

Comparação de Modelo Linear de Mistura Espectral (MLME) e Modelo Não Linear de Mistura Espectral (MNLME) aplicados à dados TM/Landsat-5 com dados subpixel do sensor RapidEye.

José Marinaldo Gleriani¹
Pedro Henrique Silva Ferreira²
Vicente Paulo Soares¹

¹Universidade Federal de Viçosa - DEF
36570-000 - Viçosa - MG, Brasil
{gleriani, vicente} @ufv.br

²Universidade Federal de Viçosa –Geografia/CCH
36570-000 - Viçosa - MG, Brasil
pedro.h.henrique@ufv.br

Abstract. Linear Spectral Mixture Models (MLME) have been widely used for equating the proportion of components within a mixed pixel. However, some authors have investigated using nonlinear Spectral Mixture (MNLME) in modeling these components. In this study, the MLME was compared with MNLME which run through a supervised MLP (Multilayer Perceptrons) network where TM / Landsat (30m) data were used as input layer. Data used as output layer included the proportion of the components obtained from a Rapideye scene (5m) considering two situations: the proportion of components (shade, vegetation and sand) after MaxVer classification and the proportion of components after application of the MLME in the Rapideye image. The choice of the best model was based on the total mean absolute error, with the MLME having provided a better fit of the proportions of mixed pixel.

Palavras-chave: modelo linear de mistura espectral, modelo não linear de mistura espectral, Landsat TM, pixel impuro, linear spectral mixture model, non-linear spectral mixture model, TM/Landsat, mixed pixel.

1. Introdução

Pixel é a unidade espacial de uma cena, cuja “impureza” esta associada às características de fragmentação da paisagem, diversidade de cobertura e resolução espacial do sensor. A análise de mistura espectral provê uma alternativa para determinar as proporções dos componentes dentro de um pixel impuro (misto) (Tso e Mather, 2001). Alguns trabalhos (Quintanoet al., 2011; Cardozo et al., 2011) utilizaram três, as vezes quatro (Nascimento, 1997) componentes puros (*endmembers*), os quais, em diferentes combinações, representariam o valor digital de qualquer pixel da cena. O modelo mais utilizado para solucionar as proporções no pixel misto – Modelo Linear de Mistura Espectral – MLME é expresso pela Equação 1 (Van de Voorde et al, 2009):

$$DN_b = \sum_{i=1}^n S_{i,b} F_i + E_b \quad (1)$$

Onde DN_b é o valor digital do pixel para banda b , F_i é a proporção de cada “*endmember*” dentro do pixel, $S_{i,b}$ é a reflectância do “*endmember*” i na banda b , n é o número de “*endmembers*” e E_b é o erro de ajuste para a banda b .

O princípio físico a qual está baseado os Modelos Lineares de Mistura Espectral (MLME), é que não existe espalhamento múltiplo entre os diferentes tipos de cobertura, assim, a energia que chega ao sensor é uma soma linear simples de cada componente da cobertura Terrestre (Tso e Mather, 2001)

Um dos primeiros trabalhos utilizando MNLME é o de Foody et al (1997). Nesse trabalho, os autores não utilizaram “*endmembers*” pela impossibilidade do tamanho das feições (floresta, pasto e rio) no pixel (1km) do sensor AVHRR/NOAA encontrados em um cena no Norte do estado do MT. Duas arquiteturas de rede MLP (*Perceptrons de Múltiplas Camadas*), tendo como entrada dados dos canais 1, 2 e 3 do sensor AVHRR/NOAA e três pseudo-“*endmembers*” como proporções de saída, foram testadas com resultados significativos. A “pureza” das proporções foi checada com uma imagem TM/Landsat.

Liu e Wu (2005) testaram quatro MNLME: o algoritmo ART (Adaptative Resonance Theory), a variação ART-MMAP, Arvore de regressão e a rede MLP. Nesse estudo, dados TM/Landsat, registrados com uma imagem MODIS (1km), foram classificados em floresta, grama, água e área improdutivo (solo seco/rocha exposta). Com os dados TM calcularam-se as proporções “puras” das três classes em 1km². Fez-se a modelagem utilizando dados MODIS (bandas 1 a 7) na camada de entrada e as proporções na camada de saída. A averiguação dos melhores modelos foi feita baseada nos parâmetros do modelo, complexidade computacional, exatidão e habilidade em prever a mistura. O modelo ART-MMAP teve ligeira vantagem em relação aos demais pela facilidade de implementação e exatidão de informação subpixel.

Van de Voorde et al. (2009), fizeram a checaram o desempenho entre o MLME e o MNLME para prever as proporções de solo exposto, superfície impermeabilizada e vegetação. O MNLME utilizado foi a rede MLP treinada com algoritmo de retropropagação do erro. Através de dados ETM+/Landsat-7 e, com proporção “pura” gerada com dados Ikonos, os autores calcularam o erro médio por classe, o erro absoluto médio por classe e o erro total absoluto médio concluindo a vantagem do MNLME sobre o MLME.

Dentro deste contexto, o objetivo desse trabalho foi comparar os MLME e o MNLME, aplicado com rede MLP, aplicados a dados TM/landsat-5 cujas proporções dos “*endmembers*”, em células de 30m, foram obtidas com dados do sensor RapidEye.

2. Metodologia de Trabalho

A área de estudo fica situada à direita da represa de Três Marias, no Rio São Francisco, entre os municípios de Felixlândia e Três Marias entre as coordenadas ilustradas na Figura 1.




Figura 1 – Localização da área de estudo em imagem 3B4G5R TM/Landsat-5.

As imagens utilizadas foram as do sensor TM/Landsat-5 (219/73) do dia 04 de maio de 2010 e do sensor RapidEye de 16 de abril de 2010. Para a análise a qual se propõe esse artigo e pelas características de cobertura (cerrado) e uso (reflorestamento) da região, as mudanças no uso/cobertura do solo foram desprezadas. O RapidEye é um programa Alemão, composto de cinco satélites que compõem uma constelação. Possuem sensores multiespectrais que coletam imagens com resolução espacial de 6,5m reamostrados para 5m em cinco canais: azul (0,440–0,510 μm), verde (0,520–0,590 μm), vermelho (0,630–0,685 μm), transição do vermelho/infravermelho próximo (0,690–0,730 μm) e infravermelho próximo (0,760–0,850 μm) (Campbell e Wynne, 2011).

A resolução radiométrica do sensor é de 16 bits, mas nesse trabalho a resolução foi degradada para 8bits, uma vez que as imagens frações (Mix) do MLME processadas no Spring são de 8bits.

A imagem do sensor RapidEye foi registrada (RMSE < 0,4) com 21 pontos de controle e um polinômio de 3º grau, com a cena TM que estava na projeção UTM/WGS-84. Inicialmente, executou-se o MLME implementado no aplicativo Spring 5.2 com o Modelo de Mistura Ponderado com a normalização [0-1]. Para definir os componentes “puros” (*endmembers*), fez-se uma análise visual da cena, além de uma análise do gráfico de dispersão (Figura 2). A cena da região é composta basicamente por cerrado, reflorestamento (eucalipto), água e solo, com predominância do tipo arenoso.

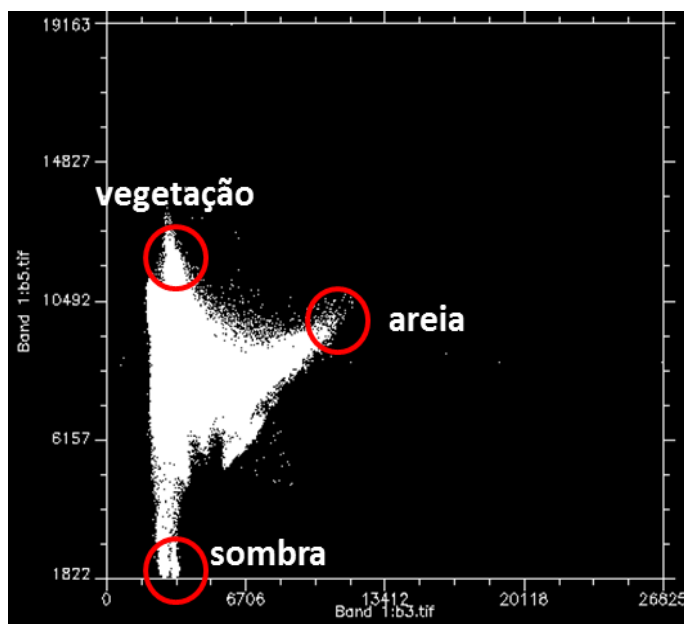


Figura 2 – Gráfico de dispersão com eixo x (banda 3 –vermelho) e eixo y (banda 4 – infravermelho próximo), ilustrando, nos extremos, os componentes puros utilizados no modelo.

Para a execução do Modelo não Linear de Mistura Espectral (MNLME), seguiu-se a metodologia semelhante à executada por Liu e Wu (2005). Fez-se a amostragem de uma área correspondente a 2% da imagem total, onde, através da programação LEGAL (Linguagem Espacial para Geoprocessamento Algébrico), gerou-se a uma matriz de 781linhas x 819 colunas (30x30m), que posteriormente foi vetorizada (Figura 3a). Executou-se a classificação supervisionada com o algoritmo de Máxima Verossimilhança da imagem RapidEye e a contagem do número de pixels “puros” classificados como Vegetação, Areia e Sombra dentro de cada célula vetorial 30x30m, a qual abrangia 36 pixels RapidEye.

Executando-se a contagem zonal para cada célula 30x30 e a proporcionalidade de cada classe em 36 pixels, montou-se os arquivos de saída da rede MLP (*Perceptrons de Múltiplas*

Camadas). Por exemplo, o pixel central da Figura 2c, seria o vetor com valores - 0,805; 0,194; 0 - para as classes areia/vegetação/solo, respectivamente. Os valores digitais do sensor TM (bandas 2, 3, 4, 5 e 7), foram escalonados linearmente entre 0 e 1, onde 1 era o valor máximo exibido no histograma de cada banda. Não utilizou-se a banda 1, pelo ruído apresentado.




Figura 3 – Matriz 30x30 (a) com posterior vetorização e sobreposta a imagem 2B3R5G RapidEye (b) e imagem classificada (c), no destaque, exibindo duas classes: vegetação, na cor verde e areia em amarelo.

Através do aplicativo SNNS (*Stuttgart Neural Network Simulator*) (Zellet al., 1988) montou-se a rede, com arquitetura 5-9-3 que foi treinada com 4500 ciclos com o algoritmo de retropropagação do erro com taxa de aprendizagem (η) de 0,1.

Devido as características do classificador Maxver e a simplicidade do vetor de saída obtido, como será discutido no capítulo Resultados e Discussões, optou-se por uma segunda metodologia de MNLME (MNLME₍₂₎); aplicou-se o modelo de MLME nos dados RapidEye (5m) com a alteração do arquivo “*Spectralbands*” uma vez que os canais do referido sensor não foram implementados no programa. Embora a saída para dados de 5m fosse normalizada, com a soma das proporções igual a 1, executou-se a média zonal em cada componente (Areia, Vegetação e Sombra) e a normalização (Equação 2), para que a soma das proporções, em 30m, também fosse igual a 1:

$$prop_A = \frac{A}{A + V + S} \quad (2)$$

Onde $prop_A$ é a proporção, em valores reais, da componente Areia; A, V e S são as medias zonais (30m) dos pixels com areia, vegetação e sombra. O raciocínio foi repetido, gerando-se um PI (plano de informação) para as proporções de vegetação ($Prop_V$) e sombra ($Prop_S$).

Após a execução dos MNLME, importou-se as matrizes para o Spring, computando-se o erro médio banda a banda. O erro para o MLME é bem conhecido na literatura dado pela Equação3:

$$erro_k = b_k - (Pr opV.X + Pr opAY + Pr opS.Z) \quad (3)$$

Onde “ $erro_k$ ” é o erro obtido para a banda k , b_k é a banda original k , Prop, são as Proporções de Vegetação, Areia e Sombra calculadas pelo modelo; X, Y e Z são os valores espectrais para as componentes puras, Vegetação, Areia e Sombra.

No entanto, uma vez que a saída de um neurônio com função logística sigmoide é dada na Equação 4:

$$F(t) = \frac{1}{1 + e^{-t}} \quad (4)$$

Onde t é a soma dos pesos (w) multiplicados pelas entradas (x) em uma rede, acrescidos do viés (Equação 5):

$$t = x_1 w_1 + x_2 w_2 + \dots + x_n w_n + vies \quad (5)$$

O erro é dado pela Equação 6:

$$erro_k = b_k - (F(t)V.X + F(t)A.Y + F(t)S.Z) \quad (6)$$

Para averiguação do melhor ajuste, computou-se o Erro Absoluto Médio Total (EAMT) para cada banda e cada modelo (Equação7), onde o melhor modelo teria o resultado próximo da banda original, ou seja, o valor do erro próximo de zero.

$$erro_k = \sum_{i=1}^N \frac{|b_k - (MixV.S_{V,k} + MixA.S_{A,k} + MixS_{S,k})|}{N} \quad (7)$$

Onde, erro é o desvio em valor absoluto; b_k é a banda original k ; MixV, MixS e MixS são as frações vegetação, areia e sombra, respectivamente, na banda k ; S é a refletância dos “*endmembers*” das respectivas frações na banda k ; N é o total de pixels da imagem.

3. Resultados e Discussão

A visualização das imagens proporção Areia/Vegetação/Sombra para o MLME e as duas metodologias de MNLME é exibida na Figura 2. Embora visual, observa-se grande diferenças nas tonalidades de cinza para cada imagem proporção em cada modelo na qual foi gerado. Não apenas os MNLME são distintos do MLME como os MNLME produziram resultados distintos entre si e, apenas a componente – Vegetação – do MNLME₍₂₎ aproximou-se da correspondente do MLME.

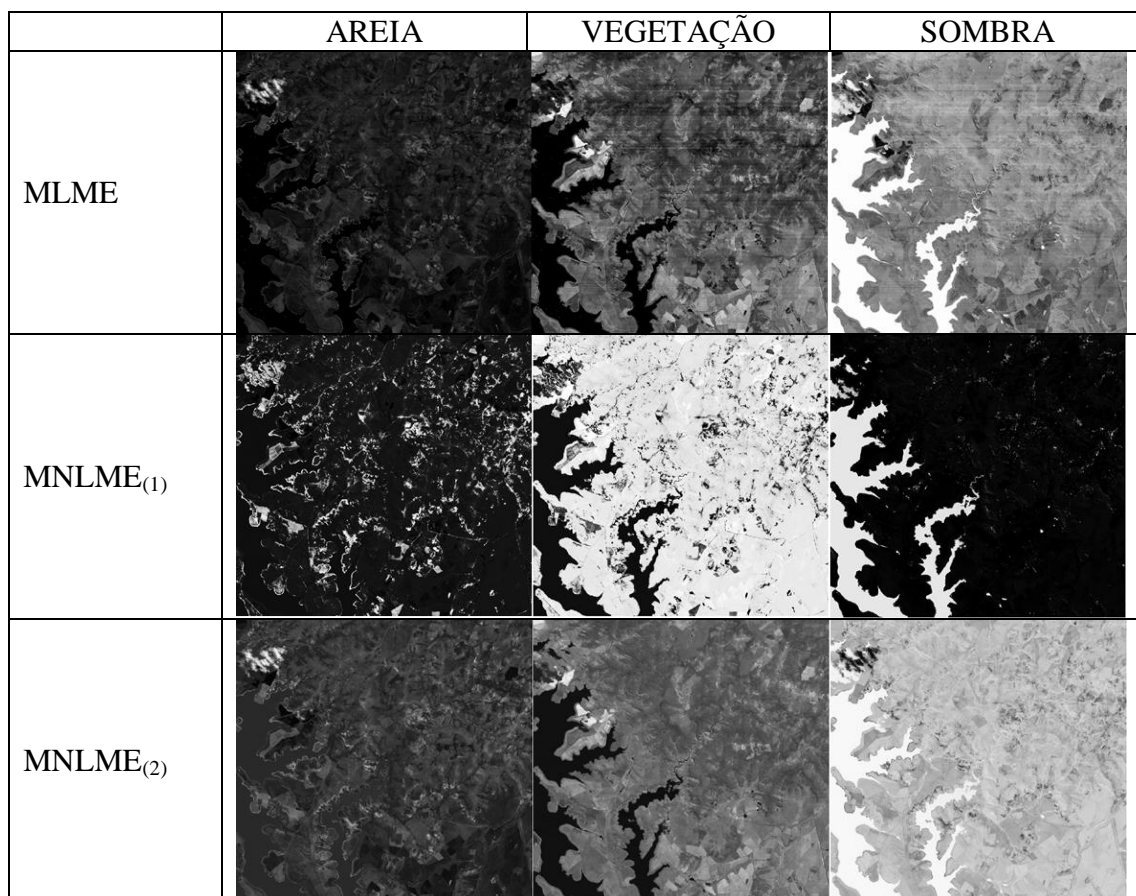


Figura 2 – Imagens proporção Areia, Vegetação e Sombra para o MLME e as duas metodologias de MNLME.

A averiguação quantitativa qual modelo teve melhor desempenho está comparativamente descrita na Tabela 1.

Análise desta tabela mostra que o MLME apresentou os menores erros, com exceção para a banda 5, cujo resultado foi muito próximo ao do MNLME₍₁₎.

Tabela 1 – Erros obtidos com o MLME e o MNLME com os vetores de saída advindos da classificação MaxVer (MNLME₍₁₎) e advindos do MLME₍₂₎.

| MODELO | BANDA | B2 | B3 | B4 | B5 | B7 |
|----------------------|-------|------|------|------|------|------|
| MLME | | 10,9 | 9,8 | 6,9 | 18,8 | 2,7 |
| MNLME ₍₁₎ | | 16,4 | 18 | 62,0 | 18,7 | 11,0 |
| MNLME ₍₂₎ | | 23,9 | 22,9 | 53,7 | 60,7 | 23 |

A utilização de duas metodologias para obtenção dos dados de saída foi decidida, pela natureza dos vetores de saída obtidos com a classificação que, rotula ou não, um pixel em determinada classe (“hard classification”). Assim, o rótulo “vegetação” advindo de 36 pixels RapiEye – cujo vetor de saída para as classes areia/vegetação/solo seria (0; 1; 0), com a aplicação do MLME na imagem RapidEye apresentou, para o mesmo pixel, após a média zonal e a aplicação da Equação 2 e similares, os valores: 0,23; 0,43; 0,34. Essa saída expressaria, teoricamente, melhor a variação espectral dos pixels de entrada e a realidade da impureza dos pixels 5m, que na classificação é admitida total pureza. Vale ressaltar que o ajuste de pesos da rede MLP para a saída com dados RapidEye com proporções advindas de

um MLME foi melhor, chegando a um bom ajuste com 200 ciclos contra 4500 ciclos para a o arquivo de saída advindo da classificação MaxVer.

Embora inferior no presente trabalho, a metodologia de MNLME só faria sentido prático de aplicação a grandes áreas não abrangidas por sensores de grande resolução espacial. Van de Voorde et al (2009) ao modelarem com uma rede MLP um MNLME em uma cena Ikonos (11x11km), poderia aplicá-lo, generalizando o MNLME em toda a cena *ThematicMapper* de 185x185km. Caso o usuário utilizasse somente a área coincidente de dois sensores com resolução espacial distinta, obviamente, utilizaria somente dados de alta resolução.

O sensor RapidEye utilizado nesse trabalho permitiu a implementação de um MNLME, no caso, uma rede MLP, e compará-lo a ao tradicional MLME. Novos modelos como o de Liu e Wu (2005) devem ser implementados em diferentes localidades. Sensores de alta resolução espacial tem quadro de imageamento menor e, conseqüentemente, resolução temporal inferior a menos que a órbita seja programada/direcionada. O programa RapidEye, por fazer imageamento em constelação – 5 sensores com 25km de faixa individual - permite um bom equilíbrio entre as resoluções espacial e temporal desejado pelo usuários.

4. Conclusões

O MLME apresentou melhor ajuste de proporções dentro de um pixel misto em relação ao MNLME executado através da rede MLP. A utilização do MLME para obter um vetor mais representativo, sem admitir pureza do pixel 5m do sensor RapidEye, não resultou em melhor ajuste do MNLME.

Agradecimentos

Os autores agradecem o apoio FAPEMIG

Referências Bibliográficas

Campbell, J.B.; Wynne, R.H. **Introduction to Remote Sensing**, 5ed, New York, Editora Guilford, 718p.

Cardozo, G. F.; Souza Jr, C. M.; Souza Filho, P. W. M. Análise de Mistura Espectral de Ambientes Úmidos Costeiros com Imagens Landsat. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 15., 2011, Curitiba. **Anais...** São José dos Campos: INPE, 2011. Artigos, p. 6472-6479. CD-ROM, On-line. ISBN 978-85-17-00056-0. Disponível em: <<http://marte.dpi.inpe.br/col/dpi.inpe.br/marte/2011/06.27.17.19/doc/p0957.pdf>>. Acesso em: 05 ago. 2012.

Foody, G.M.; Lucas, R.M.; Curran, P.J.; Honzak, M. Non-linear mixture modeling without end-members using an artificial neural network. **International Journal of Remote Sensing** v.18, n.4, p.937-953, 1997.

Liu, W.; Wu, E.Y. Comparison os non-linear mixture models: sub-pixel classification. **Remote Sensing of Environment**, v.94, n.2, p.145-154, 2005.

Nascimento, P. S. R. **Avaliação de técnicas de segmentação e classificacao por regiões em imagens Landsat-TM, visando o mapeamento de unidades de paisagem na Amazônia**. 1997. 120 p. (INPE-6391-TDI/607). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, Sao Jose dos Campos, 1997. Disponível em: <<http://urlib.net/sid.inpe.br/iris@1912/2005/07.20.08.45>>.

Quintano, C.; Fernandez-Manso, A.; Shimabukuro, Y. E.; Pereira, G. Aplicação do modelo linear de mistura espectral para o mapeamento de queimadas no Parque Nacional das Emas. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 15., 2011, Curitiba. **Anais...** São José dos Campos: INPE, 2011. Artigos, p. 7910-7917. CD-ROM, On-line. ISBN 978-85-17-00056-0. Disponível em: <<http://www.dsr.inpe.br/sbsr2011/files/p0685.pdf>>. Acesso em: 05 ago. 2012.

Tso, B; Mather, P. M. **Classification Methods for Remotely Sensed Data**. New York : Taylor and Francis, 2001. 332 p.

Van de Voorde, T; Roeck, T; Canters, F. A comparison of two spectral mixture modeling approaches for impervious surface mapping in urban areas. **International Journal of Remote Sensing**.v.30, n.18, p. 4785-4806, 2009.

Zell, A.; Mamier, G.; Mache, M.V.N.; Hübner, R.; Dörin, S.; Hermann, K-U; Soye, T.; Schmalzl, M.; Sommer, T.; Hatzigeorgiou, A.; Posselt, D.; Schreiner, T.; Kett, B.; Clemente, G.; Wieland, J.; Gatter, J. **SNNS – Stuttgart Neural Network Simulator** v.4.2, User Manual, University of Stuttgart/ University of Tübingen, 338p. 1998.