

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.

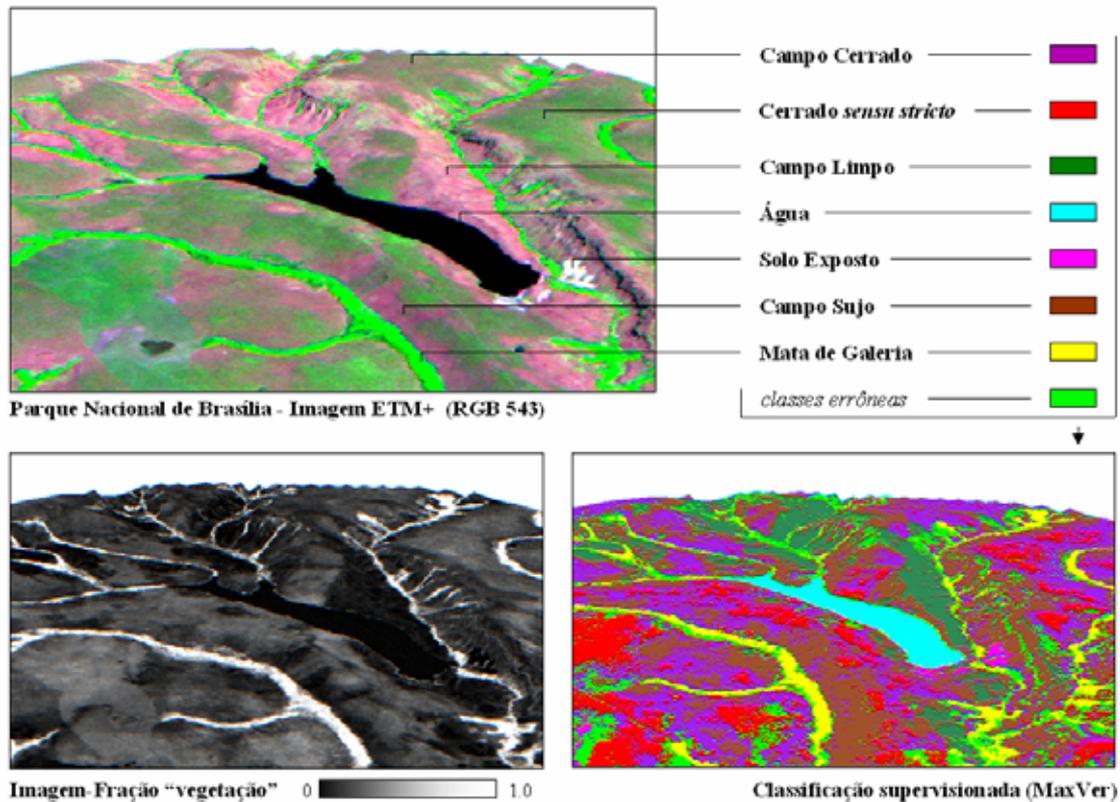


Figura 2.1. Imagem do Parque Nacional de Brasília, submetida ao MLME (Imagem Fração *vegetação*) e a uma classificação supervisionada (*MaxVer*). Na Imagem Fração, a variação na escala de cinza indica, de forma contínua, a proporção de um determinado alvo (ex. Mata de Galeria).

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 ρ_{NIR} e ρ_{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.

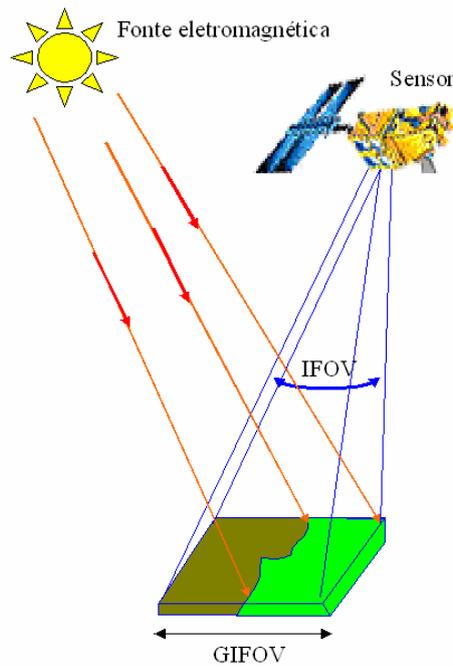


Figura 2.2. Representação física de um *pixel* misturado, devido à presença de dois tipos de materiais no GIFOV do sensor.

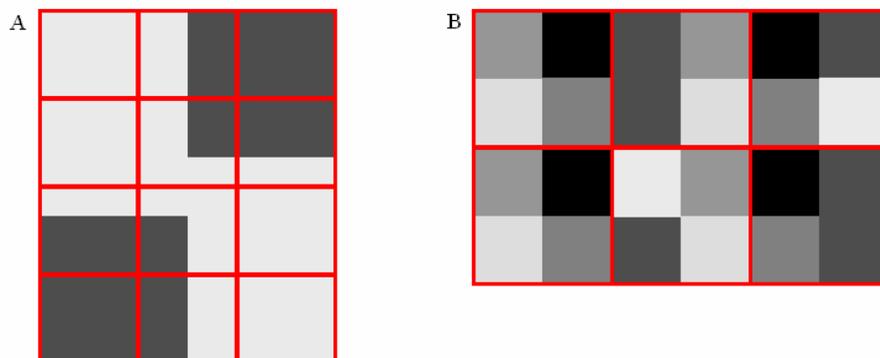


Figura 2.3. (A) O *pixel* (linha vermelha) se encontra na fronteira de alvos diferentes. (B) Diferentes materiais contidos em um único *pixel*.

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**).

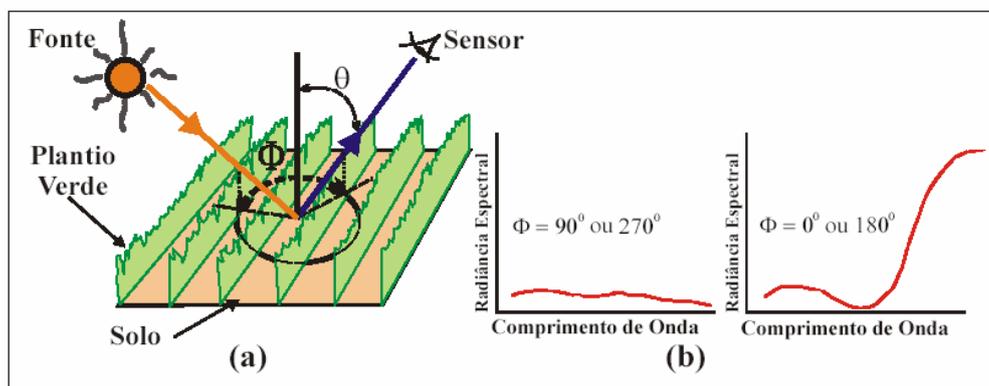


Figura 2.4. (a) Geometria de reflexão em um plantio. (b) Variação da radiância espectral em função dos diferentes ângulos zenitais (solares).

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.

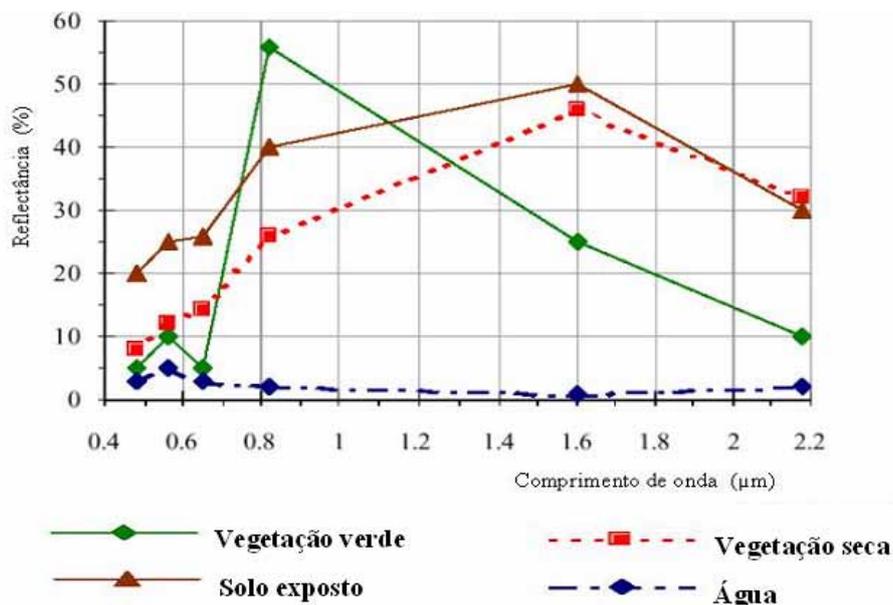


Figura 2.5. Curvas de reflectância da vegetação verde, vegetação seca (não-fotossintética), solo exposto e água. Modificada de Shimazaki e Tateishi (2001).

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).

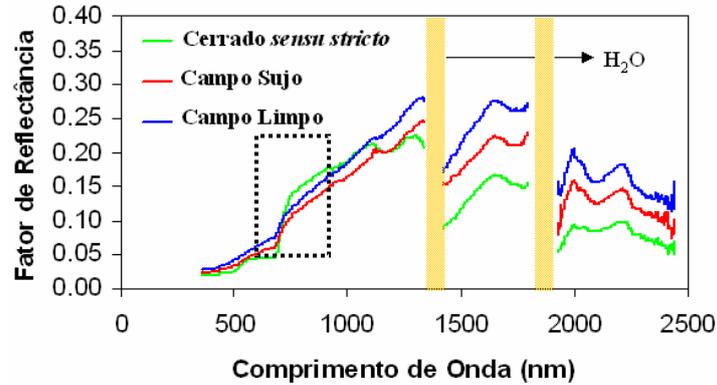


Figura 2.6. Comportamento espectral de três classes de vegetação, típicas do bioma Cerrado: Cerrado *sensu stricto*, Campo Sujo e Campo Limpo, obtidas por espectrorradiometria de campo no Parque Nacional de Brasília (época seca). A área circulada indica a confusão espectral destas classes na região do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

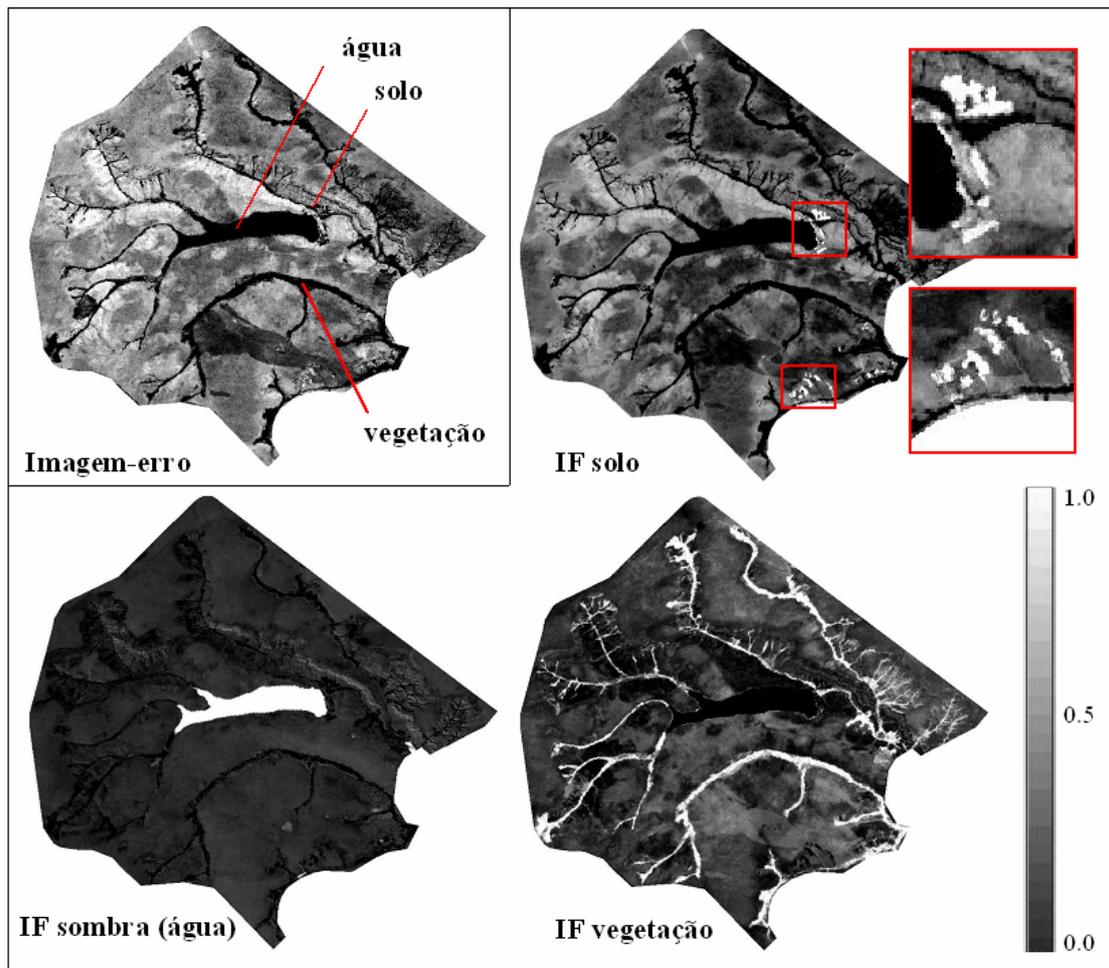


Figura 2.7. Imagens Fração *solo*, *vegetação* e *sombra* (água) do Parque Nacional de Brasília, com a respectiva imagem erro.

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).

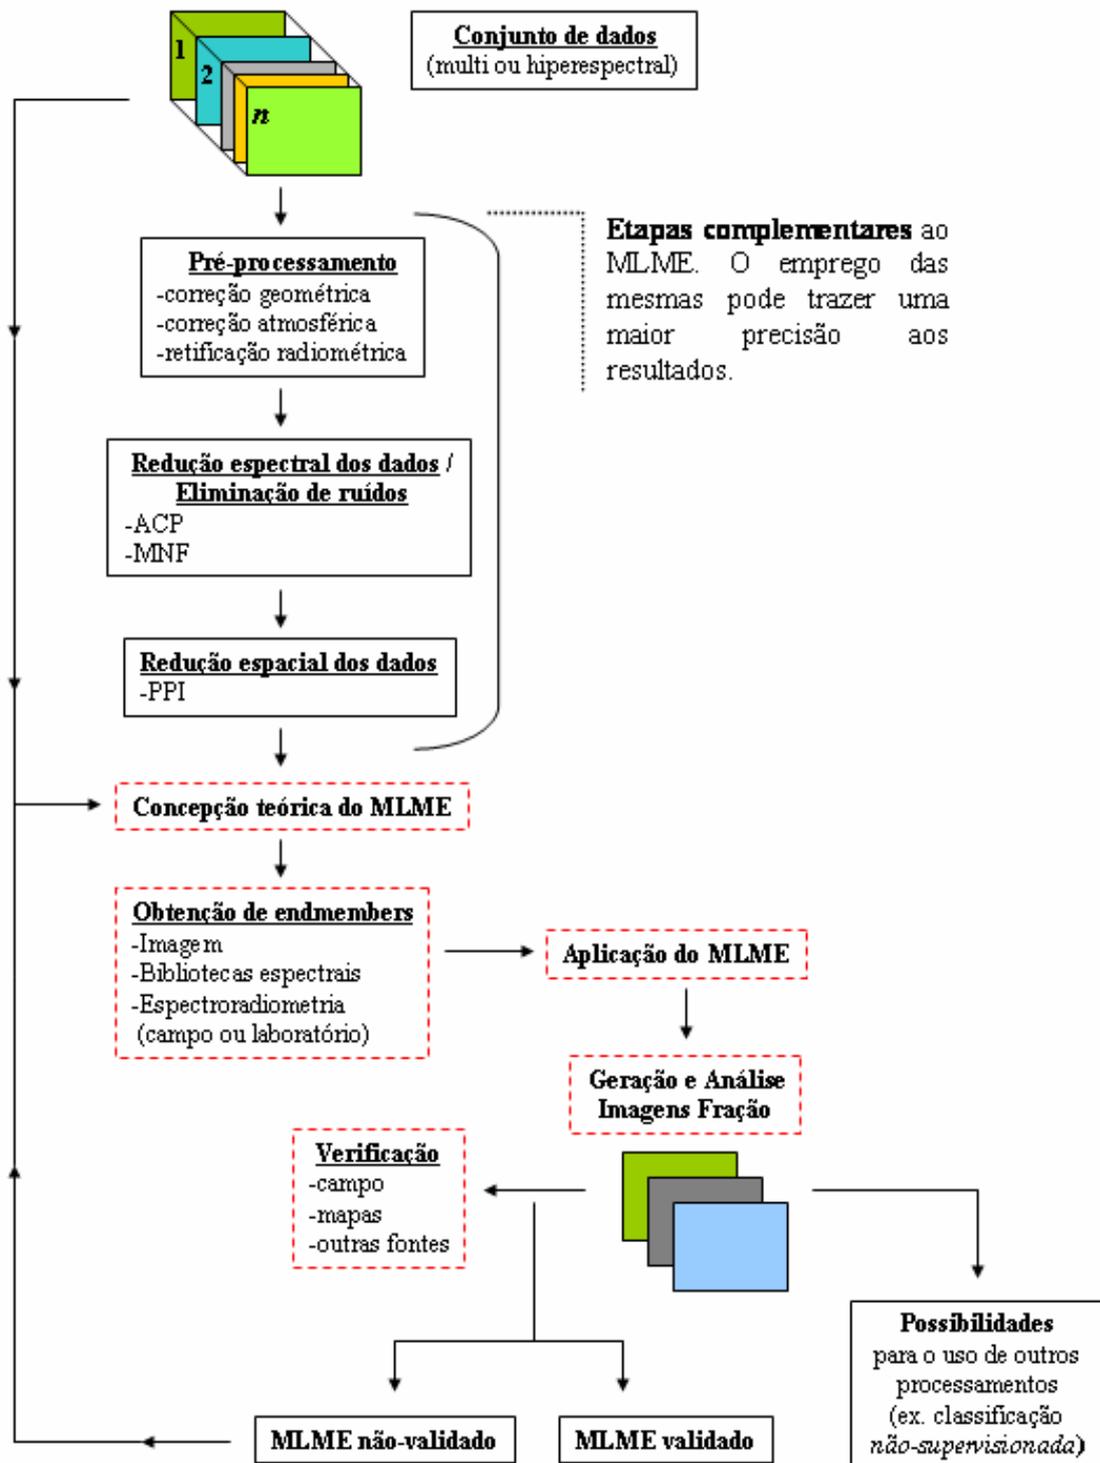


Figura 2.8. Método geral, com as etapas obrigatórias (caixa tracejada na cor vermelha) e complementares, para a aplicação de um Modelo Linear de Mistura Espectral em dados multiespectrais ou hiperespectrais.

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.

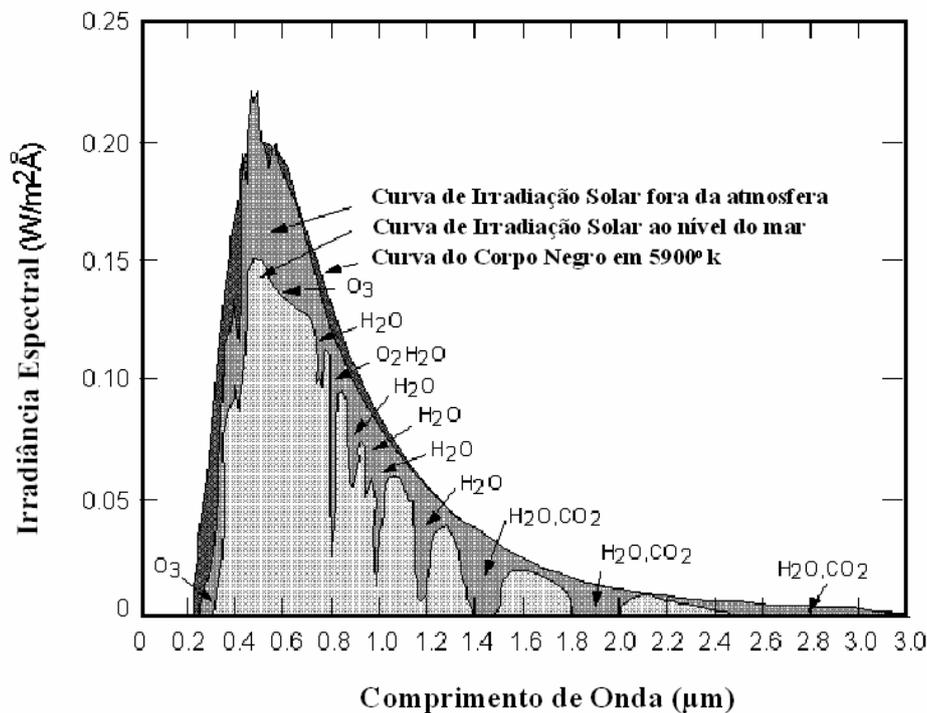


Figura 2.9. Espectro solar com as bandas de absorção/interferência atmosférica.

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.

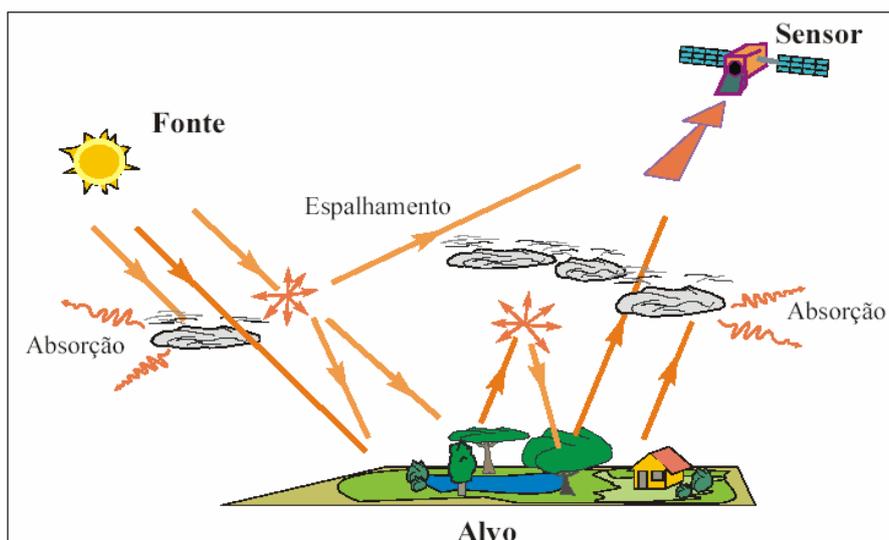


Figura 2.10. Influência da atmosfera na trajetória da radiação eletromagnética entre a fonte e o sensor. Fonte: Moreira (2002).

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).

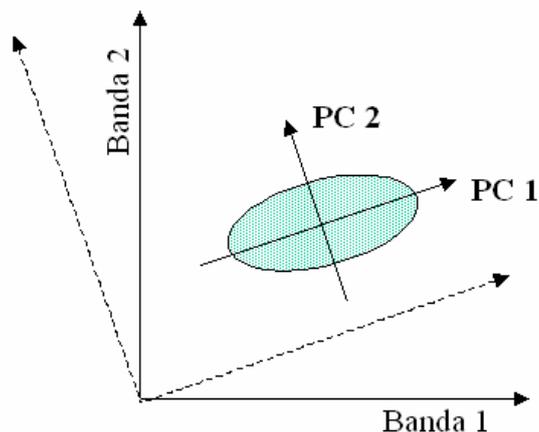


Figura 2.11. Representação gráfica da Análise por Componentes Principais em duas dimensões. Os eixos originais da imagem (bandas 1 e 2) são rotacionados, redistribuindo os *pixels* (elipse) sobre um novo sistema de eixos, formado pelas Componentes Principais 1 e 2.

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.

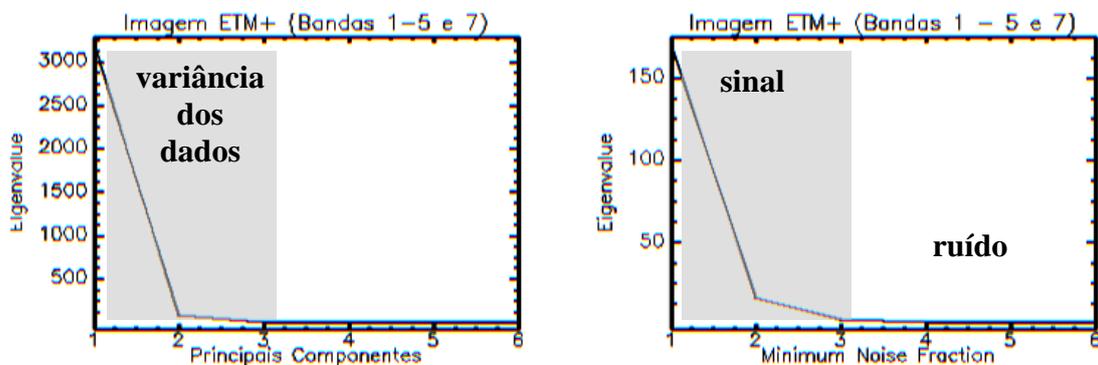


Figura 2.12. Distribuição dos autovalores (*eigenvalues*) após realização da ACP e do MNF, para as bandas 1-5 e 7 do sensor ETM+.

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.

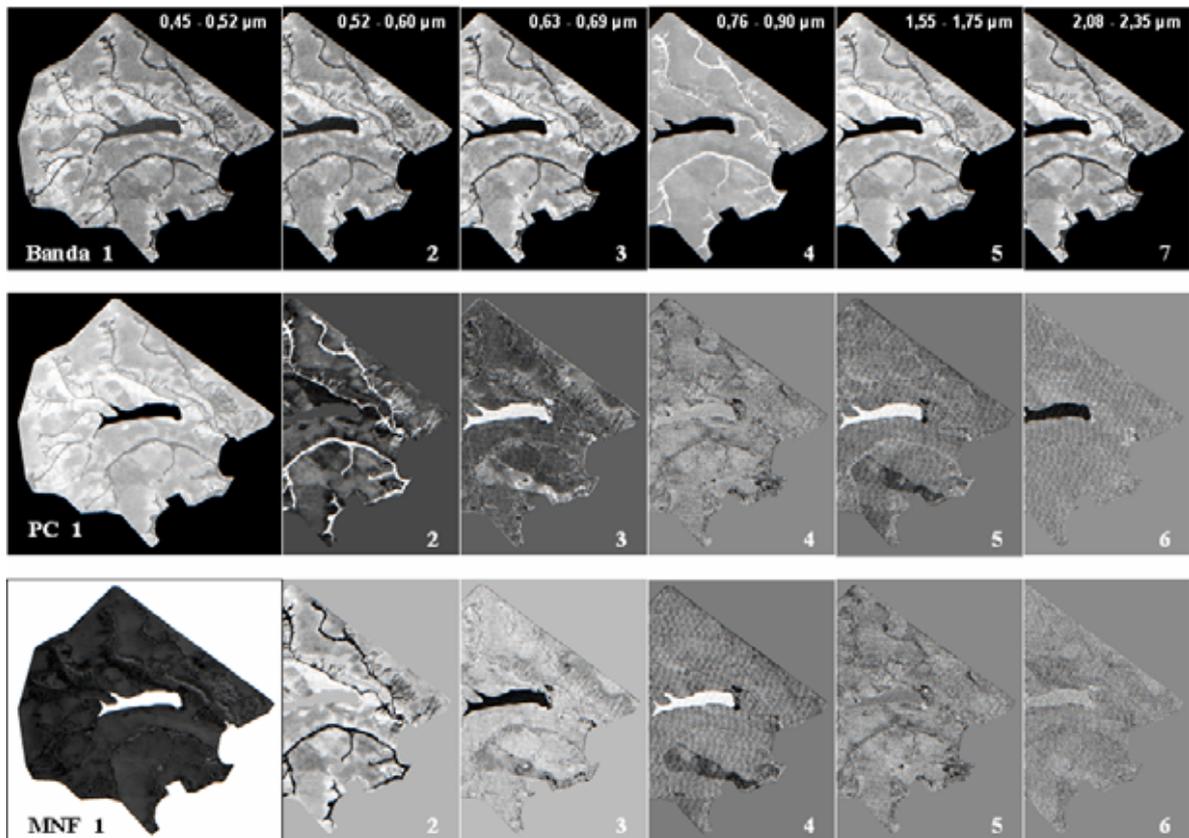


Figura 2.13. A primeira fileira de imagens corresponde às bandas 1-5 e 7 do sensor ETM+, Parque Nacional de Brasília (julho de 2001). A segunda fileira corresponde às imagens resultantes da ACP. A terceira fileira corresponde às imagens resultantes da transformação MNF. Note que os ruídos ficam segregados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

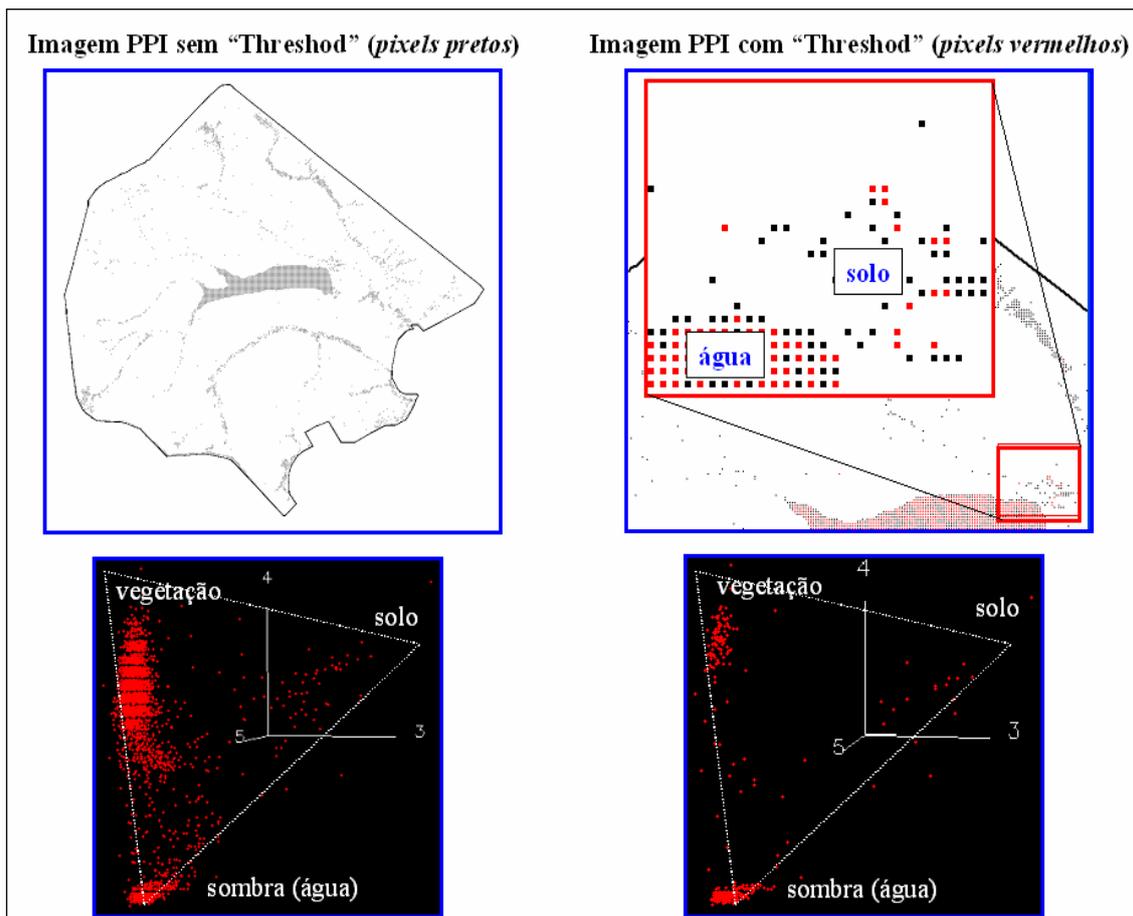


Figura 2.14. Imagem resultante do *Índice de Pureza dos Pixels (Pixel Purity Index - PPI)*, representando os *pixels* espectralmente puros, e sobreposição destes *pixels* após o uso de um limite mínimo e máximo, visando a seleção de *endmembers* em áreas específicas da imagem.

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.

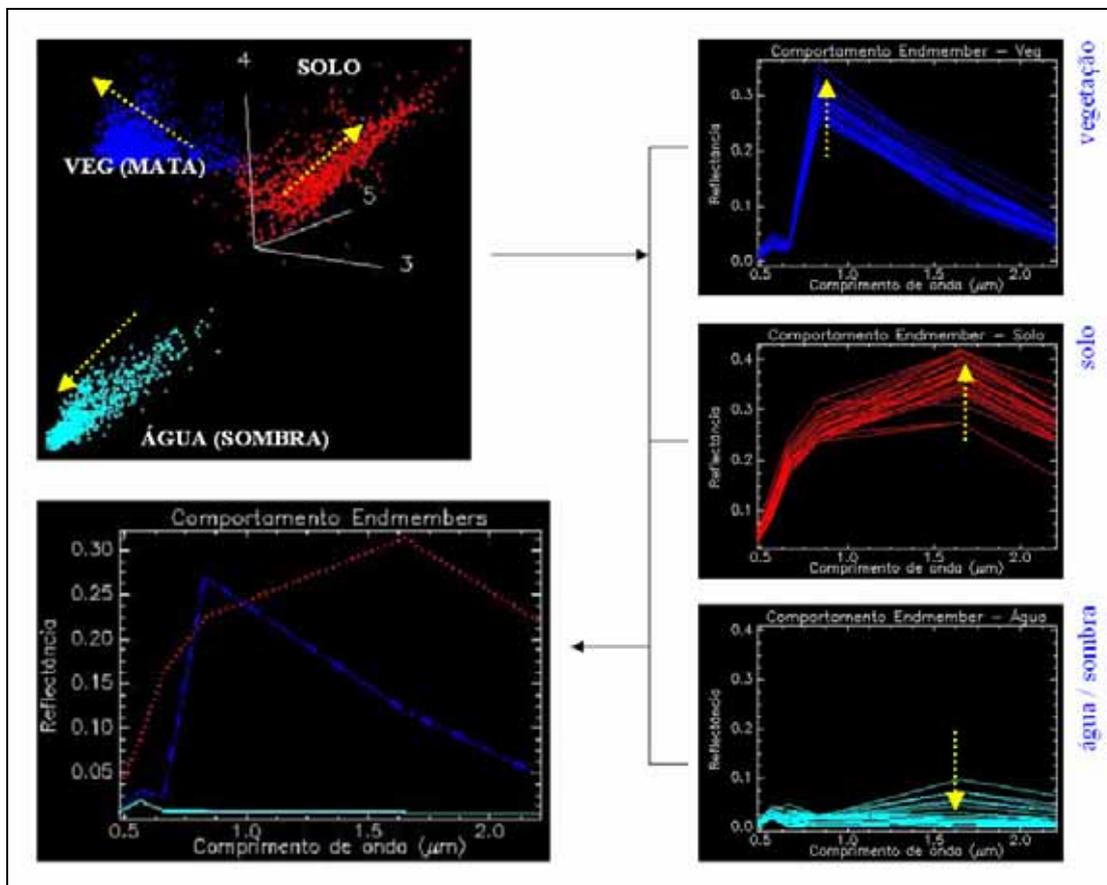


Figura 2.15. Distribuição dos *pixels* no espaço amostral vermelho- infravermelho próximo, onde a proximidade dos extremos favorece a busca por componentes espectralmente mais puros, como demonstrado pelo comportamento dos espectros.

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.

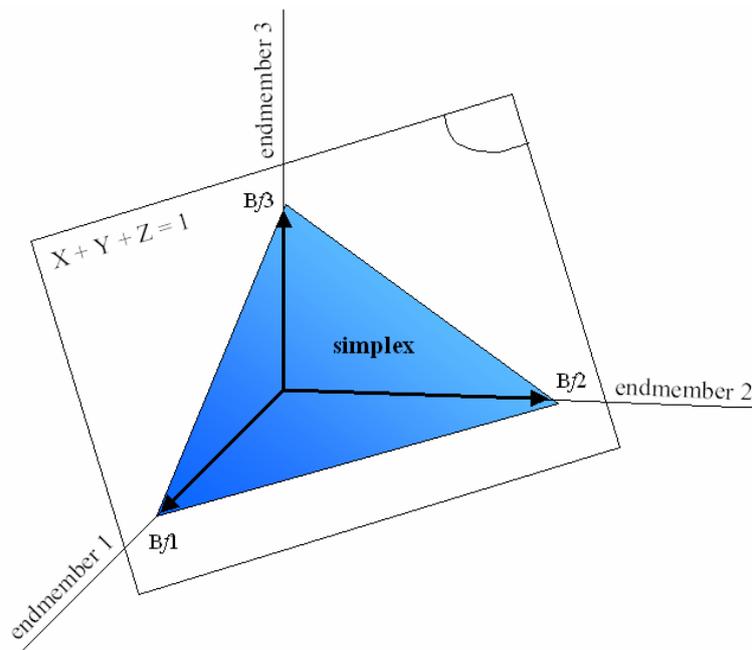


Figura 2.16. Simplex de frações em um caso tridimensional, onde Bf1, Bf2 e Bf3 são as bases ortogonais para três *endmembers*, atendendo às restrições do método (Equação 2.7). Modificada de Bajjouk et al. (1998).