-		x
Imagem MNF	-	x	-	-		x

\* Máscara para os alvos Mata de Galeria, solo e água (represa Santa Maria), restringindo o modelo linear específico às fitofisionomias de Cerrado.



**Figura 3.16.** Amostras de *pixels* obtidas nas diversas categorias de análise. VD = Valor Digital, R = Reflectância.

### 3.4.2 - Análise Discriminante e Separabilidade entre Classes

O potencial das imagens fração para o Cerrado foi medido principalmente por meio da aplicação de um modelo estatístico baseado na Distância de Mahalanobis (para duas ou mais variáveis) (Schowengerdt, 1997). Geraram-se, assim, as Análises Discriminante (matrizes de classificação), seguido pela respectiva Matriz “F” (Estatística F), a qual indica o grau de separabilidade destas classes de vegetação.

Inicialmente, foram avaliadas as IF (*endmembers* - imagem) obtidas pelo modelo linear geral (vegetação, solo e sombra), observando-se cinco classes de Cerrado no

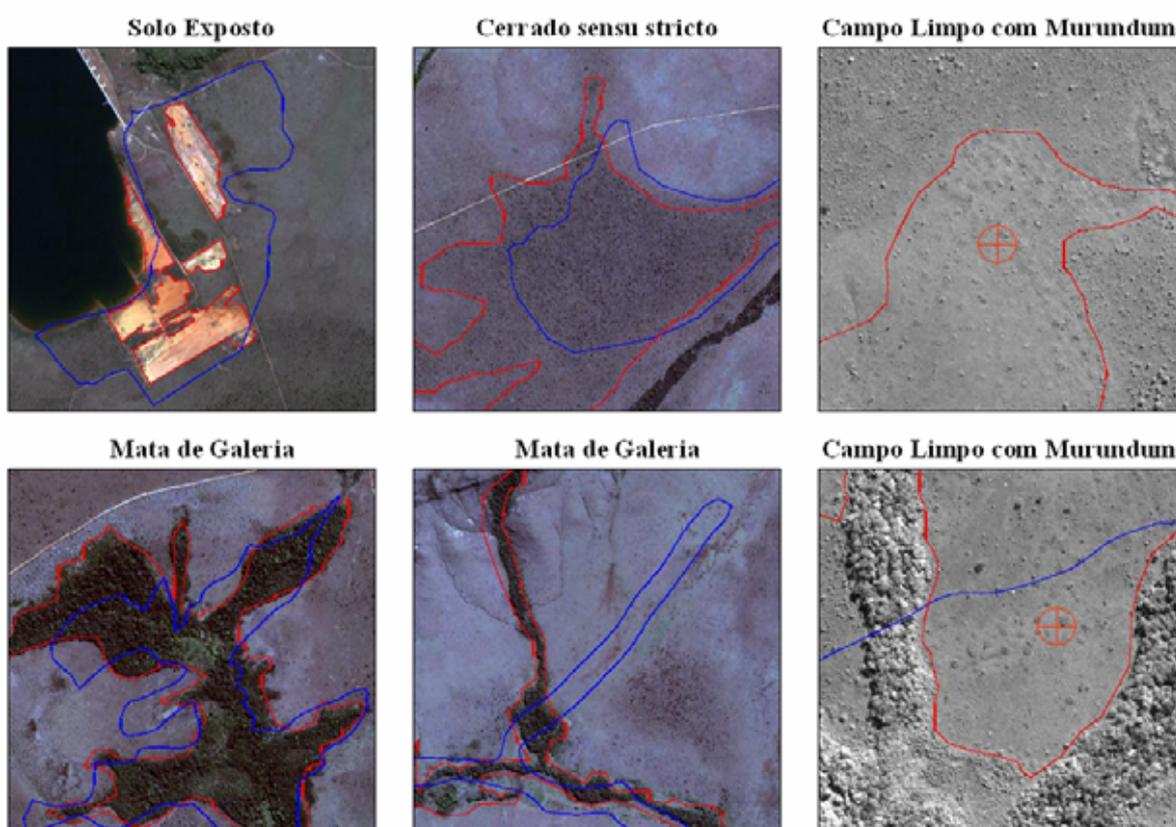
PNB, além do solo e da água: CL, CS, CC, CSS e MG. A análise estatística foi repetida para a Imagem NDVI e para a cena ETM+ (bandas 1-5 e 7). Num segundo momento, foram avaliadas as IF (*endmembers - Referência e Imagem*) resultantes do modelo linear específico para o Cerrado (CL, CS e CSS), observando-se o comportamento das quatro principais fitofisionomias deste bioma: CL, CS, CC e CSS.

## CAPÍTULO 4

### RESULTADOS E DISCUSSÕES

#### 4.1 - Mapa de Vegetação Atualizado do PNB

A principal diferença entre o mapa atual de vegetação do Parque Nacional de Brasília e o mapeamento anterior, elaborado em 1995 pela Fundação Pró-Natureza (FUNATURA), refere-se aos ajustes realizados nos limites de cada classe de cobertura vegetal, uso da terra (áreas construídas) e áreas de solo exposto. A **Figura 4.1** destaca algumas dessas correções vetoriais.



**Figura 4.1.** Exemplo de ajustes vetoriais realizados para o novo mapa de vegetação nas classes temáticas *Solo Exposto*, *Mata de Galeria*, *Cerrado sensu stricto* e *Campo Limpo com Murundum*, utilizando imagens IKONOS (1 m e 4 m de resolução espacial). Os vetores vermelhos correspondem às áreas corrigidas (mapa atualizado); os vetores azuis correspondem às falhas no antigo mapeamento.

Outra correção diz respeito à nomenclatura das classes de vegetação, sendo adotada uma nova definição para algumas fitofisionomias, de acordo com Eiten (2001, e comunicação pessoal). As classes antes identificadas por “Invasoras/Pioneiras” e “Campo Rupestre”, por exemplo, foram renomeadas para “Campo Cerrado com Trembléias” e “Campo Sujo com presença de Arnica (*lycnophora ericoides*) e Canela de Ema”, respectivamente. Em outro exemplo, áreas definidas por “Parque de Cerrado” passaram a serem identificadas como “Campo Limpo com Murundum”. Tais mudanças foram baseadas na constatação da presença dessas espécies em determinados pontos do parque, considerando-se também a caracterização estrutural das mesmas. A **Tabela 4.1** compara a legenda do antigo mapa com o atual, seguido pela área de cada classe (em hectares).

**Tabela 4.1.** Classes temáticas presentes no antigo e no novo mapeamento do PNB, com a respectiva área (hectares e %).

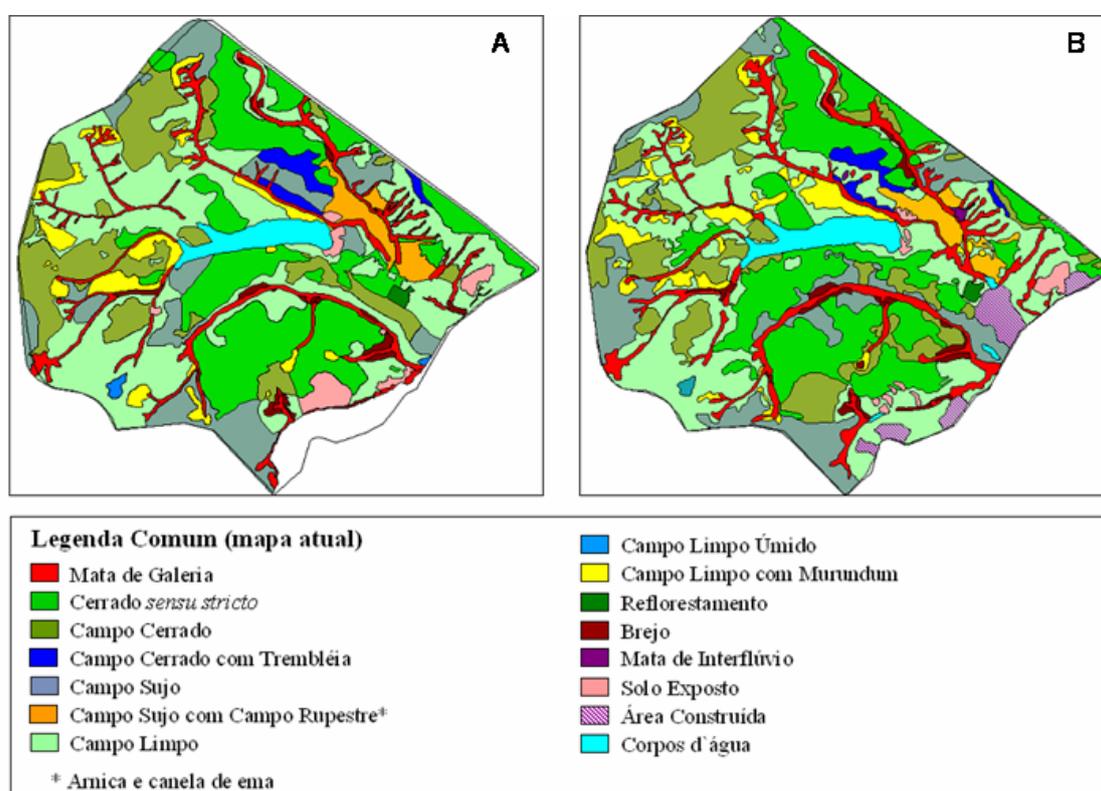
Classes - Mapa Antigo	Área (ha) <sup>1</sup>	Área (%)	Classes - Mapa Atual	Área (ha) <sup>1</sup>	Área (%)
Brejo	388	1,3	Brejo	462	1,5
Vereda	36	0,1	(incorporada <sup>2</sup> )	-	-
Campo Limpo	9.418	30,8	Campo Limpo	8.572	27,2
Campo Limpo Úmido	77	0,3	Campo Limpo Úmido	49	0,2
Parque de Cerrado	1.326	4,3	Campo Limpo com Murundum	1.428	4,5
Campo Sujo	3.233	10,6	Campo Sujo	3.593	11,4
Campo Rupestre	739	2,4	Campo Sujo com presença de Arnica ( <i>lycnophora ericoides</i> ) e “Canela de Ema”	611	1,9
Cerrado Ralo	4.163	13,6	Campo Cerrado	4.369	13,9
Invasoras/Pioneiras	494	1,6	Campo Cerrado com Trembléias	376	1,2
Cerrado Típico	6.778	22,2	Cerrado <i>sensu stricto</i>	6.983	22,1
Mata de Galeria	2.444	8	Mata de Galeria	3.026	9,6
-	-	-	Mata de Interflúvio (mata seca)	43	0,1
Reflorestamento	78	0,3	Reflorestamento	65	0,2
Represa Santa Maria	770	2,5	Corpos d’água (represa Santa Maria e outros reservatórios)	890	2,8
Solo Exposto	620	2	Solo Exposto	302	1
-	-	-	Área Construída <sup>3</sup>	764	2,4
<b>Área Total</b>	<b>30.565</b>	<b>100</b>	<b>Área Total</b>	<b>31.534</b>	<b>100</b>

<sup>1</sup> Área aproximada, calculada em um Sistema de Informações Geográficas.

<sup>2</sup> Pequeno polígono incorporado à classe Mata de Galeria.

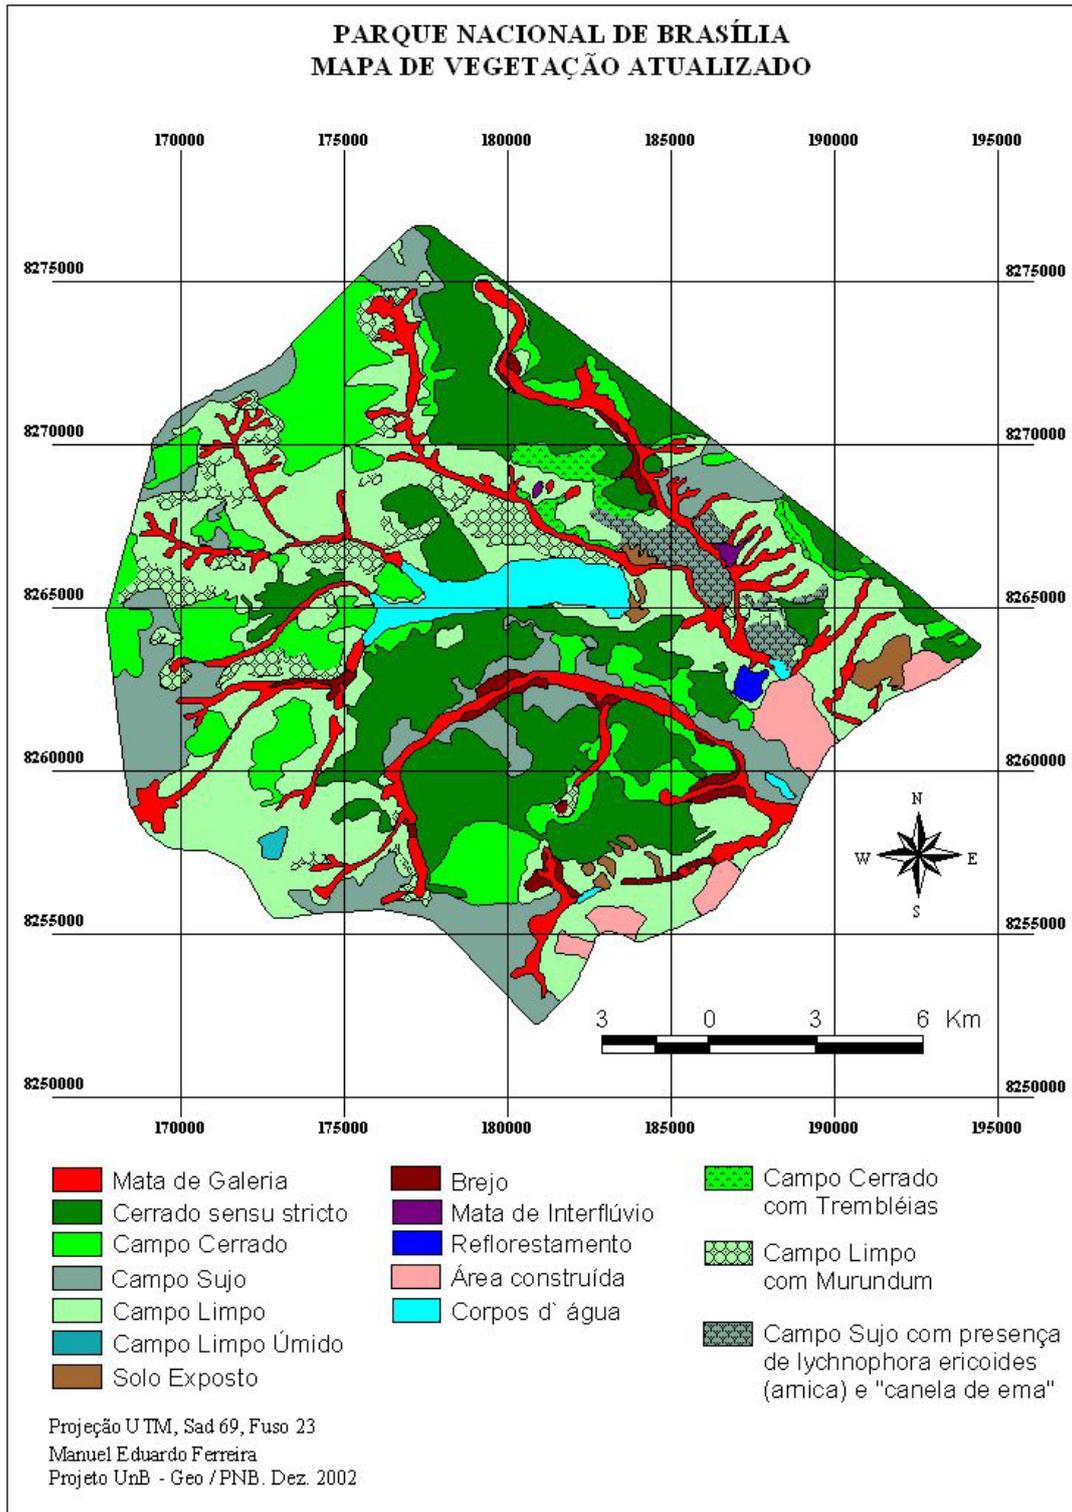
<sup>3</sup> Benfeitorias no PNB.

Grande parte dessas correções só foi possível devido às imagens obtidas pelo sensor IKONOS, cobrindo áreas de difícil acesso no PNB. Destaca-se, por exemplo, o Campo Limpo com murundum, cujo mapeamento fora realizado com maior precisão. Em outros casos, a visita à área de estudo foi imprescindível na verificação da presença de espécies como trembléias, “arnica” e “canela de ema” (campo rupestre), abundantes em alguns trechos de Campo Cerrado e Campo Sujo, porém, não diferenciadas nas imagens de satélite (ETM+ e IKONOS) para o parque. A **Figura 4.2** ilustra os dois mapas (antigo e atual), expondo as correções vetoriais realizadas.



**Figura 4.2.** Comparação visual entre os dois mapas de vegetação do PNB: (A) mapeamento antigo (FUNATURA-1995), e (B) mapeamento atual (2002).

A **Figura 4.3** ilustra o mapa atual de vegetação, com a apresentação das classes temáticas discutidas neste estudo. Este se encontra anexado à dissertação, no formato analógico, tamanho de impressão A3.



**Figura 4.3.** Novo mapa de vegetação do Parque Nacional de Brasília.

## 4.2 - Potencial das Imagens Fração para o Mapeamento do Cerrado (PNB)

Antes de apresentar os resultados qualitativos e quantitativos deste estudo, é importante ressaltar alguns pontos, principalmente para os leitores com pouco ou nenhum envolvimento com a área de Sensoriamento Remoto.

Todos os processamentos envolvidos direta ou indiretamente na aplicação do Modelo Linear de Mistura Espectral (MLME) foram realizados com relativa facilidade operacional / baixa demanda computacional, inclusive com baixa subjetividade por parte do analista. Tais características ressaltam a funcionalidade do método aqui em destaque, tornando-o viável para um monitoramento sistemático de grandes áreas, como o bioma Cerrado, com a vantagem de ser aplicável a qualquer categoria de imagem (baixa ou alta resolução espacial / espectral / temporal).

Em geral, as análises confirmam uma dificuldade maior na discriminação de duas classes de Cerrado: Campo Sujo e Campo Cerrado. Apesar disto, o MLME demonstra um bom desempenho para com as demais classes deste bioma, além de ser aplicável a outras análises, envolvendo, por exemplo, a detecção de mudanças na cobertura vegetal e uso do solo.

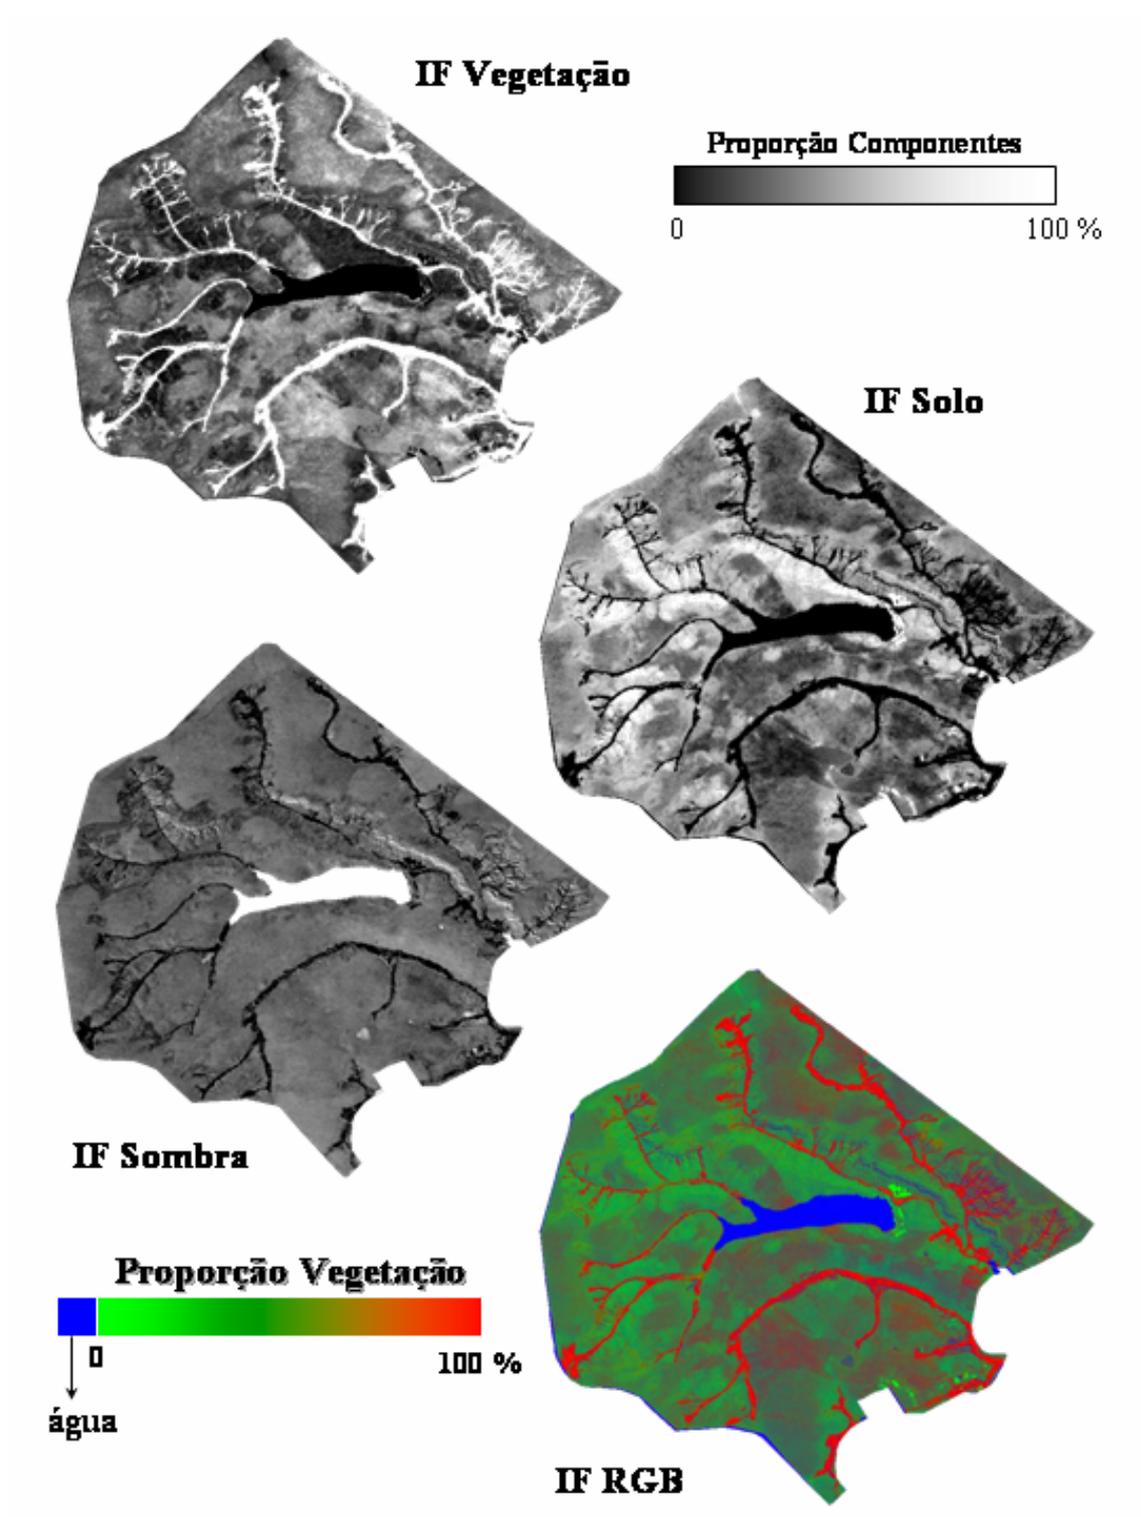
### 4.2.1 - Modelo linear geral (*vegetação, solo e sombra*)

Com a aplicação do modelo linear geral nas imagens ETM+, em valor digital (0-255) e em reflectância, foi possível discriminar grande parte das fitofisionomias existentes no PNB, com um bom desempenho para ambos os conjuntos de dados. Classes como Mata de Galeria, Solo e Água (represa Santa Maria), onde os *endmembers* foram obtidos, apresentaram 100% da área realçada pelas respectivas Imagens Fração. Constatou-se que as IF *vegetação* e *solo* ficaram mais sensíveis às alterações na cobertura vegetal do que a IF *sombra*, trazendo assim uma maior contribuição para a análise das espécies vegetais no parque (**Figura 4.4**).

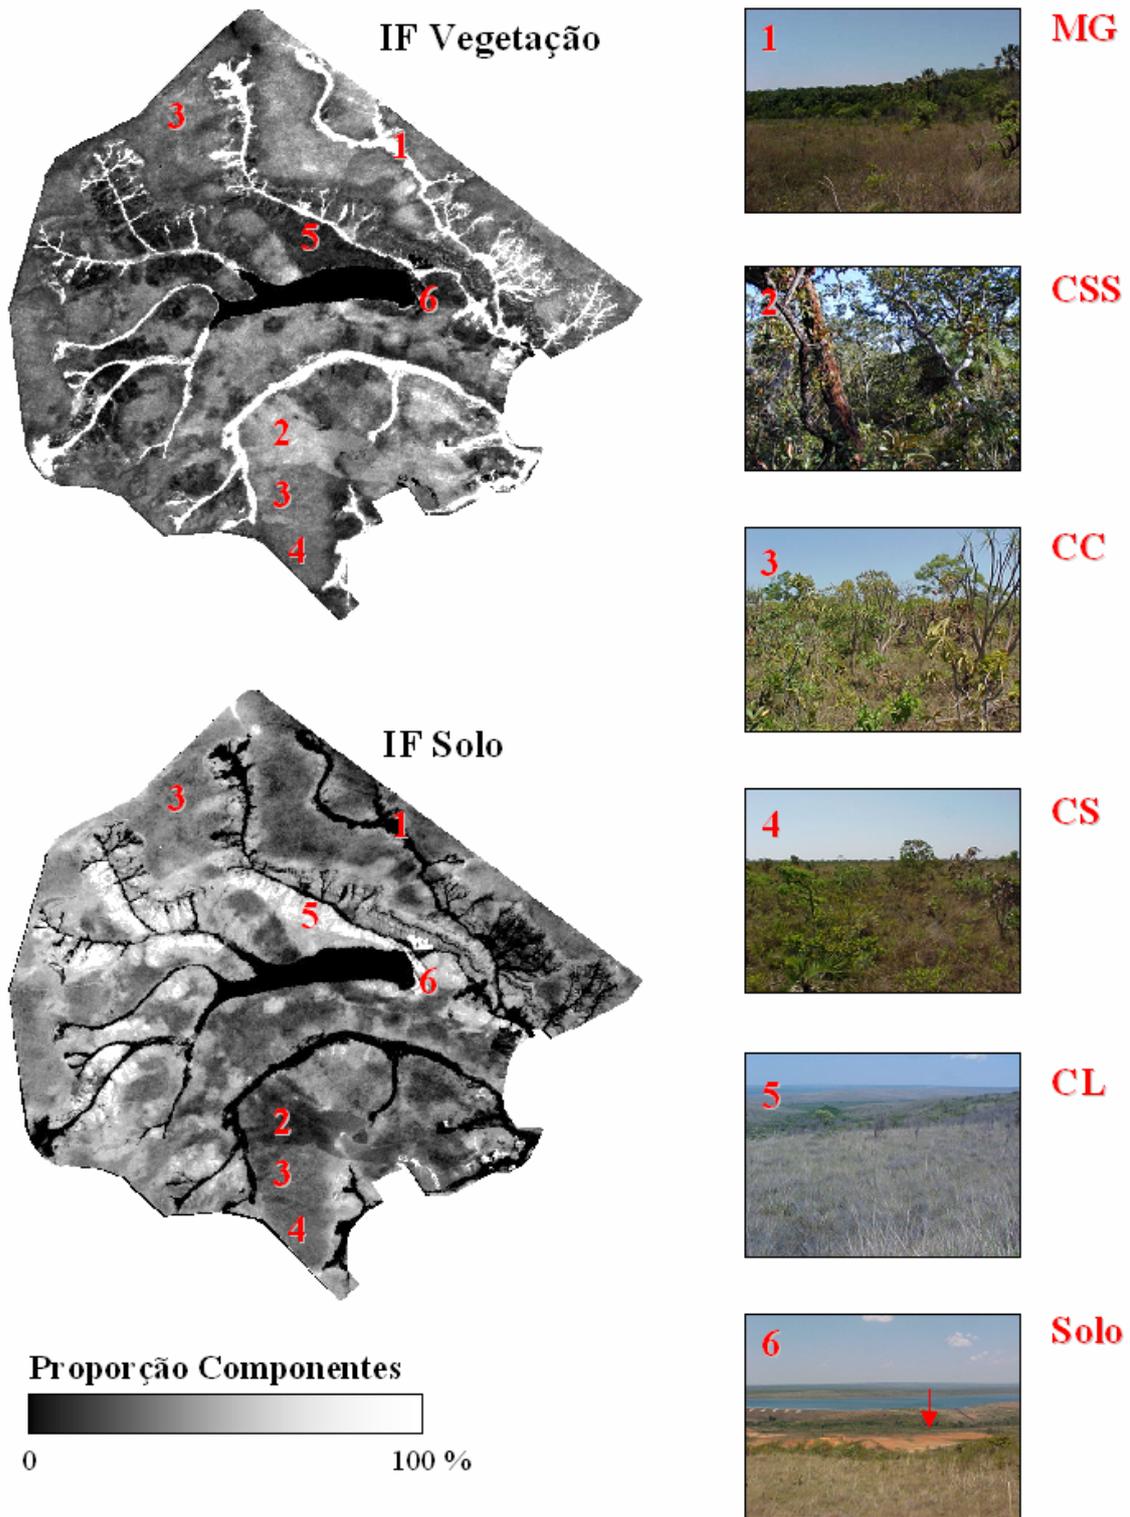
Com base na proporção de cada componente (*vegetação* ou *solo*), foi possível identificar áreas representativas para as fitofisionomias presentes na área de estudo. A IF *solo*, por exemplo, destacou, além dos pontos com solo exposto, aquelas áreas correspondentes ao estrato herbáceo (ex. Campo Limpo), onde a presença de um

componente arbustivo (ex. Campo Cerrado) ou arborescente (ex. Cerrado *sensu stricto*) é praticamente nula. No outro extremo, encontra-se a IF *vegetação*, a qual destacou, além das áreas com maior vigor vegetacional (Mata de Galeria, com alta intensidade de brilho), fitofisionomias pertencentes ao extrato arbustivo, cuja proporção de cobertura é inferior (intensidade de brilho menor) (**Figura 4.5**).

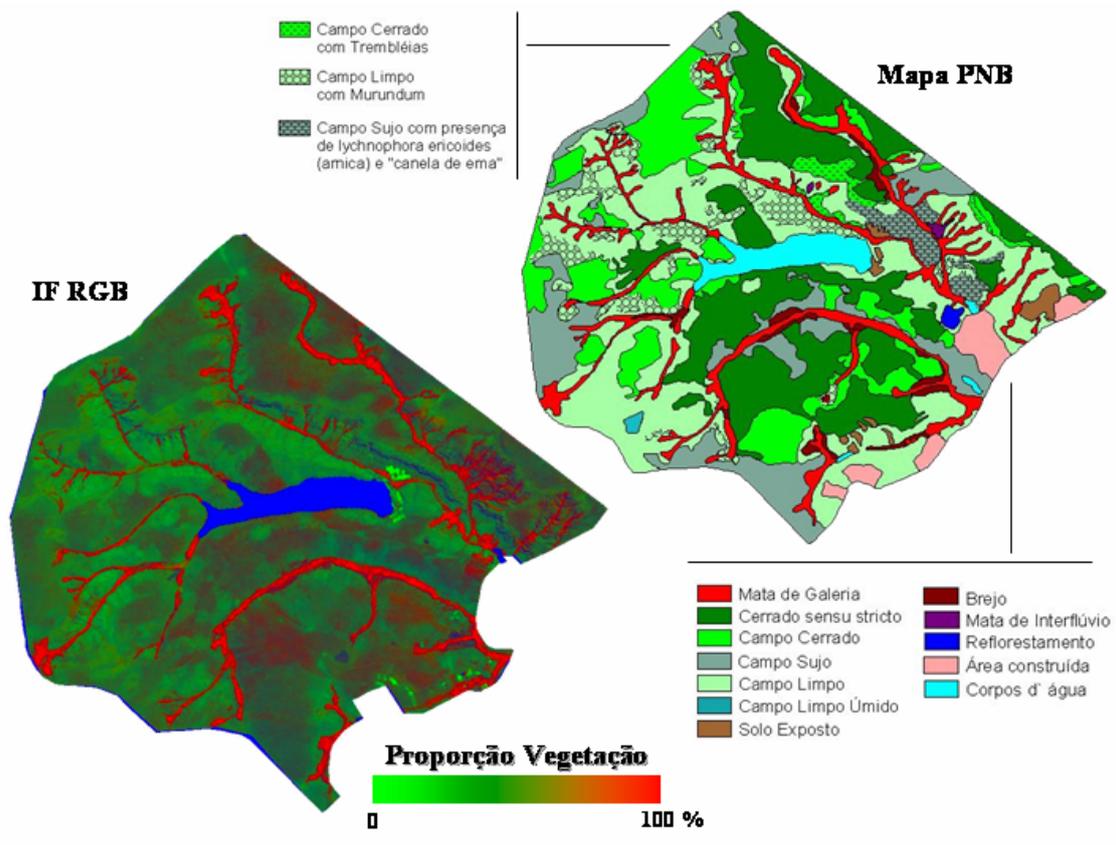
Na composição colorida, gerada com as frações *vegetação* (canal vermelho), *solo* (canal verde) e *sombra* (canal azul), obteve-se uma boa indicação visual de pelo menos quatro classes de Cerrado, além do Solo e da Água: Campo Limpo, Campo Cerrado, Cerrado *sensu stricto* e Mata de Galeria. Foi registrada uma maior confusão entre as áreas de Campo Sujo e Campo Cerrado (baixa diferenciação), fato este comprovado pela realização de análises estatísticas (Análise Discriminante e Teste-t). A resposta espectral dessas classes é muito próxima, inclusive na imagem ETM+ (sem aplicação do MLME). Em comparação com o mapa de vegetação, estas IF apresentaram uma semelhança satisfatória quanto à distribuição de grande parte das fitofisionomias, o que demonstra um bom desempenho do MLME para o Cerrado. A **Figura 4.6** ilustra estes resultados.



**Figura 4.4.** Imagens Frações do PNB, resultantes do modelo linear geral. IF RGB: Veg./Solo/Sombra.



**Figura 4.5.** IF Vegetação e Solo, seguido pela identificação visual das principais fitofisionomias do bioma Cerrado.



**Figura 4.6.** Comparação do mapa de vegetação com as IF RGB Veg./Solo/Sombra (modelo linear geral).

### Análise Discriminante

Por meio da Análise Discriminante, foi possível verificar que as Imagens Fração “Valor Digital” (**Tabela 4.2**) e “Reflectância” (**Tabela 4.3**) obtiveram o mesmo desempenho na discriminação das fitofisionomias de Cerrado. Tal fato demonstra que o procedimento de correção atmosférica contribui com uma pequena diferença nos valores dos *pixels* das respectivas IF, o que não chega a interferir no potencial do MLME para a análise deste bioma.

A importância deste resultado consiste em dois aspectos: **a)** a correção atmosférica, quando realizada de forma criteriosa e correta, é reconhecida como um dos procedimentos mais complexos em sensoriamento remoto, o que aumenta consideravelmente a demanda computacional de qualquer análise com imagens de satélite. Como mencionado no capítulo 2, são vários os dados complementares para se executar um modelo de correção da atmosfera; **b)** no Brasil, um país que já apresenta

uma certa tradição em sensoriamento remoto, a grande maioria dos usuários relativiza, ou desconhece, a importância desta para as análises de imagens de satélite, por exemplo.

Sendo assim, em uma análise atemporal envolvendo a geração de Imagens Fração na região do Cerrado, o uso de métodos para atenuar a contaminação atmosférica pode ser dispensado, sem que haja uma perda significativa na precisão dos resultados. Por outro lado, esta diferença entre os dois conjuntos de imagens (IF-VD e IF-R) demonstra a possibilidade de erro no acompanhamento de mudanças na paisagem (cobertura vegetal) ao longo do tempo (análise multitemporal), podendo gerar análises super ou subestimadas. Mudanças na geometria de imageamento, condições atmosféricas, dentre outros fatores espúrios ao processo de obtenção dos dados, seriam os prováveis motivos para uma imprecisão nos resultados. Especificamente neste caso, a correção atmosférica, ou até mesmo os métodos de retificação radiométrica (ambos mencionados no capítulo 2), são indispensáveis nas etapas de processamento. Esta discussão é retomada a partir dos resultados obtidos pelo Teste-t, empregados na medição da interferência atmosférica no modelo linear de mistura espectral.

Nos dois conjuntos de imagens, as classes de vegetação foram bem definidas (próximo a 100% de acerto), com exceção para o CC e o CS. Nas IF-VD, a classe CS apresentou 21% (31) das amostras identificadas como CC, e apenas 4% (6) como CL. Na classe CC, 18% (27) das amostras foram identificadas como CS, e apenas 7% (11) como CSS. Na IF-R estes valores foram muito semelhantes.

Observou-se uma maior dificuldade do MLME em discriminar a classe Campo Sujo (estrato arbustivo) daquelas de Campo Cerrado (estrato arborecente) e vice-versa, com um erro aproximado de 25% para ambas as fitofisionomias. Na mesma abordagem, foi constatado que a classe de CSS teve 9% das amostras identificadas como CC.

**Tabela 4.2.** Análise Discriminante para as Imagens Fração “Valor Digital” (IF-VD).

	Água	CC	CL	CSS	CS	MG	Solo	% acerto
Água	50	0	0	0	0	0	0	100
CC	0	112	0	11	27	0	0	75
CL	0	0	144	0	6	0	0	96
CSS	0	13	0	137	0	0	0	91
CS	0	31	6	0	113	0	0	75
MG	0	0	0	1	0	149	0	99
Solo	0	0	2	0	0	0	48	96
<b><i>n</i> = 150 (solo e água = 50)</b>							<b>Total classificado corretamente</b>	<b>89</b>

**Tabela 4.3.** Análise Discriminante para as Imagens Fração “Reflectância” (IF-R).

	Água	CC	CL	CSS	CS	MG	Solo	% acerto
Água	50	0	0	0	0	0	0	100
CC	0	112	0	12	26	0	0	75
CL	0	0	143	0	7	0	0	95
CSS	0	14	0	136	0	0	0	91
CS	0	30	6	1	113	0	0	75
MG	0	0	0	1	0	149	0	99
Solo	0	0	4	0	0	0	46	92
<b><i>N</i> = 150 (solo e água = 50)</b>							<b>Total classificado corretamente</b>	<b>88</b>

Na cena ETM+ (bandas 1-5 e 7), não submetida ao MLME (**Tabela 4.4**), foi verificado um desempenho semelhante ao das Imagens Fração, no que se refere à Análise Discriminante. A porcentagem de acerto neste tipo de imagem foi levemente superior apenas para a classe Campo Cerrado, com 78% (contra 75% nas IF), enquanto que o CSS foi menos discriminado, apresentando 11% de suas amostras como sendo de CC (contra 9% nas IF). As demais classes obtiveram valores bem aproximados.

No caso da imagem NDVI (**Tabela 4.5**), a capacidade de discriminação destas fitofisionomias foi substancialmente inferior aos resultados alcançados para as IF-VD / R (**Tabelas 4.2 e 4.3**), assim como para a cena ETM+ (bandas 1-5 e 7) (**Tabela 4.4**). A diferença mais significativa foi verificada com as classes Campo Limpo e Campo Sujo, cujo erro nesta imagem ficou em torno de 25 % e 48 %, respectivamente.

A classe CS apresentou na imagem NDVI uma forte associação espectral com o CC e com o CL, enquanto que o próprio CL obteve uma associação maior com o CS. Esta associação pode ser confirmada na **Tabela 4.5**. Já o CSS e o CC apresentaram, respectivamente, 18% e 29% de erro. Neste caso, o CSS teve uma associação maior com o CC, enquanto que este foi mais associado ao CS. A Mata de Galeria, o solo e a água foram alvos bem discriminados, com aproximadamente 100 % das amostras identificadas corretamente.

**Tabela 4.4.** Análise Discriminante para a cena ETM+ (bandas 1-5 e 7).

	Água	CC	CL	CSS	CS	MG	Solo	% acerto
Água	50	0	0	0	0	0	0	100
CC	0	117	0	9	24	0	0	78
CL	0	0	144	0	6	0	0	96
CSS	0	16	0	134	0	0	0	89
CS	0	32	6	0	112	0	0	75
MG	0	0	0	1	0	149	0	99
Solo	0	0	0	0	0	0	50	100
<b>n = 150 (solo e água = 50)</b>		<b>Total classificado corretamente</b>						<b>89</b>

**Tabela 4.5.** Análise Discriminante para a imagem NDVI.

	Água	CC	CL	CSS	CS	MG	Solo	% acerto
Água	50	0	0	0	0	0	0	100
CC	0	106	1	14	29	0	0	71
CL	0	1	112	0	37	0	0	75
CSS	0	27	0	123	0	0	0	82
CS	0	38	34	0	78	0	0	52
MG	0	0	0	1	0	149	0	99
Solo	0	0	1	0	0	0	49	98
<b>n = 150 (solo e água = 50)</b>		<b>Total classificado corretamente</b>						<b>78</b>

### Grau de separabilidade

Com base na Matriz “F” (Estatística F), com a qual pode-se avaliar o grau de separabilidade entre as classes amostradas, as Imagens Fração “Valor Digital” apresentaram, em média, valores “F” semelhantes àqueles obtidos pelas Imagens Fração

“Reflectância” (Tabelas 4.6 e 4.7). Tal fato não anula as diferenças entre estas imagens nem tão pouco a importância da normalização radiométrica destes dados, mas reforça a idéia de que uma correção atmosférica, em análises atemporais, influi pouco nos resultados obtidos pelo MLME.

**Tabela 4.6.** Matriz “F” para as Imagens Fração “Valor Digital” (IF-VD).

	Água	CC	CL	CSS	CS	MG	Solo
Água	<b>0.00</b>						
CC	3823.24	<b>0.00</b>					
CL	5429.21	673.34	<b>0.00</b>				
CSS	3696.74	241.72	1654.84	<b>0.00</b>			
CS	4049.97	<b>87.55</b>	307.83	619.95	<b>0.00</b>		
MG	7206.63	5280.07	8811.01	3363.37	6648.27	<b>0.00</b>	
Solo	7923.21	2969.10	1373.34	4023.70	2431.10	8752.70	<b>0.00</b>

**Tabela 4.7.** Matriz “F” para as Imagens Fração “Reflectância” (IF-R).

	Água	CC	CL	CSS	CS	MG	Solo
Água	<b>0.00</b>						
CC	3788.75	<b>0.00</b>					
CL	5447.85	676.80	<b>0.00</b>				
CSS	3634.33	256.67	1693.11	<b>0.00</b>			
CS	4051.09	<b>89.16</b>	303.21	647.77	<b>0.00</b>		
MG	6936.22	5179.30	8691.36	3228.50	6541.73	<b>0.00</b>	
Solo	7713.76	2523.24	1153.63	3437.54	2077.61	7413.70	<b>0.00</b>

Nesta matriz, quanto menor o valor de “F”, menor a separabilidade (ou distância) entre as fitofisionomias, indicando, por sua vez, uma maior dificuldade de identificação ou mapeamento deste bioma.

Com base nestes valores, foi confirmada a forte associação entre as classes Campo Sujo e Campo Cerrado, apresentando um valor “F” menor dentre estas duas matrizes (média de 88). As demais classes com menor grau de separabilidade foram, em ordem crescente: CC e CSS (média de 249), CS e CL (média de 306), CS e CSS (média de 633), e CL e CC (média 674). Classes como MG, solo e água apresentaram valores “F” mais elevados, indicando uma boa separabilidade destes componentes nas IF.

De uma forma geral, o grau de separabilidade é inversamente proporcional à associação observada entre os estratos fisionômicos do bioma Cerrado. Sendo assim, o valor “F” aumenta à medida que se caminha para os extremos destas fisionomias. Como exemplo, o maior valor desta matriz foi verificado na baixa associação das classes MG e CL, decaindo gradativamente quando a relação entre as classes torna-se mais tênue ou menos abrupta (ex. MG e CSS ou CL e solo).

Na matriz “F” referente à imagem ETM+ (bandas 1-5 e 7) (**Tabela 4.8**), foram verificados valores significativamente mais baixos daqueles apresentados pelas matrizes correspondentes às Imagens Fração (VD e R) e Imagem NDVI (**Tabela 4.9**). Dessa forma, as classes de Cerrado marcadas por uma mistura espectral mais intensa, em geral posicionadas entre os limites dos estratos fisionômicos (ex. Campo Sujo, Campo Cerrado e Cerrado *sensu stricto*), apresentaram os valores mais baixos neste tipo de análise estatística.

Como exemplo desta baixa separabilidade, podem-se citar as classes Campo Sujo e Campo Cerrado (31), seguido pelas classes Cerrado *sensu stricto* e Campo Cerrado (91), Campo Sujo e Campo Limpo (124), Campo Sujo e Cerrado *sensu stricto* (227), e Campo Limpo e Campo Cerrado (259). Tais valores nas Imagens Fração (IF-VD) foram, na mesma ordem: 87, 241, 307, 619 e 673. Na imagem NDVI, tais valores “F” foram, respectivamente: 121, 335, 106, 859 e 453. As classes naturalmente distantes em termos fisionômicos, ou seja, com baixa associação, apresentaram, em geral, um alto valor “F”, permanecendo as diferenças entre os grupos de imagens avaliados. Neste caso, o NDVI obteve a melhor resposta, enquanto que a imagem ETM+ (bandas 1-5 e 7) continuou com baixo desempenho.

**Tabela 4.8.** Matriz “F” para a cena ETM+ (bandas 1-5 e 7).

	Água	CC	CL	CSS	CS	MG	Solo
Água	<b>0.00</b>						
CC	1498.39	<b>0.00</b>					
CL	2101.55	259.88	<b>0.00</b>				
CSS	1413.67	91.56	622.83	<b>0.00</b>			
CS	1598.26	<b>31.08</b>	124.17	227.55	<b>0.00</b>		
MG	2600.35	1872.73	3164.77	1183.09	2344.14	<b>0.00</b>	
Solo	2920.03	1952.71	1508.61	2214.68	1818.32	3853.44	<b>0.00</b>

**Tabela 4.9.** Matriz “F” para a imagem NDVI.

	Água	CC	CL	CSS	CS	MG	Solo
Água	<b>0.00</b>						
CC	6503.87	<b>0.00</b>					
CL	4303.02	453.70	<b>0.00</b>				
CSS	8762.33	333.32	1569.11	<b>0.00</b>			
CS	5311.12	121.11	106.00	859.46	<b>0.00</b>		
MG	21983.34	9143.73	13671.00	5977.01	11369.45	<b>0.00</b>	
Solo	920.30	1892.65	809.01	3186.93	1276.13	12347.68	<b>0.00</b>

Como exemplo desta baixa separabilidade, pode-se citar as classes Campo Sujo e Campo Cerrado (31), seguido pelas classes Cerrado *sensu stricto* e Campo Cerrado (91), Campo Sujo e Campo Limpo (124), Campo Sujo e Cerrado *sensu stricto* (227), e Campo Limpo e Campo Cerrado (259). Tais valores nas Imagens Fração (IF-VD) foram, na mesma ordem: 87, 241, 307, 619 e 673. Na imagem NDVI, tais valores “F” foram, respectivamente: 121, 335, 106, 859 e 453. As classes naturalmente distantes em termos fisionômicos, ou seja, com baixa associação, apresentaram, em geral, um alto valor “F”, permanecendo as diferenças entre os grupos de imagens avaliados. Neste caso, o NDVI obteve a melhor resposta, enquanto que a imagem ETM+ (bandas 1-5 e 7) continuou com baixo desempenho.

Com base nas análises realizadas até o momento (Matriz Discriminante e Matriz “F”), o Modelo Linear de Mistura Espectral (VD e R) se mostrou tão ou mais eficaz que os demais grupos de imagens avaliados, ora para a realização de um mapeamento do Cerrado ora para um acompanhamento da proporção de cada componente em uma dada região. Outras vantagens já mencionadas, tal como a redução dos dados de entrada em Imagens Fração, apresentando um parâmetro físico da superfície, reforçam esta condição. Embora o método não tenha discriminado todas as fitofisionomias com 100% de acerto, este obteve, para as classes mais críticas, valores satisfatórios, compensados por uma separabilidade média também elevada.

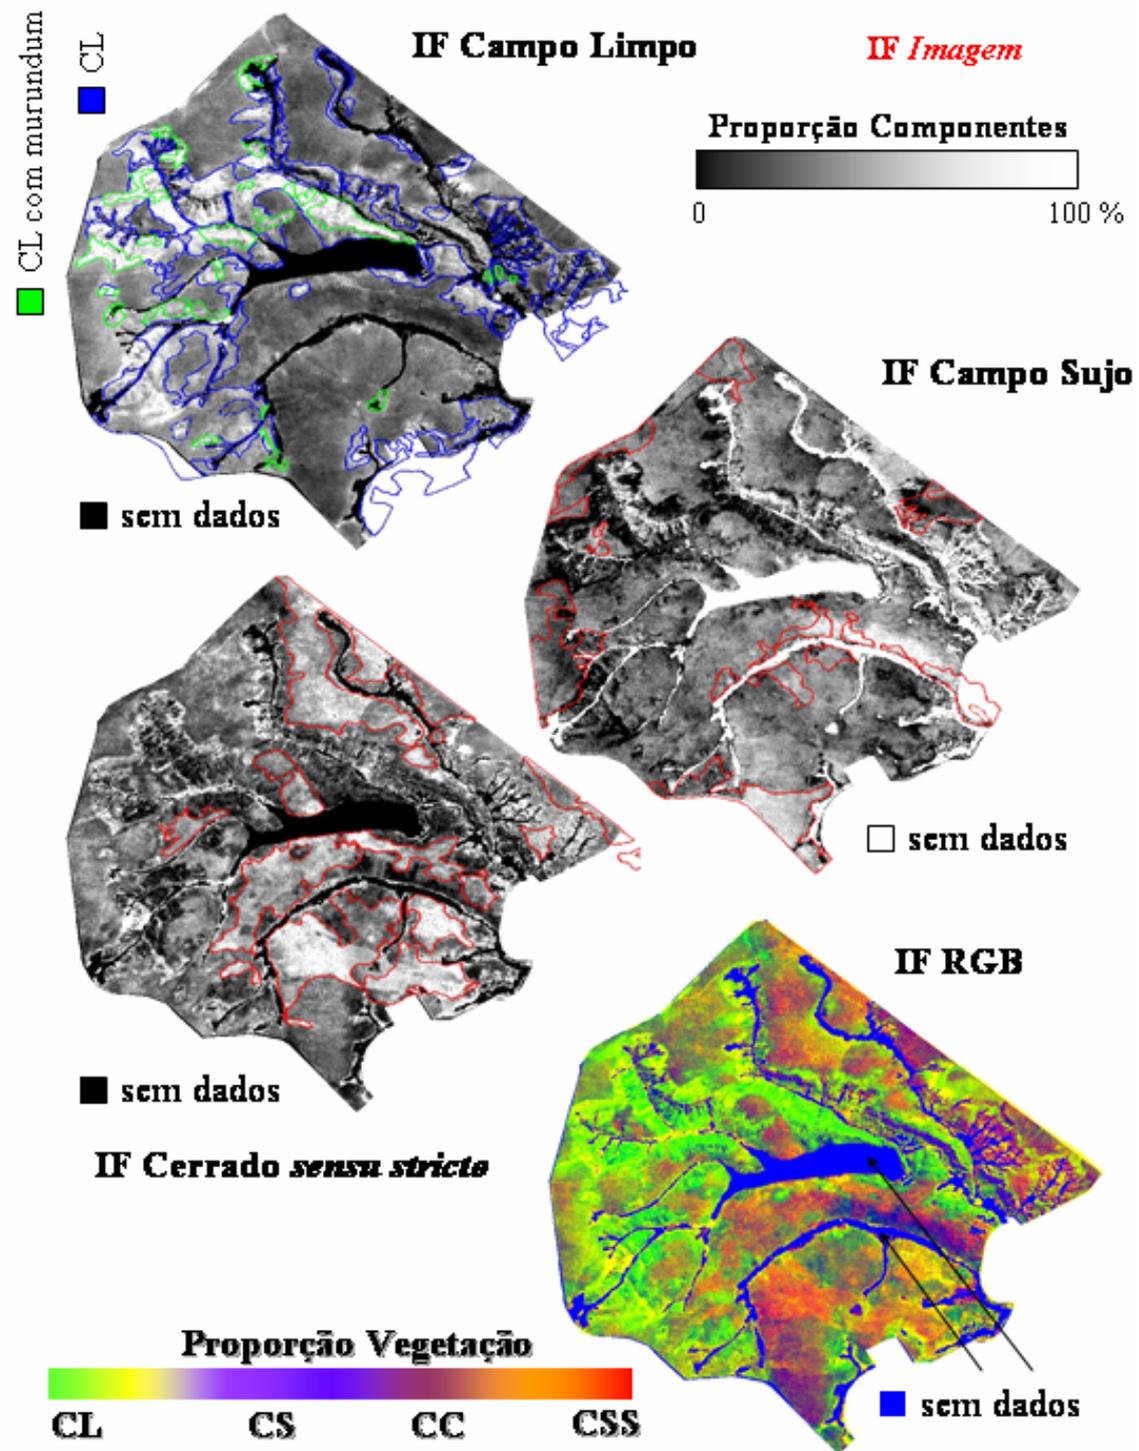
#### 4.2.2 - Modelo Linear Específico

Estes resultados referem-se às análises realizadas com Imagens Fração obtidas do modelo linear específico (Campo Limpo, Campo Sujo e Cerrado *sensu stricto*), utilizando espectros obtidos na área de estudo (IF - *Referência*) e na própria imagem ETM+ Reflectância (IF - *Imagem*). A análise foi restrita às classes CL, CS, CC e CSS. A título de comparação, os procedimentos estatísticos foram igualmente conduzidos com as IF obtidas da técnica MNF, e também com a cena ETM+ (Reflectância, bandas 1-5 e 7).

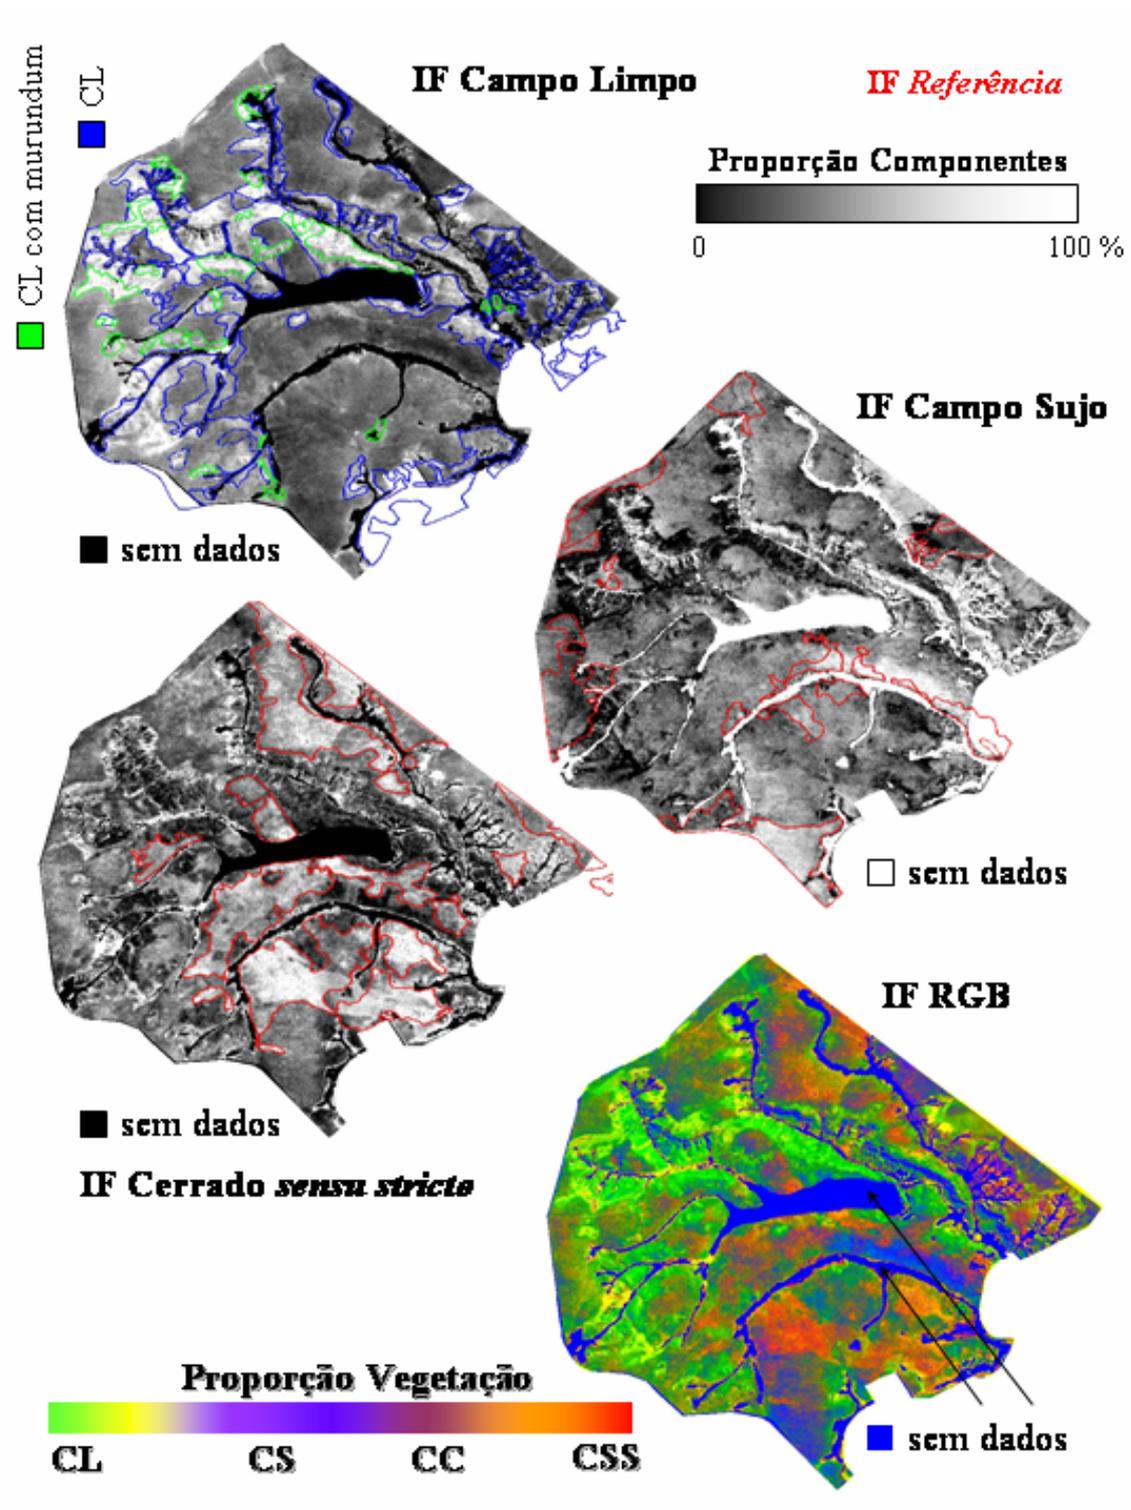
As **Figuras 4.7 e 4.8** ilustram as IF resultantes deste modelo, com *endmembers* obtidos diretamente na imagem ETM+ e por espectrorradiometria de campo (espectros de referência), respectivamente. As imagens sintéticas (ou Imagens Fração), para ambos conjuntos de dados, apresentaram resultados muito parecidos no que se refere à discriminação das fitofisionomias.

Em termos visuais, os três componentes (CL, CS e CSS), cujos *endmembers* foram submetidos ao método WLS, demonstram de fato áreas no parque ocupadas pelas respectivas fitofisionomias. Os componentes CL e CSS foram bem realçados, porém, com pequenas omissões, verificadas no mapa de vegetação do PNB (camada vetorial sobre as imagens fração). No terceiro componente, Campo Sujo, algumas áreas foram realçadas, provavelmente subestimando a presença desta classe de Cerrado no parque.

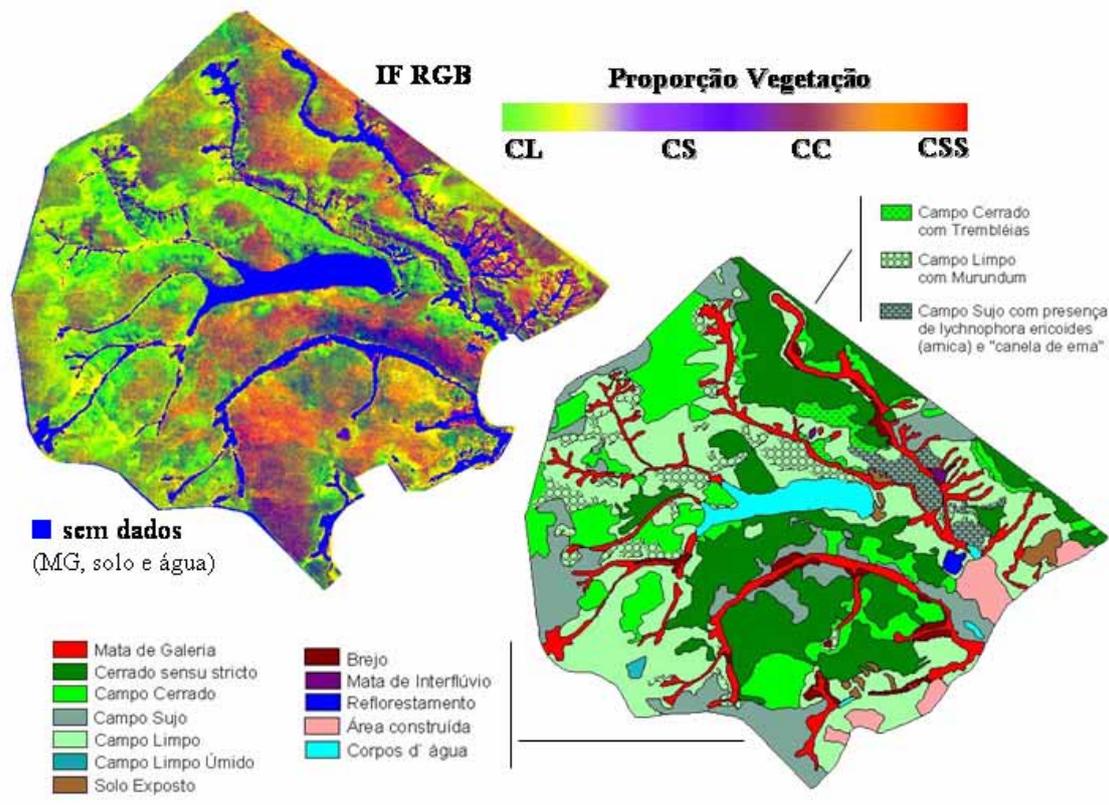
Por outro lado, a composição colorida (RGB), gerada com as IF CSS (*Red*), CL (*Green*) e CS (*Blue*), trouxe uma boa contribuição para a discriminação das fitofisionomias, inclusive do Campo Cerrado (CC). Nesta imagem (**Figuras 4.7 e 4.8**), as classes de vegetação são realçadas de acordo com a proporção de cobertura vegetal. As áreas de maior confusão espectral, comumente verificada entre o CS e o CC, ou entre o CL e o CS, foram destacadas, com grande semelhança com o mapa atualizado (**Figura 4.9**). Neste sentido, o modelo linear específico apresentou um potencial superior ao modelo linear geral, na identificação destas fitofisionomias. Uma comparação visual dos resultados gerados pelos dois modelos lineares é realizada com base na **Figura 4.10**.



**Figura 4.7.** IF do PNB, resultantes do modelo linear específico, com *endmembers* obtidos diretamente na imagem ETM+. IF RGB: CSS/CL/CS. A legenda “sem dados” indica as áreas de MG, solo exposto e água, mascaradas nesta análise.



**Figura 4.8.** Imagens Frações do PNB, resultantes do modelo linear específico, com *endmembers* obtidos por espectrorradiometria de campo. IF RGB: CSS/CL/CS. A legenda “sem dados” indica as áreas de MG, solo exposto e água, mascaradas nesta análise.



**Figura 4.9.** Comparação entre a IF RGB (modelo linear específico) e o mapa de vegetação atualizado do PNB.

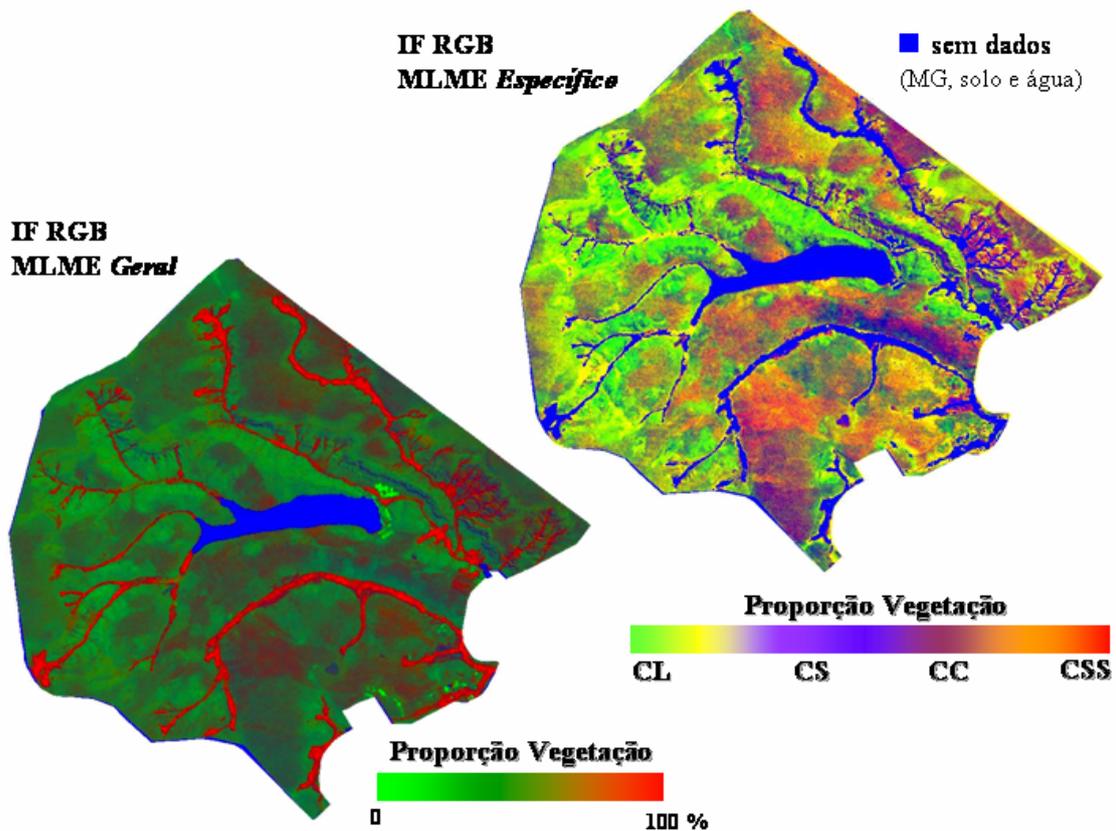
Os dois modelos (geral e específico) podem ser utilizados em conjunto, considerando que o primeiro destacou, com grande fidelidade ao mapa (verdade de campo), as classes temáticas Mata de Galeria (áreas com vegetação densa), solo exposto e corpos d'água (represa). Sabe-se que essas informações, facilmente obtidas pelo MLME, são de extrema importância para um monitoramento ambiental, quando o interesse é a detecção de mudanças na cobertura do solo (uso da terra), ou quando se objetiva uma análise da emissão/absorção de gases como o CO<sub>2</sub>, por exemplo, onde os parâmetros são diferenciados para cada espécie vegetal.

Quanto à qualidade das IF resultantes do modelo linear específico, a mesma está relacionada a uma série de fatores, às vezes inerente aos estudos aqui realizados. Dentre estes fatores destacam-se:

1) A qualidade dos *endmembers*. Por se tratar este bioma de um mosaico de vegetação, onde a presença dos três estratos é constante (além do solo), a obtenção de espectros puros torna-se uma etapa mais difícil, mesmo quando realizada com um

espectrorradiômetro aerotransportado, caso desta pesquisa. A chance de o espectro apresentar uma pequena proporção de solo, arbustos e folhas é alta, dificultando a separação de um ou outro componente. Uma sugestão seria a elaboração de uma biblioteca espectral a partir de dados coletados com um espectrorradiômetro na superfície. Mesmo assim, o problema da mistura pode persistir quando medidas radiométricas foram feitas, por exemplo, do dossel de um Cerrado *sensu stricto*, onde o controle do analista é menor.

2) A constituição do MLME (número de *endmembers*). A definição do conjunto de *endmembers* aplicados ao modelo mostrou ser importante na obtenção das Imagens Fração. Neste caso, pode ter faltado ao modelo linear específico um quarto componente (sombra, etc), capaz de trazer um melhor modelamento aos *pixels*, considerando que algum componente não foi ajustado. Como consequência deste ajuste deficiente, observa-se a IF Campo Sujo, pouco diferenciada das áreas de Campo Limpo ou de Campo Cerrado.



**Figura 4.10.** Comparação visual entre as IF (RGB) geradas a partir do MLME geral e específico. Observa-se um destaque maior das classes de Cerrado com as imagens obtidas pelo MLME específico.

## Análise Discriminante

Com base na Análise Discriminante (**Tabelas 4.10 e 4.11**), foi observado um desempenho similar entre as Imagens Fração *Referência* (*endmembers* obtidos por espectrorradiometria de campo) e Imagens Fração *Imagem* (*endmembers* obtidos da própria cena ETM+) para a discriminação das principais fitofisionomias no PNB (CL, CS, CC e CSS). Esta semelhança dos valores, confirmada também pelas análises visuais (**Figuras 4.7 e 4.8**), ressalta um ponto positivo para o método, demonstrando uma robustez do MLME específico ao acomodar *endmembers* advindos de fontes de dados diferentes, sem, no entanto, apresentar perdas na qualidade dos resultados. Em outras palavras, o potencial do MLME no bioma Cerrado está mais associado à qualidade dos *endmembers* e à maneira com estes foram combinados no próprio modelo, do que com a forma de obtenção dos *endmembers* (*Imagem* ou *Referência*). Entretanto, e sempre que possível, a espectrorradiometria de campo, ou laboratório, deve ser considerada neste tipo de análise.

**Tabela 4.10.** Análise Discriminante para as Imagens Fração *Referência*.

	CSS	CC	CS	CL	% acerto
CSS	132	18	0	0	88
CC	11	111	28	0	74
CS	0	33	111	6	74
CL	0	0	7	143	95
<b>n = 150</b>	<b>Total classificado corretamente</b>				<b>83</b>

**Tabela 4.11.** Análise Discriminante para as Imagens Fração *Imagem*.

	CSS	CC	CS	CL	% acerto
CSS	134	16	0	0	89
CC	11	111	28	0	74
CS	1	35	108	6	72
CL	0	0	7	143	95
<b>n = 150</b>	<b>Total classificado corretamente</b>				<b>83</b>

Em relação ao comportamento destas fitofisionomias, confirmou-se uma confusão espectral intensa entre Campo Sujo e Campo Cerrado, fato este observado também com as demais categorias de imagens analisadas. Dessa forma, e com base nas IF *Referência*,

22% das amostras de CS foram identificadas como CC, e apenas 4% como CL. Por outro lado, 19% das amostras de CC foram identificadas como CS, e apenas 7% como CSS. As classes CL e CSS foram bem discriminadas por esta categoria de imagem, com 95% e 88% de acerto, respectivamente. Os valores obtidos pelas IF *Imagem* foram bastante aproximados, com pequenas diferenças em relação às classes CS e CSS, com 72% e 89% de acerto contra 74% e 88% obtido pelas IF *Referência*, respectivamente.

Com base na Análise Discriminante para a Imagem ETM+ (bandas 1-5 e 7), verificou-se uma inversão no potencial de identificação das classes CS e CL por parte das Imagens Fração e por essa categoria de imagem. Assim, e de acordo com os valores apresentados nas **Tabelas 4.10 e 4.12**, o CS foi melhor discriminado (96% de acerto) na imagem ETM+ (bandas 1-5 e 7), registrando apenas 4% de confusão com o CL. Por outro lado, o CL foi mal discriminado quando comparado com os resultados obtidos pelo MLME, apresentando uma forte associação com o CC (cerca de 20%). A confusão espectral entre CS e CC, neste caso maior com a utilização do modelo linear específico, é uma característica comum no Cerrado, enquanto que a outra associação, entre CL e CC, é mais atípica e, portanto, mais simples para ser corrigida em um mapeamento. As demais classes (CC e CSS) apresentaram uma porcentagem de acerto aproximada, levemente superiores na imagem ETM+ (bandas 1-5 e 7).

**Tabela 4.12.** Análise Discriminante para a cena ETM+ (bandas 1-5 e 7).

	CSS	CC	CS	CL	% acerto
CSS	135	15	0	0	90
CC	9	116	0	25	77
CS	0	0	144	6	96
CL	0	30	5	115	77
<b>n = 150</b>	<b>Total classificado corretamente</b>				<b>85</b>

Visando complementar a avaliação do MLME na discriminação das classes de Cerrado no PNB, a Análise Discriminante foi conduzida com as Imagens Fração obtidas a partir das bandas MNF 1 e 2. De acordo com os valores apresentados na matriz de classificação (**Tabela 4.13**), o uso da técnica MNF mostrou-se favorável, na medida em que todas as classes foram melhor discriminadas em relação às IF *Referência* e IF *Imagem*.

**Tabela 4.13.** Análise Discriminante para as Imagens Fração MNF.

	CSS	CC	CS	CL	% acerto
CSS	135	15	0	0	90
CC	9	115	26	0	77
CS	0	30	116	4	77
CL	0	0	6	144	96
<i>n</i> = 150	Total classificado corretamente				85

### Grau de Separabilidade

Com base nas **Tabelas 4.14 e 4.15**, foi verificado um grau de separabilidade entre as fitofisionomias de Cerrado (CL, CS, CC e CSS) levemente superior nas IF (modelo linear específico) geradas a partir de um conjunto de *endmembers* obtidos por espectrorradiometria de campo (referência). Provavelmente, esta pequena diferença com os valores obtidos pelas IF *Imagem* (*endmembers* da própria imagem) não influi na precisão de um mapeamento. Dessa forma, qualquer que seja a biblioteca espectral utilizada, o potencial do MLME na discriminação dessas classes de vegetação será o mesmo. Tal fato é reforçado pelas Imagens Frações apresentadas nas **Figuras 4.7 e 4.8**.

Em relação a estes valores (**Tabela 4.14**), o grau de separabilidade foi maior, obviamente, entre fitofisionomias de estratos opostos (herbáceo / arbórescente), como constatado entre as classes CSS e CL (1932). Esta separabilidade vai diminuindo na medida em que os estratos de vegetação estão mais próximos, como ocorre entre as classes CSS e CS (767), CC e CSS (304). O menor grau de separabilidade ficou entre as classes CS e CC. Como consequência, há uma maior dificuldade em mapear (discriminar) essas classes, fato observado através da Análise Discriminante e nas próprias IF.

**Tabela 4.14.** Matriz “F” para as Imagens Fração *Referência*.

	CSS	CC	CS	CL
CSS	0.00			
CC	304.63	0.00		
CS	767.71	105.15	0.00	
CL	1932.44	731.21	311.47	0.00

**Tabela 4.15.** Matriz “F” para as Imagens Fração *Imagem*.

	CSS	CC	CS	CL
CSS	0.00			
CC	288.36	0.00		
CS	730.79	101.07	0.00	
CL	1864.29	713.11	306.84	0.00

A mesma análise (Estatística “F”) foi aplicada aos dados ETM+ (bandas 1-5 e 7) (**Tabela 4.16**), visando comparar o potencial do MLME. Foi constatado um resultado semelhante àquele já demonstrado pelo modelo linear geral, ou seja, um grau de separabilidade significativamente maior para as IF como um todo.

Assim, e considerando que na Análise Discriminante os resultados estatísticos foram bem próximos entre esses dois conjuntos de dados (IF e Imagens Originais), o potencial do MLME no mapeamento do Cerrado fica mais evidente após a comparação dos resultados apresentados pelas **Tabelas 4.14 e 4.16**, com destaque aos valores “F” mais baixos na cena ETM+ (bandas 1-5 e 7), sem o uso de qualquer técnica para o realce das informações. Mais especificamente em relação aos valores da **Tabela 4.16** observa-se um grau de separabilidade muito pequeno entre o CL e o CC (38), classes que normalmente não apresentam uma confusão espectral ou dificuldades para discriminação das mesmas.

**Tabela 4.16.** Matriz “F” para a cena ETM+ (bandas 1-5 e 7).

	CSS	CC	CS	CL
CSS	0.00			
CC	117.74	0.00		
CS	750.26	291.73	0.00	
CL	289.96	38.87	129.96	0.00

Na última categoria de dados, das IF geradas com endmembers provenientes de imagens MNF, os resultados indicam que a técnica de ajuste de ruídos e redução espectral, juntamente com o método de desmistura linear, é uma boa opção de processamento de imagens visando o estudo das fisionomias de Cerrado. Os valores “F” (**Tabela 4.17**), assim como os valores obtidos pela Análise Discriminante (**Tabela**

4.13), foram superiores às demais categorias de dados, indicando, por exemplo, uma maior sensibilidade dessas IF à variação na cobertura vegetal no PNB, normalmente caracterizadas por uma forte associação natural entre as fitofisionomias. A imagem MNF (RGB 1/2/3) por si só proporciona um ótimo realce da vegetação (Figura 3.14).

**Tabela 4.17.** Matriz “F” para as Imagens Fração MNF.

	CSS	CC	CS	CL
CSS	0.00			
CC	335.65	0.00		
CS	842.43	114.58	0.00	
CL	2162.96	822.71	352.09	0.00

### 4.3 - Interferência Atmosférica no MLME

A avaliação da interferência atmosférica no Modelo Linear de Mistura Espectral foi realizada por meio de uma análise estatística denominada Teste de Médias ou Teste-t, utilizando-se dados obtidos diretamente das IF - Valor Digital e IF - Reflectância (modelo linear geral). Pretendia-se, assim, observar a existência de diferenças significativas entre os dois conjuntos de dados, cada qual com três IF (Vegetação, Solo e Sombra). Amostras das seguintes variáveis foram comparadas entre si: Campo Limpo (CL), Campo Sujo (CS), Campo Cerrado (CC), Cerrado sensu stricto (CSS) e Mata de Galeria (MG). Dois possíveis eventos foram definidos ( $H_0$  e  $H_1$ ), ao nível de segurança de 5% ( $\alpha = 0.05$ ):

$H_0$ : média dos valores na IF - VD = média dos valores na IF - R ( $p \geq 0.05$ ).

$H_1$ : média dos valores na IF - VD  $\neq$  média dos valores na IF - R ( $p \leq 0.05$ ).

As Tabelas 4.18, 4.19 e 4.20 demonstram os resultados obtidos a partir desta análise. Todas as classes de vegetação apresentaram diferenças significativas nas médias dos valores encontrados nas IF - VD e R ( $p \leq 0,05$ ). Pode-se afirmar, dessa forma, que a correção atmosférica influi na proporção das frações contidas em cada *pixel*, após o uso do MLME (frações correspondentes aos *endmembers* utilizados no modelo linear), sem, no entanto, aumentar o potencial deste na discriminação das classes de Cerrado. Este fato é reforçado com os resultados apresentados nas Tabelas

4.2 e 4.3, onde o potencial discriminatório das IF - VD e IF - R no Cerrado foi o mesmo numa análise atemporal.

Entretanto, esta diferença na média dos valores deve ser considerada em uma análise multitemporal, onde as fitofisionomias apresentarão uma média diferente para cada data de imagem processada, implicando em resultados não fidedignos para a área de estudo, caso a correção atmosférica não tenha sido realizada previamente na imagem.

Ainda nesta abordagem, a classe temática *Solo* e *Água* não apresentaram diferenças significativas (na média dos valores dos *pixels*) apenas no conjunto IF Água - VD e IF Água - R. Nas demais IF, estas classes foram influenciadas pela correção atmosférica aplicada antes do processamento na cena ETM+. Dessa forma, pode-se prever que uma análise do Cerrado, visando, por exemplo, o acompanhamento de áreas desmatadas ao longo de um determinado período de tempo, poderia ser realizada com imagens sem correção atmosférica, desde que fosse utilizada a IF Água, obtida a partir de dados ETM+. Testes complementares devem ser realizados, a fim de garantir tal procedimento com outro sensor de resolução espacial diferenciada.

**Tabela 4.18.** Teste-t realizado com a Imagem Fração Água - VD e R.

<b>IF Água</b>	<b>IF – R</b>						
<b>IF – VD</b>	MG	CSS	CC	CS	CL	Água	Solo
MG	<b>0.000</b>						
CSS		<b>0.000</b>					
CC			<b>0.000</b>				
CS				<b>0.000</b>			
CL					<b>0.000</b>		
Água						<b>0.350</b>	
Solo							<b>0.064</b>

**Tabela 4.19.** Teste-t realizado com a Imagem Fração Solo - VD e R.

<b>IF Solo</b>	<b>IF – R</b>						
<b>IF – VD</b>	MG	CSS	CC	CS	CL	Água	Solo
MG	<b>0.000</b>						
CSS		<b>0.000</b>					
CC			<b>0.000</b>				
CS				<b>0.000</b>			
CL					<b>0.000</b>		
Água						<b>0.036</b>	
Solo							<b>0.017</b>

**Tabela 4.20.** Teste-t realizado com a Imagem Fração Vegetação - VD e R.

<b>IF Veg.</b>	<b>IF – R</b>						
<b>IF – VD</b>	MG	CSS	CC	CS	CL	Água	Solo
MG	<b>0.000</b>						
CSS		<b>0.000</b>					
CC			<b>0.000</b>				
CS				<b>0.000</b>			
CL					<b>0.000</b>		
Água						<b>0.045</b>	
Solo							<b>0.025</b>

## CAPÍTULO 5

### CONSIDERAÇÕES FINAIS

Com base nos resultados apresentados, pode-se dizer que o Modelo Linear de Mistura Espectral apresentou um bom desempenho na discriminação de fitofisionomias encontradas no Parque Nacional de Brasília (bioma Cerrado).

- ❖ Ambos os modelos testados – *geral* e *específico* – se mostraram sensíveis às variações na cobertura vegetal, sobressaindo-se inclusive sobre outras técnicas de processamento, tal como o NDVI;
- ❖ Foi obtido, com razoável sucesso, realce para os três componentes do Cerrado: herbáceo, arbustivo e arborescente, estruturas básicas para a compreensão deste complexo ambiente;
- ❖ Com semelhante eficiência, as áreas de solo exposto, vegetação verde e sombra (representada no parque pelos corpos d'água) foram destacadas por esses modelos. Além do realce, a proporção dos componentes em cada *pixel*, disponibilizada pelas Imagens Fração, contribuiu para a análise dessas fitofisionomias.

Especificamente em relação ao modelo geral, aplicado nas cenas do sensor ETM+ com e sem correção atmosférica, destacaram-se os seguintes pontos de discussão:

- ❖ Foi alcançado uma boa concordância entre os dados de campo (mapa de vegetação) e as Imagens Fração Valor Digital (**VD**) e Reflectância (**R**), principalmente com os estratos herbáceo e arborescente, isto é, Campo Limpo, Cerrado *sensu stricto* e Mata de Galeria;
- ❖ As demais classes de Cerrado com fisionomias semi-arbustiva e arbustiva, representadas aqui pelo Campo Sujo e Campo Cerrado, foram bem discriminadas em apenas algumas áreas do PNB, ora pela IF *solo* ora pela IF

*vegetação*, implicando em um menor potencial do referido modelo na identificação deste estrato vegetacional;

- ❖ Em termos visuais, não foi detectada nenhuma diferença entre as IF VD e R para identificação dessas espécies vegetais. A Análise Discriminante e a Matriz F indicaram resultados semelhantes;
- ❖ A imagem ETM+ (Refletância) obteve valores bem próximos aos apresentados pelo MLME na matriz de classificação. No entanto, o grau de separabilidade desta cena ETM+ (bandas 1-5 e 7) foi bem inferior;
- ❖ A imagem NDVI para o PNB apresentou, em geral, os valores mais baixos tanto na Análise Discriminante quanto na matriz “F” (distância entre classes).

Em relação à forma de obtenção dos *endmembers*, e conseqüentemente ao modelo específico, faz-se as seguintes observações:

- ❖ Não foram constatadas diferenças significativas no potencial do MLME ora utilizando *endmembers* adquiridos na própria imagem ora por espectrorradiometria de campo (referência). Em ambas as abordagens (visual e estatística) os resultados foram muito próximos;
- ❖ A esperada melhora na qualidade das IF utilizando uma biblioteca espectral de referência (espectrorradiometria aérea no PNB) não foi alcançada, provavelmente devido a dois fatores: utilização de espectros misturados, principalmente por amostras de Campo Sujo e Campo Cerrado; ou utilização destes espectros de forma não adequada para aplicação do modelo específico (restrito ao Cerrado).

Quanto à necessidade de correção atmosférica, observaram-se os seguintes pontos:

- ❖ Nesta análise, a qual priorizou a discriminação de classes de Cerrado de forma atemporal, foi demonstrado que o desempenho do MLME não foi alterado pela implementação da correção atmosférica na cena ETM+;
- ❖ Entretanto, diferenças significativas (Teste - t) foram observadas nos valores médios das classes de Cerrado quando do uso do MLME (geral) em imagens com e sem correção atmosférica.
- ❖ Portanto, numa Análise de Mistura Temporal (IF com datas diferentes), a retificação (ou normalização) / correção radiométrica dos dados deve ser efetuada previamente;

Como forma de melhorar os resultados obtidos, e assim estender o uso destes modelos, são sugeridas as seguintes medidas:

- ❖ Implementação de novos modelos lineares para o Cerrado, contemplando outras combinações de *endmembers*, assim como a utilização de novas imagens de satélite, com diferentes resoluções espaciais e espectrais;
- ❖ Um grupo de *endmembers* viável, já testado por Miura et al. (2003) em imagens hiperespectrais do PNB (sensor EO-1 Hyperion - canal SWIR), indica o uso dos *endmembers solo*, *vegetação verde* e *vegetação seca* para a discriminação dos estratos fisionômicos do Cerrado. Na região do infravermelho médio, em torno de 2.090 nm e 2.280 nm, ocorre uma maior absorção da energia pela lignina-celulose, substância presente nas fitofisionomias não fotossinteticamente ativas. Considerar-se-ia, assim, que parte deste mosaico de vegetação é composto por espécies secas (galhos, gravetos, etc.) permitindo uma melhor caracterização biofísica deste bioma;

- ❖ Uma segunda possibilidade para implementação do MLME no Cerrado propõe a utilização de um quarto *endmember* junto ao modelo linear específico, abordado nesta pesquisa. Dessa forma, além dos componentes *Campo Limpo*, *Campo Sujo* e *Cerrado sensu stricto*, seria adicionado o componente *sombra*, o que poderá auxiliar no realce da estrutura arbustiva no Cerrado, principalmente para as classes Campo Sujo e Campo Cerrado, as quais apresentaram confusão espectral mais intensa;
  
- ❖ Uma terceira sugestão diz respeito ao implemento da Análise de Mistura Temporal (AMT) juntamente com as imagens obtidas pelo sensor MODIS, de resolução espacial moderada e alta resolução temporal (imagens diárias), visando principalmente a detecção de mudanças na cobertura vegetal do bioma Cerrado ou em outros biomas brasileiros (Amazônia);
  
- ❖ Todas as imagens obtidas por este sensor (MODIS), ao longo de um determinado período, poderiam ser inseridas no modelo linear como se fossem bandas multiespectrais, optando-se também por uma região do espectro eletromagnético que melhor representasse o alvo em questão. Soma-se, assim, o potencial da técnica de mistura linear com as qualidades de um novo instrumento de imageamento terrestre;
  
- ❖ Nesta metodologia, as IF *solo* e *vegetação* seriam as mais indicadas para gerar um mapa de uso da terra para o Cerrado, por exemplo, com base nos resultados aqui observados;
  
- ❖ O sensor NOAA / AVHRR é uma opção para este tipo de metodologia (AMT), porém, com algumas limitações em relação ao MODIS, considerando que as imagens do segundo também são gratuitas aos usuários de sensoriamento remoto, com resolução temporal equivalente (diária), resolução espectral e espacial superiores (36 bandas / 250m, 500m e 1km), já disponibilizadas com correção atmosférica e georreferenciadas;

- ❖ Dados do sensor ASTER (a bordo da plataforma Terra, como o MODIS) seriam uma opção a mais para implementação do MLME para análises realizadas no Cerrado. Este sensor apresenta uma configuração semelhante a do Landsat 7 ETM+, porém com resolução espacial mais fina (15 metros) nas bandas do visível e infravermelho próximo.

Por fim, as imagens sintéticas, geradas pelo MLME, podem e devem ser combinadas com outros métodos de realce e extração de informações. Imagens-diferenças, algoritmos não-supervisionados e de segmentação, são alguns exemplos que podem contribuir para um melhor aproveitamento deste método.

## 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 espectralradiométricos 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**).

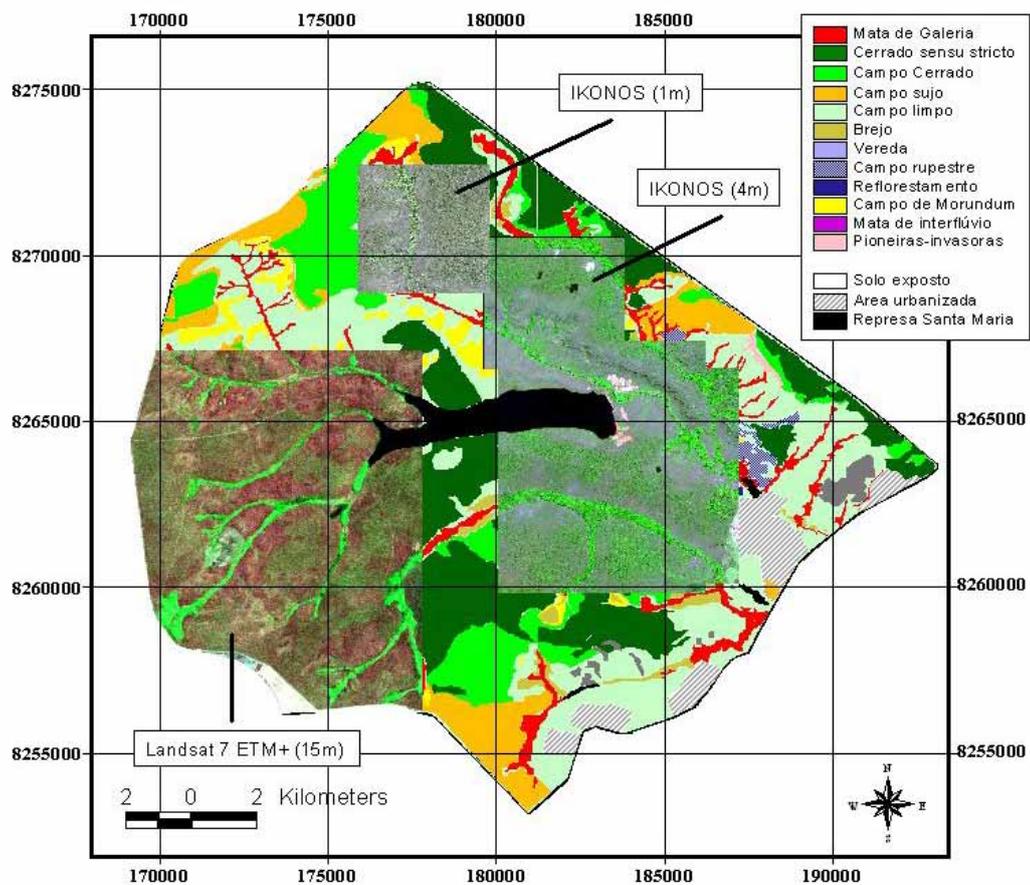
### Abordagem Metodológica

- 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**.

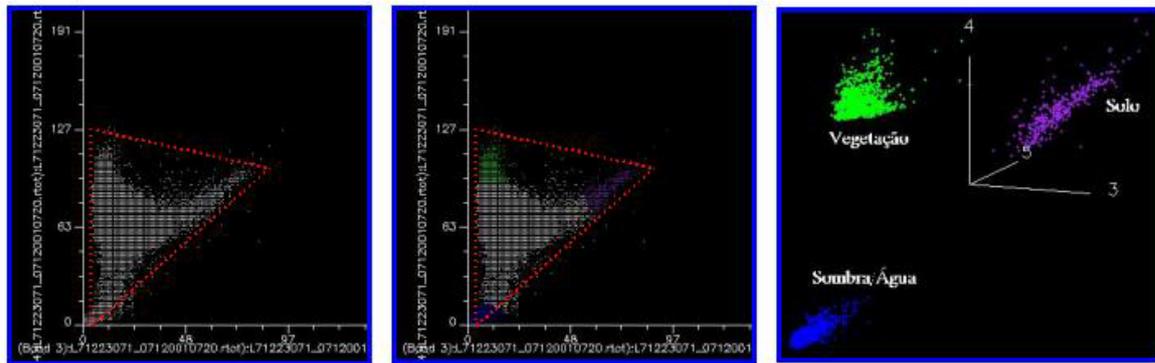
### Aplicação do MLME nos dados Landsat 7 ETM<sup>+</sup>

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.

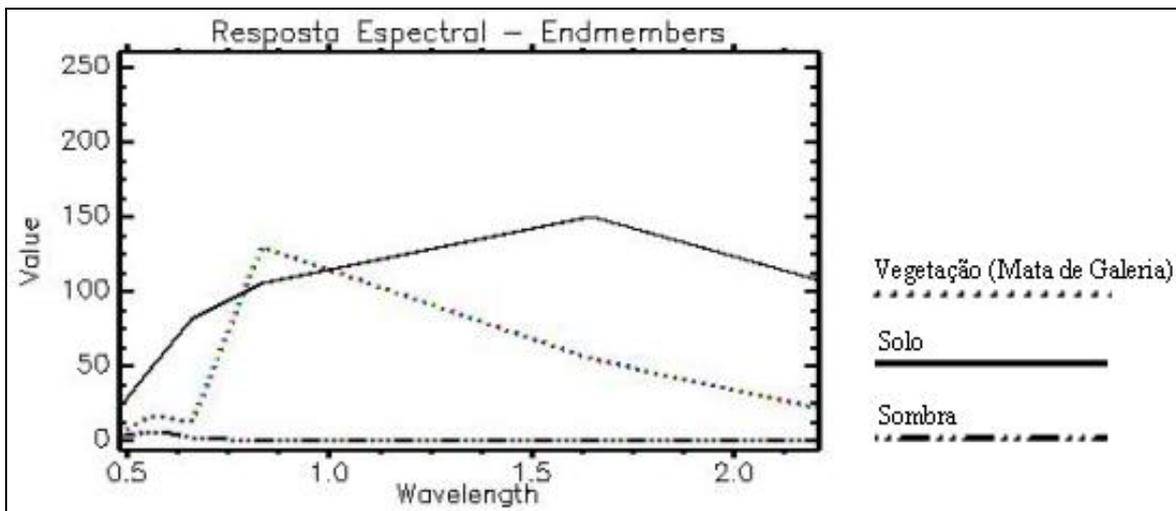


**Figura 1.** Área de Estudo. Mapa de cobertura vegetal do Parque Nacional de Brasília, atualizado através das cenas Landsat 7 ETM<sup>+</sup> e IKONOS (1m e 4m).



**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

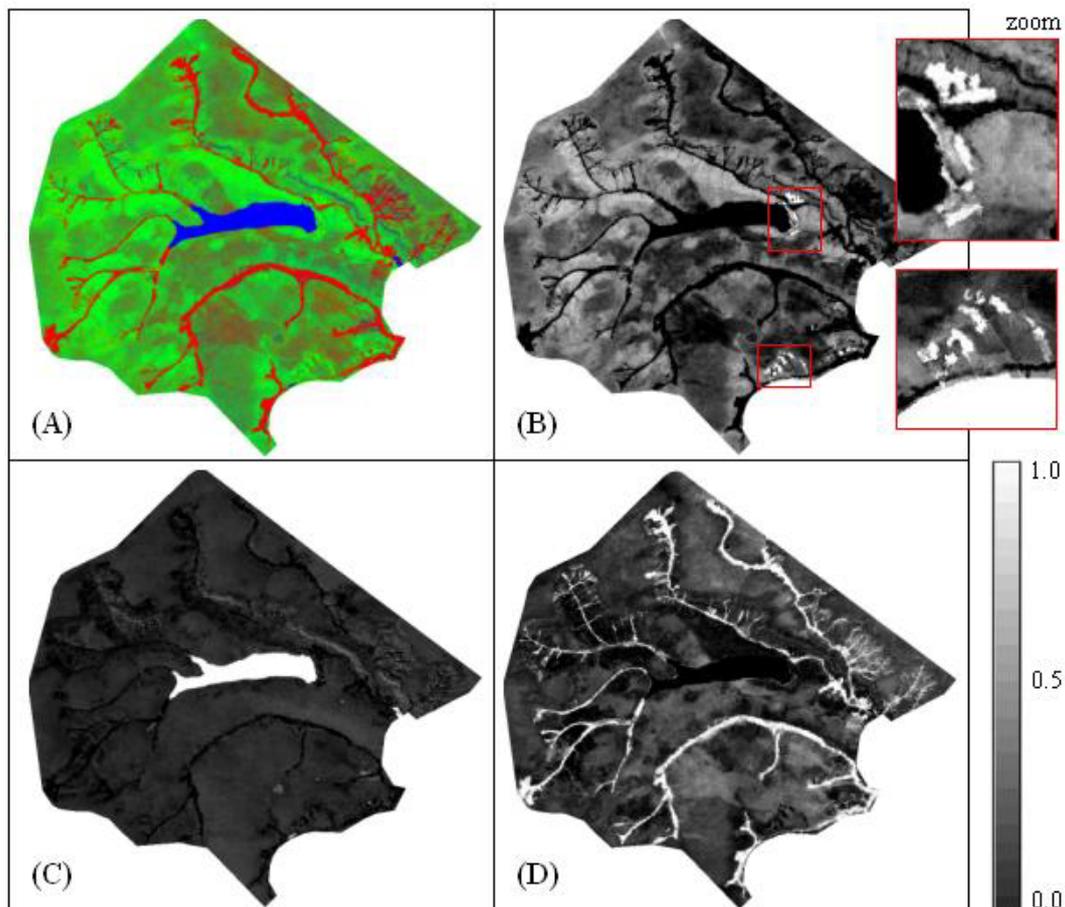
Na **Figura 4** são apresentadas as imagens-fração (bandas sintéticas), geradas com o método WLS, contendo as proporções para os componentes *vegetação* (Mata de Galeria), *solo* e *sombra* (água). Bandas sintéticas utilizando o método CLS foram geradas, com resultados muito similares ao WLS. Contudo, 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 arbóreo (e.g. Cerradão, Mata de Galeria) é praticamente nula. No outro extremo, encontra-se a imagem-fração

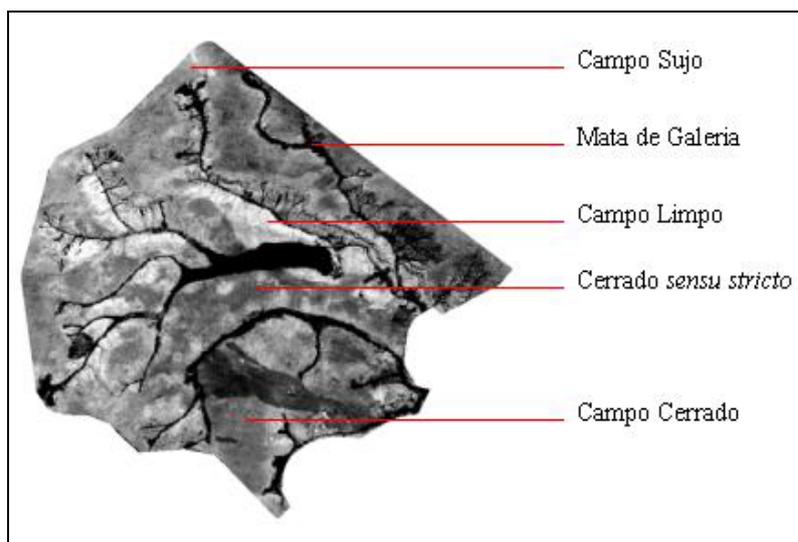
vegetação, a qual destacou, além das áreas com maior vigor vegetacional (Mata de Galeria), fisionomias de Cerrado pertencentes ao estrato arbustivo.

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.

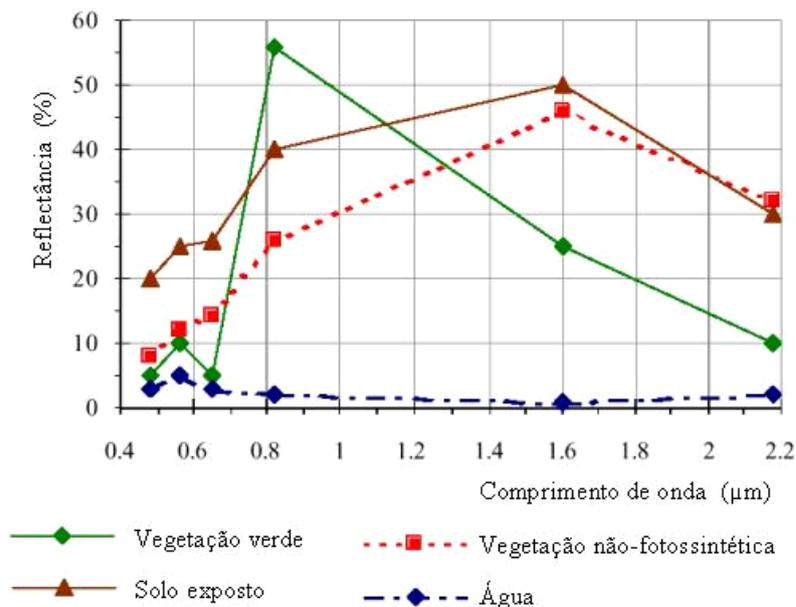
Imagens de sensoriamento remoto normalmente apresentam uma combinação de *pixels* puros e *pixels* misturados. Os *pixels* misturados surgem quando o campo de visada instantâneo do sensor (IFOV) inclui mais de uma classe de cobertura (Verhoeve & De Wulf, 2002). Como exemplo, pode-se citar as pequenas 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).

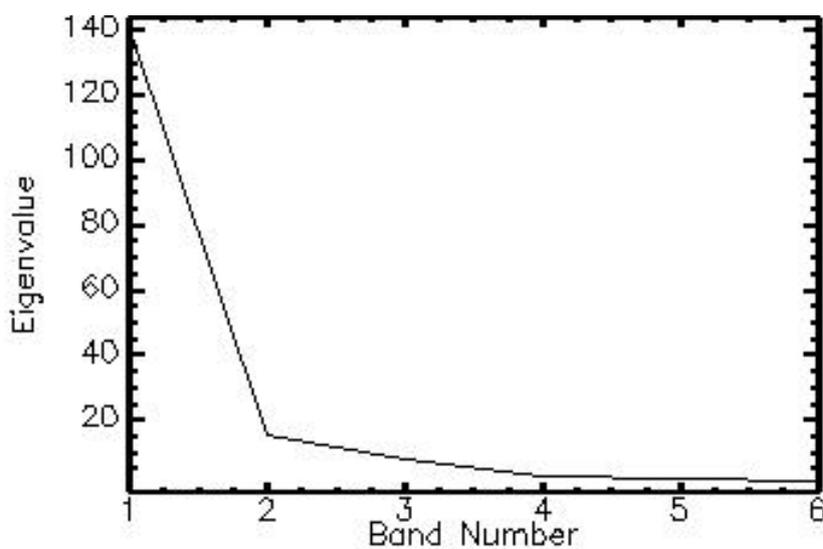
Antes da aplicação de um MLME, é necessário que a imagem, originalmente em números digitais (0 - 255), seja convertida para valores de reflectância aparente (Rogan et al. 2002; Shimabukuro et al., 1998). Este procedimento é fundamental para a geração de imagens-fração baseadas na reflectância dos componentes,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

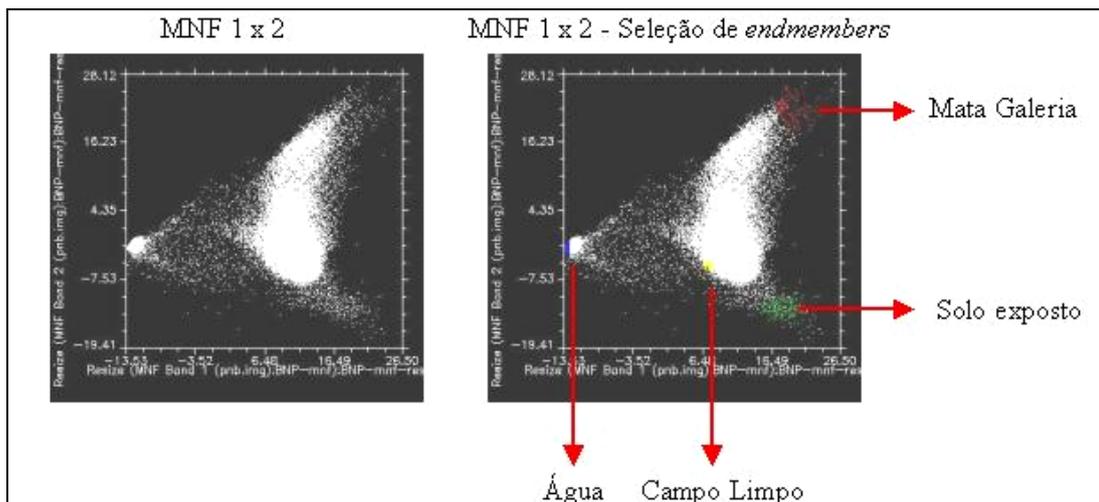
Após aplicação da APC ou MNF, a análise de mistura espectral pode ser realizada em duas etapas básicas (Shimazaki & Tateishi, 2001; Schweik & Green, 1999). A primeira etapa refere-se à aquisição de *pixels* puros, freqüentemente denominados de *endmembers*, visando separar um componente (ex: vegetação 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.



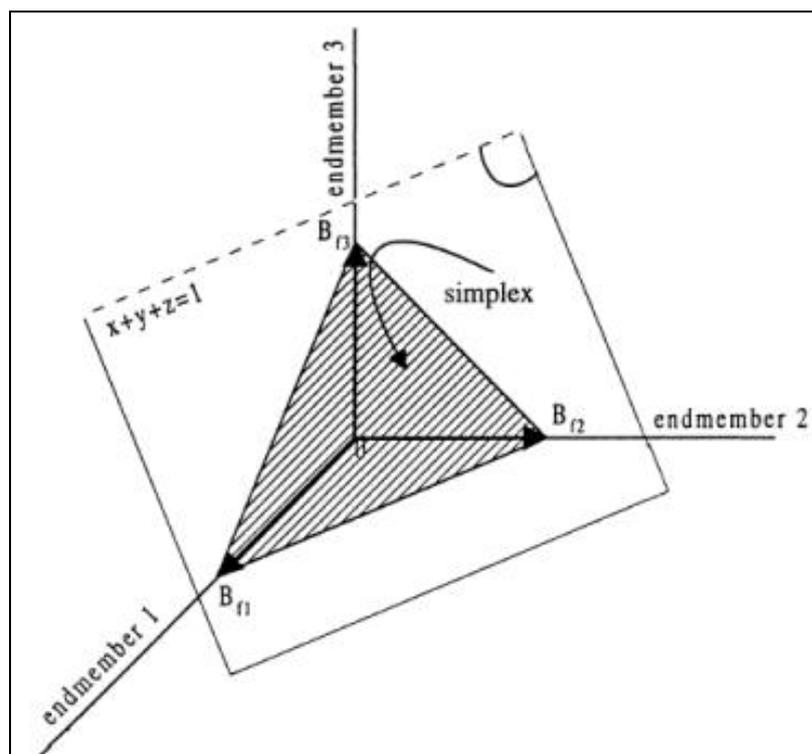
**Figura 2.** Distribuição dos eigenvalues após realização da transformação MNF com as bandas 1-5 e 7 do sensor Landsat 7 ETM+. Eigenvalues mais altos correspondem as resultantes MNF 1 e MNF 2.

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:

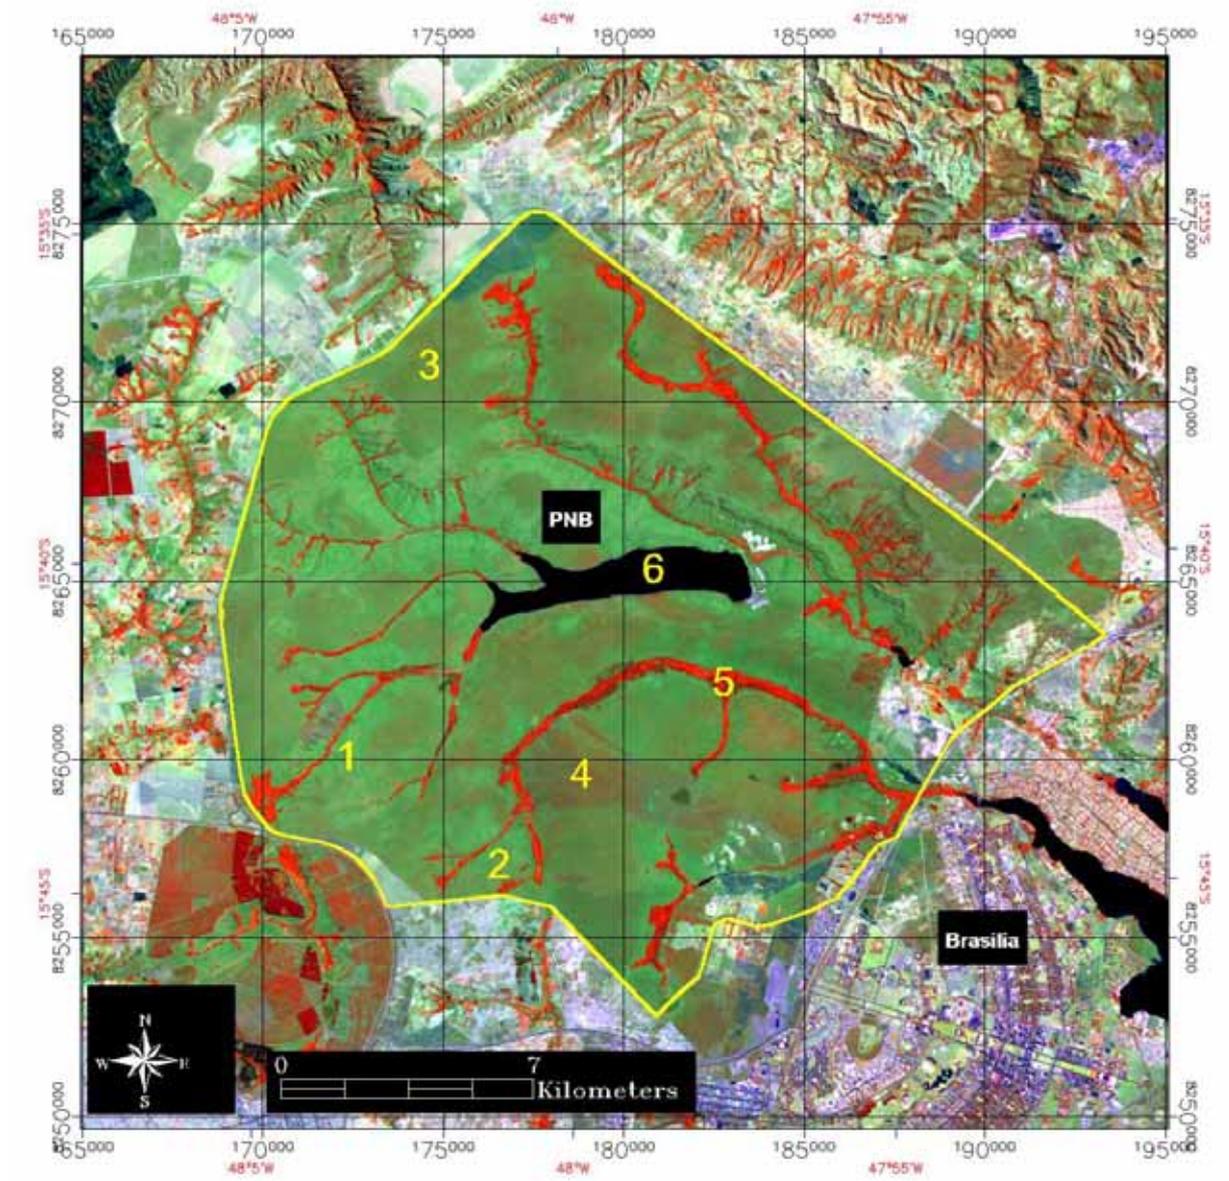
$$1 \geq x_j \geq 0 \text{ e } \sum x_j = 1 \quad (3)$$

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).

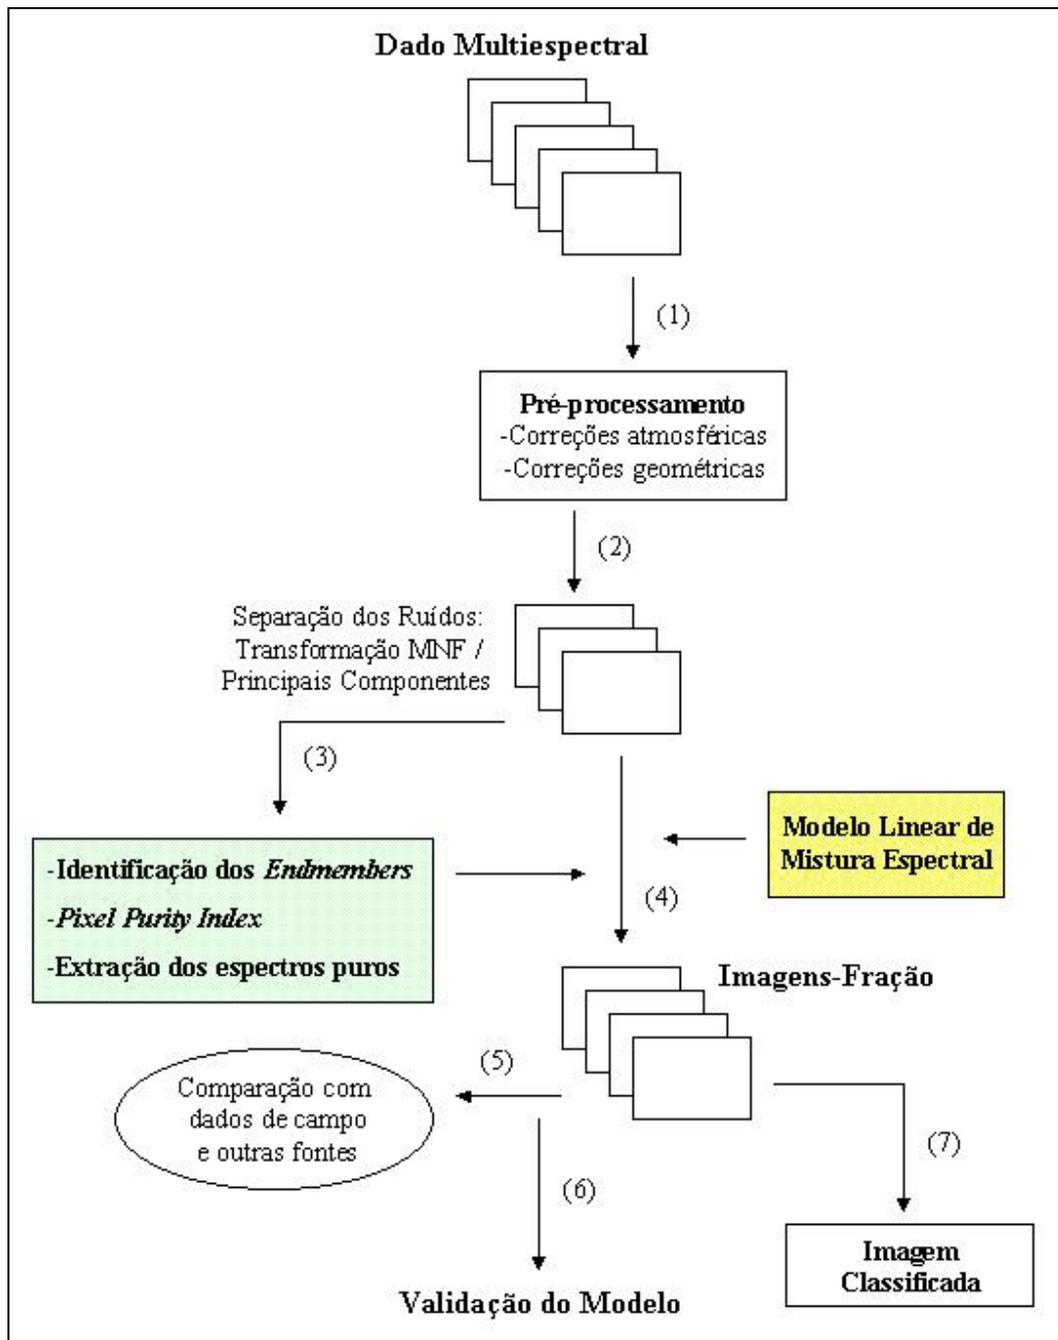


Figura 6. Esquema-resumo para aplicação do MLME na imagem do PNB. Modificado de Bajjouk et al. (1998).

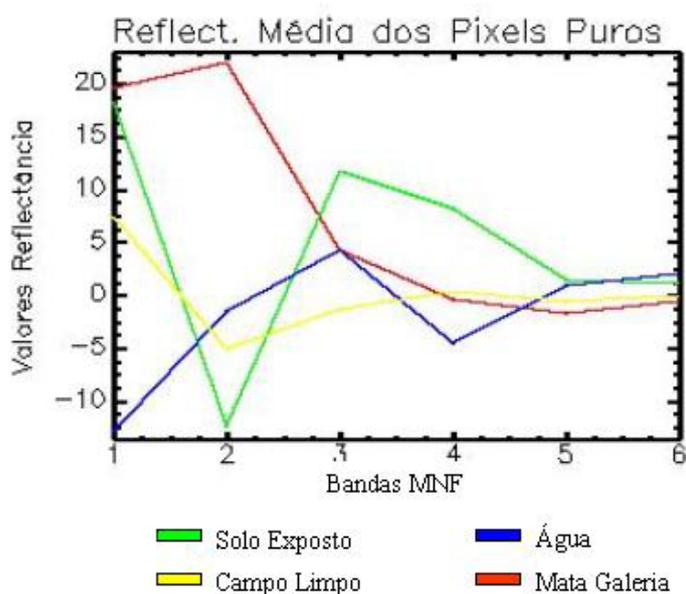
#### 4 - RESULTADOS PRELIMINARES E CONCLUSÕES

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*

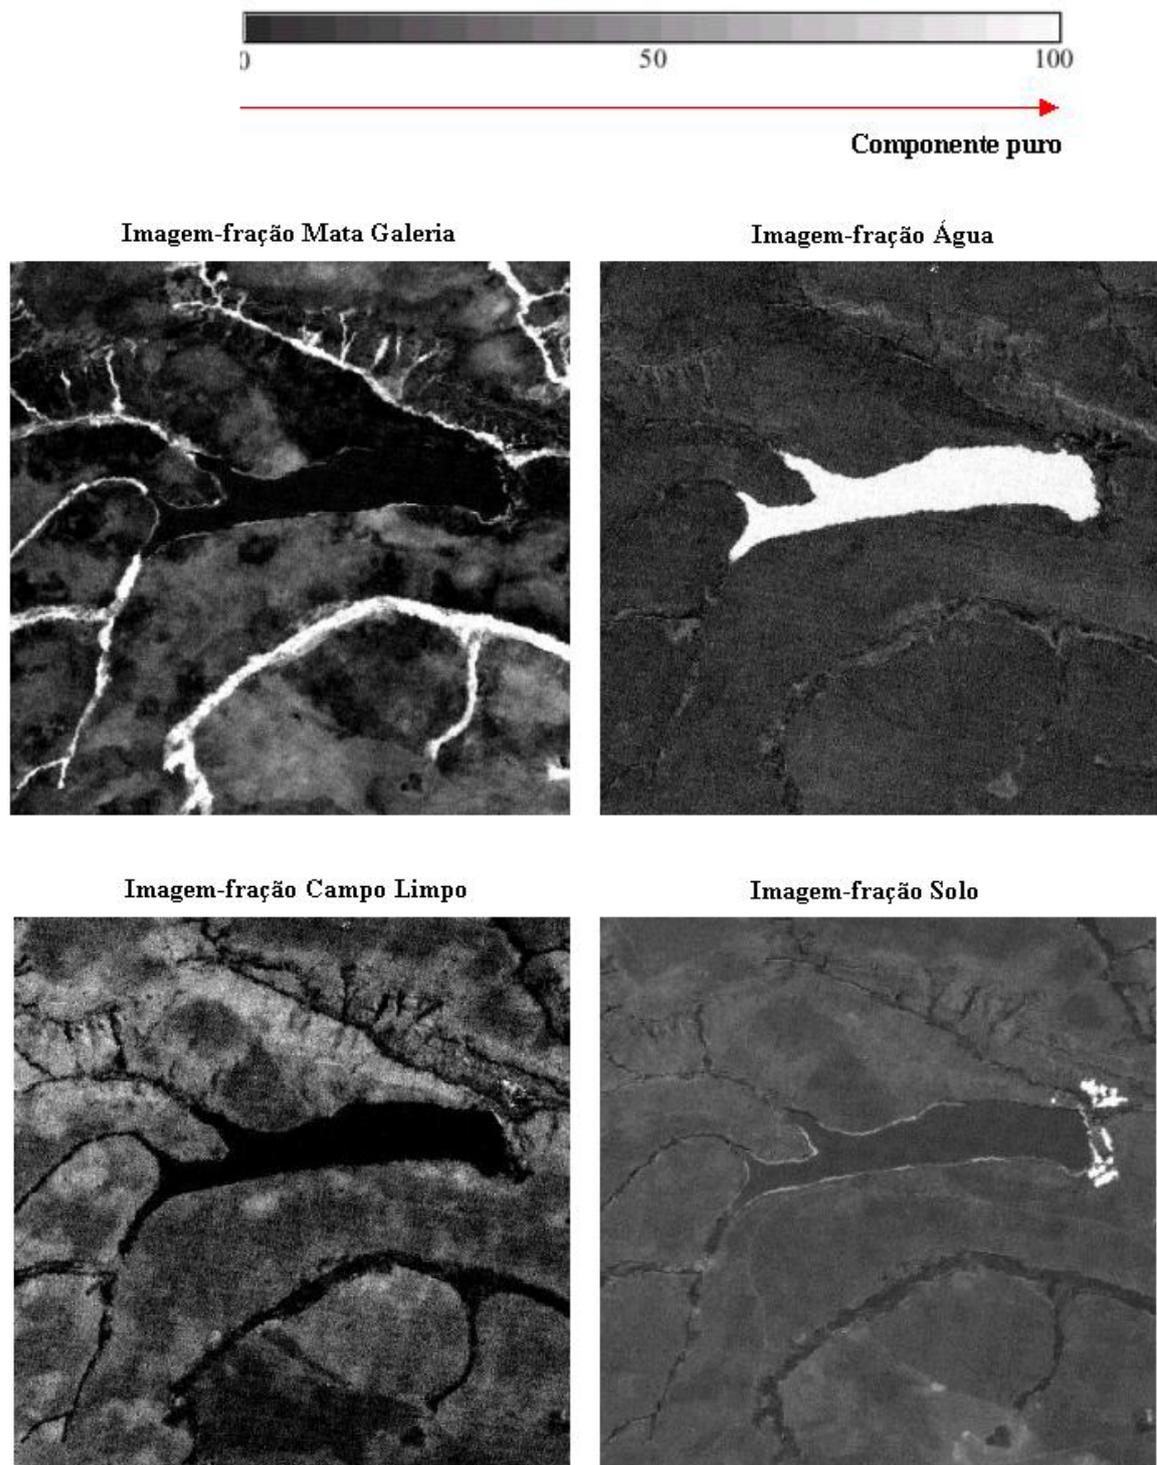
puros. A figura 7 ilustra as curvas de reflectância média utilizadas no MLME, correspondendo aos 4 componentes analisados.

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.

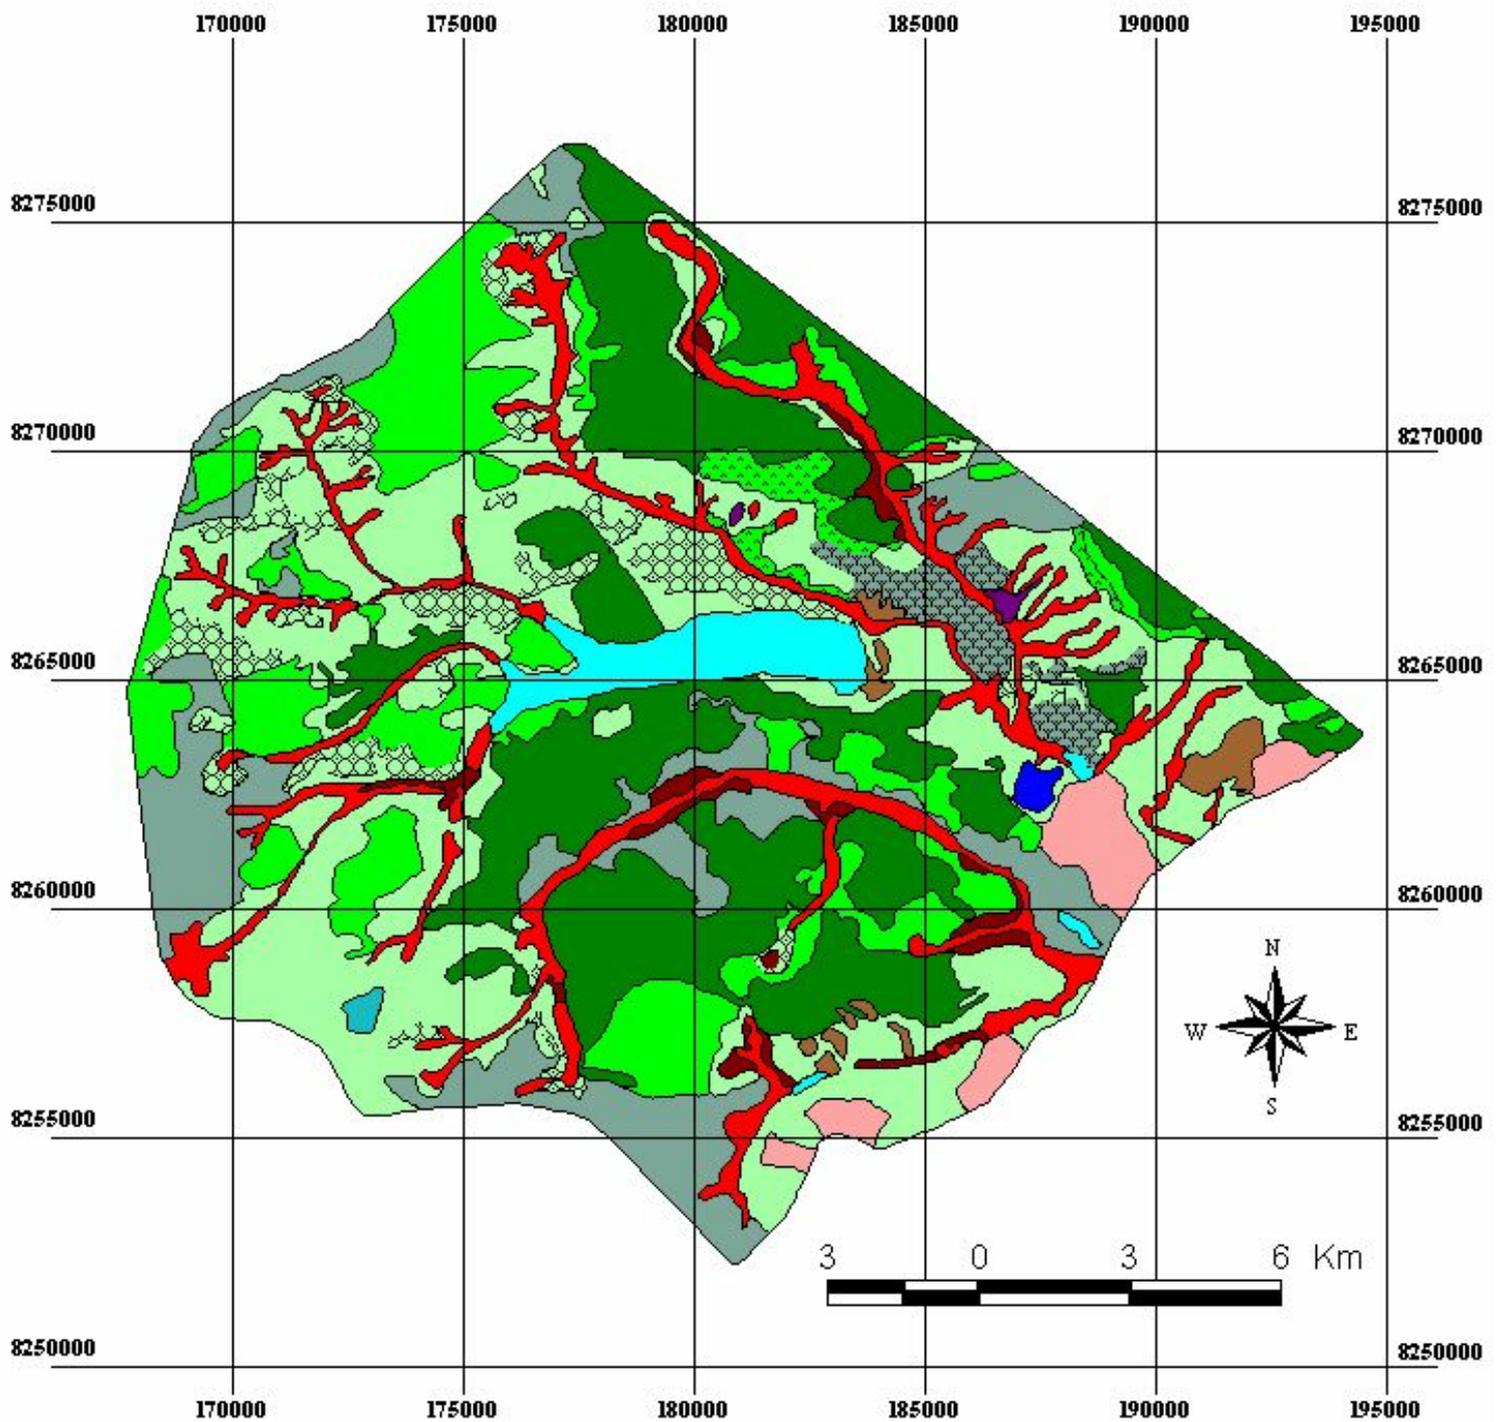
VERHOEYE, J.; DE WULF, R. Land cover mapping at sub-pixel scales using linear optimization techniques. **Remote Sensing of Environmental**, New York, v. 79, p. 96-104, 2002.

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.**

# PARQUE NACIONAL DE BRASÍLIA MAPA DE VEGETAÇÃO ATUALIZADO



- |                                                                                     |                       |                                                                                     |                     |                                                                                       |                                                                            |
|-------------------------------------------------------------------------------------|-----------------------|-------------------------------------------------------------------------------------|---------------------|---------------------------------------------------------------------------------------|----------------------------------------------------------------------------|
|  | Mata de Galeria       |  | Brejo               |  | Campo Cerrado com Trembléias                                               |
|  | Cerrado sensu stricto |  | Mata de Interflúvio |  | Reflorestamento                                                            |
|  | Campo Cerrado         |  | Área construída     |  | Campo Limpo com Murundum                                                   |
|  | Campo Sujo            |  | Corpos d' água      |  | Campo Sujo com presença de lychnophora ericoides (amica) e "canela de ema" |
|  | Campo Limpo           |                                                                                     |                     |                                                                                       |                                                                            |
|  | Campo Limpo Úmido     |                                                                                     |                     |                                                                                       |                                                                            |
|  | Solo Exposto          |                                                                                     |                     |                                                                                       |                                                                            |

Projeção UTM, Sad 69, Fuso 23  
 Manuel Eduardo Ferreira  
 Projeto UnB - Geo / PNB. Dez. 2002

## REFERÊNCIAS BIBLIOGRÁFICAS

ADAMS, J. B.; SABOL, 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.

BANNARI, A.; MORIN, D.; BONN, F.; HUETE, A. R. A review of vegetation indices. **Remote Sensing Reviews**, v. 13, p. 95-120, 1995.

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).

BRASIL. Ministério do Meio Ambiente. **Primeiro relatório nacional para a convenção sobre diversidade biológica - Brasil. Serviços do ponto focal brasileiro do mecanismo de informação da convenção sobre diversidade biológica.** Disponível em: <http://www.mma.gov.br/port/sbf/chm/relato.html>. Acesso em: 03 de abril 2003.

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.

CODEPLAN (Companhia de Desenvolvimento do Planalto Central). **Base cartográfica digital**. Brasília, 1996.

CRÓSTA, A. P. **Processamento de imagens digitais de sensoriamento remoto**. Campinas: UNICAMP, 1992. 170 p.

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.

DIAS, B. F. S. Cerrados: uma caracterização. In: DIAS, B. F. S. (Org.). **Alternativas de desenvolvimento dos Cerrados: manejo e conservação dos recursos naturais renováveis**. Brasília: Fundação Pró-Natureza, 1992. p. 11-25.

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.

DUARTE, V.; SHIMABUKURO, Y. E.; AULICINO, L. C. M. Metodologia para padronizar e atualizar o banco de dados do Projeto “PRODES Digital”. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., 2003, Belo Horizonte, MG. **Anais...** São José dos Campos: INPE, 2003. p. 2705 - 2712.

EITEN, G. The Cerrado vegetation of Brazil. **The Botanical Review**, New York, v. 38, n. 2, p. 201-341, 1972.

EITEN, G. **Vegetação natural do Distrito Federal**. Brasília: UnB: SEBRAE, 2001. 162 p.

EMBRAPA CERRADOS. **Mapa de reconhecimento dos solos do DF**: base cartográfica digital. Planaltina, DF, 1978.

FARRAND, W. H. 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.

FERREIRA, L. G.; HUETE, A. R. Assessing the seasonal dynamics of the Brazilian Cerrado vegetation through the use of spectral vegetation indices. **International Journal of Remote Sensing**, 2002 (*in press*).

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). **Remote Sensing of Environment**, New York, 2003a (*in press*).

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, 2003b. 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.

FREITAS-SILVA, F. H. **Inventário hidrogeológico e dos recursos hídricos superficiais do Distrito Federal**. Brasília: IEMA: SEMATEC: UnB, 1998. v. 1.

FREITAS-SILVA, F. H.; CAMPOS, J. E. G. Geologia do Parque Nacional de Brasília - DF. **Boletim de Geociências do Centro-Oeste**, [S. l. ], v. 18, n. 1/2, p. 32-43, 1995.

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, 2001a. 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, 2001b. 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.

GARDNER, M. E.; ROBERTS, D. A.; FUNK, C.; NORONHA, V. Road Extraction from AVIRIS using Spectral Mixture and Q-Tree filter techniques.

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, A. A.; BERMAN, M.; SWITZER, P.; CRAIG, M. D. A transformation for ordering multispectral data in terms of image quality with implications for noise removal. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 26, n. 1, 1988.

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).

GUIMARÃES, V. S. **Cr terios para delimita o de zonas de transi o de unidades de conserva o**: o caso da zona de transi o do Parque Nacional de Bras lia - DF. 2000. 166 f. Disserta o (Mestrado) – Universidade de Bras lia, Bras lia.

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**, New York, v. 35, p. 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**, Londres, v. 14, p. 2231-2240, 1993.

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.

HUETE, A. R.; DIDAN, K; MIURA, T.; RODRIGUEZ, E. P.; GAO, X.; FERREIRA, L. G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, New York, v. 83 p. 195-213, 2002.

JACKSON, R. D.; HUETE, A. R. Interpreting vegetation indices. **Preventive veterinary Medicine**, v. 11, p. 185-200, 1991.

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).

LEE, J. B.; WOODYATT, A. S.; BERMAN, M. Enhancement of high spectral resolution remote-sensing data by a noise-adjusted principal components transform. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 28, n. 3, 1990.

MARKHAM, B. L.; BARKER, J. L. **Landsat MSS and TM post-calibration dynamic ranges, exoatmospheric reflectances and at-satellite temperatures**. [S. 1]: EOSAT, 1986. (Landsat Technical Notes, n. 1).

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 science: remote sensing of environment**. 2. ed. New York: John Wiley & Sons, 1985. 413 p.

MENDONÇA, R. C.; FELFILI, J. M.; WALTER, B. M. T.; SILVA, M. C.; REZENDE, A. V.; FILGUEIRAS, T. S.; NOGUEIRA, P. E. Flora vascular do Cerrado. In: SANO, S.M.; ALMEIDA, S.P. (Ed.). **Cerrado**: ambiente e flora. Planaltina, DF: Embrapa Cerrados, 1998. p. 289-556.

MITTERMEYER, R. A.; MYERS, N.; MITTERMEIER, C. G. Hotspots Earth's biologically richest and most endangered terrestrial ecoregions. CEMEX Conservation International, 1999.

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. **Anais...** São José dos Campos: INPE, 2003. p. 1077-1082.

MONTEIRO, J. M. G. **Fluxo de CO<sub>2</sub> em um Cerrado *sensu stricto***. 1995. 61 f. Dissertação (Mestrado) – Universidade de Brasília, Brasília.

MOREIRA, R. C. **Espectroscopia por imageamento**. [ S. l. : s. n.], 2002. 145 p. Material elaborado para o Centro Técnico Aeroespacial, Instituto de Estudos Avançados, maio de 2002.

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.

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.

OUAIDRARI, H.; VERMOTE, E. F. Operational atmospheric Correction of Landsat TM data. **Remote Sensing of Environment**, New York, v. 70, issue 1, p.4-15, 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.

PINHEIRO, G. G. C. **Análise dos dados digitais de imagem de radar (satélite JERS-1, banda L) para estudos de vegetação, solos e geologia na região do Cerrado**. 1999. 97 f. Dissertação (Mestrado) – Universidade de Brasília, Brasília.

PIVELLO, V. R.; COUTINHO, L. M. A qualitative successional model to assist in the management of Brazilian cerrados. **Forest Ecology and Management**, Amsterdam, v. 87, p. 127-138, 1996.

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.

PONZONI, F. J. Comportamento espectral da vegetação. In: MENESES, P. R.; MADEIRA NETTO, J. S. (Org.). **Sensoriamento remoto: reflectância dos alvos naturais**. Brasília: UnB; Planaltina, DF, Embrapa Cerrados, 2001. p. 63-119.

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.

RAMOS, P. C. M. **Vegetation communities and soils in National Park of Brasília**.1995. 203 f. Tese (Doutorado) - University of Edinburgh, Edinburgh.

RIBEIRO, J. F.; WALTER, T. M. B. Fitofisionomias do bioma cerrado. In: SANO, S.M.; ALMEIDA, S.P. (Ed). **Cerrado: ambiente e flora**. Planaltina, DF: Embrapa Cerrados, 1998. p. 89-166.

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.

SABINS, F. F. **Remote sensing: principles and interpretation**. San Francisco: Freeman and Company, 1978. 426 p.

SABOL, 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.

SANO, E. E.; BARCELLOS, A. O.; BEZERRA, H. S. Assessing the spatial distribution of cultivated pastures in the Brazilian savanna. **Pasturas Tropicales**, Cali, v. 22, n. 3, p. 2-15, 2002.

SANO, E. E.; PINHEIRO, G. G. C.; MENESES, P. R. Assessing JERS-1 synthetic aperture radar data for vegetation mapping in the Brazilian savanna. **Journal of the Remote Sensing Society of Japan**, Tokio, v. 21, n. 2, p. 158-167, 2001.

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.

SILVA, G. T. **Fluxos de CO<sub>2</sub> em um campo sujo submetido à queimada prescrita.** 1999. 64 f. Dissertação (Mestrado em Ecologia) – Universidade de Brasília, Brasília.

SOUZA, C. M.; 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.

TAFNER, M. A. As redes neurais artificiais: plasticidade e aprendizagem. **Cérebro & Mente**, Campinas, v. 2, n. 5, p. 1-7, 1998. Disponível em: <<http://www.epub.org.br/cm/home.htm>>. Acesso em: 12 fevereiro de 2003.

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.