

AVALIAÇÃO DO USO DO MODELO LINEAR DE MISTURA ESPECTRAL NA CLASSIFICAÇÃO DE IMAGEM ALOS.

KELISON JUBINI MACHADO¹
EDNEYA GOMES DA SILVA SOARES¹
LEANDRO TEIXEIRA DE CARVALHO¹
MÁRCIO PUPIN DE MELLO²
CARLOS ANTÔNIO OLIVEIRA VIEIRA¹

¹Universidade Federal de Viçosa - UFV
Departamento de Engenharia Civil – DEC
Setor de Engenharia de Agrimensura, Viçosa - MG
{edneyagomes, kelisonufv, carvalhoufv}@yahoo.com.br
calos.vieira@ufv.br

²Instituto Nacional de Pesquisas Espaciais – INPE
Coordenação Geral de Observação da Terra – OBT
Divisão de Sensoriamento Remoto, São José dos Campos - SP
pupin@dsr.inpe.br

RESUMO - Técnicas de Sensoriamento Remoto como a classificação de imagens de satélite tem se mostrado de fundamental importância no auxílio à tomada de decisões. Uma das limitações apresentadas na classificação é a estimativa incorreta para algumas classes temáticas. A presença de *pixels* de mistura na imagem está dentro da problemática dessa abordagem. Uma maneira de minimizar esse problema seria uma modelagem que discriminasse proporções de cada componente presente na mistura espectral de cada *pixel*. Essa modelagem é aplicada através de uma técnica conhecida como Modelo Linear de Mistura Espectral (MLME). Este trabalho tem como principal objetivo avaliar a viabilidade do uso do MLME integrado com procedimentos de classificação supervisionada para a identificação de áreas de matas. Foi utilizada uma imagem AVNIR2-ALOS, da região de Anápolis-GO. Os algoritmos de classificação supervisionada utilizados foram o de Máxima Verossimilhança (MV) e de Rede Neural Artificial (RNA). Os resultados indicaram não haver melhorias estatisticamente significativas nas classificações quando da integração com o uso do MLME para o MV. Na classificação por RNA o uso do MLME prejudicou a discriminação da classe de interesse. O fato corrobora com a premissa de que quanto maior a resolução espacial do sensor, menor a influência da mistura espectral.

ABSTRACT - Remote Sensing techniques such as classification of satellite imagery, has proven extremely important by helping the decision-making. One of the limitations outlined in classification is the wrong estimate for some thematic classes. The presence of mixing pixels in the image is one problem of this approach. One way to minimize this problem would be using a model that discriminate proportions of each component in this mixture spectrum at each pixel. This model is applied using a technique known as Linear Spectral Mixing Models (MLME). This work aims evaluating the feasibility of using MLME integrated with supervised classification procedures for the identification of forests areas. It was used an AVNIR2-ALOS image, corresponding region of Anápolis-GO (Brazil). The algorithms used for supervised classification were Maximum Likelihood (MV) and Artificial Neural Network (RNA). The results indicates no statistically significant improvements in the classifications when the MLME integration with MV. In the RNA classification, using MLME in the discrimination of interesting class wasn't good. This fact confirms the premise that the higher spatial resolution of the sensor turn down the influence of the mixture spectrum.

1 INTRODUÇÃO

Um estudo apresentado pela Organização das Nações Unidas para a Agricultura e Alimentação (FAO) revela que o Brasil é um dos países da América do Sul

que apresentaram a maior perda real de área de florestas nativas, nos últimos anos. O país registrou um aumento no índice de desmatamento de 0,5% (período de 1990 a 2000) para 0,6% (período de 2000 a 2005), ou seja, no

segundo período o Brasil perdeu mais de três milhões de hectares de florestas (FAO, 2007).

As técnicas de Sensoriamento Remoto (SR) e Sistemas de Informações Geográficas (SIGs) têm sido utilizadas de forma conjugada em estudos de recursos terrestres, com especial atenção para o monitoramento das atividades antrópicas e seus impactos ambientais (Pinto e Lombardo, 2003).

Uma destas técnicas é a classificação de imagens de satélite, que tem se mostrado de fundamental importância no auxílio à tomada de decisões de processos como o acompanhamento de recursos naturais e o mapeamento do uso do solo.

Segundo Crósta (1992) a classificação automática de imagens multiespectrais de sensoriamento remoto diz respeito a associar cada pixel da imagem a um “rótulo” descrevendo um objeto real ou classes informacionais (vegetação, solo, etc). A classificação pode ser dividida em supervisionada e não-supervisionada. A primeira é utilizada quando o analista dispõe de informações que permitem a identificação das classes de interesse na imagem, permitindo um “treinamento” do classificador. Já na não-supervisionada, o analista utiliza algoritmos computacionais para reconhecer as classes presentes na imagem e, posteriormente, atribui os rótulos a cada uma das classes previamente identificadas pelo algoritmo.

Classificadores tradicionais, baseados em informações estatísticas a respeito dos dados a serem classificados, são os que habitualmente encontram-se disponíveis na maioria dos softwares utilizados em processos de extração de informações de imagens de satélite por classificação automática.

Os resultados apresentados pelo algoritmo da Máxima Verossimilhança (MV) é tanto melhor quanto maior e representativo o número de pixels numa amostra de treinamento para implementá-los na matriz de covariância (Previdelli, 2004).

O classificador por Redes Neurais Artificiais (RNAs) apresenta algumas vantagens em relação aos classificadores baseados em conceitos estatísticos paramétricos, principalmente por não assumirem nenhuma distribuição estatística das classes informacionais.

Nelson e Illingworth (1990) definem as RNAs como sendo técnicas inovadoras de processamento de informações, que têm como objetivo básico, simular, em computadores, o funcionamento do sistema nervoso biológico.

Para Fausett (1994) as RNAs são sistemas de processamento de informações que possuem características de funcionamento similares às das redes neurais biológicas; mais especificamente, generalizações de modelos matemáticos da biologia neural.

Uma das limitações na classificação, que contribui para resultados não satisfatórios, ocorre quando há estimativa incorreta para algumas classes temáticas. São diversos os fatores que contribuem para esses erros de classificação. Dentre eles podemos citar a existência de *pixels* de mistura (Aguiar *et al.*, 1999).

Contudo esta é uma situação complexa em imagens com alvos de características espectrais semelhantes, pelo fato de muitas vezes, o valor do *pixel* não representar o valor de apenas um alvo e sim a interação destes. Essa relação cresce de maneira inversamente proporcional à resolução espacial do sensor, ou seja, quanto mais grosseira a resolução maior a mistura espectral dos componentes presentes (Haertel e Shimabukuro, 2005).

Uma maneira consistente de tentar contornar o problema da mistura espectral seria aplicar um Modelo Linear de Mistura Espectral (MLME). Trata-se de uma modelagem, através da técnica de Mínimos Quadrados Restrito, para estimar a proporção de cada alvo dentro de cada *pixel* da imagem. Este modelo assume que a resposta espectral de um *pixel* pode ser modelada por uma combinação linear das respostas espectrais dos membros de referência, algumas vezes chamados de *endmembers*. (Shimabukuro e Smith, 1991).

(Mello *et al.*, 2008) obtiveram um aumento considerável na exatidão da classificação usando as frações resultantes do MLME como vetor de atributos na entrada da classificação supervisionada por Máxima Verossimilhança quando comparadas as técnicas convencionais de classificação apresentadas em (Silva *et al.*, 2008)

Este trabalho tem como principal objetivo avaliar a viabilidade do uso do MLME integrado com procedimentos de classificação supervisionada pela Máxima Verossimilhança e Rede Neural Artificial para a identificação de áreas de matas utilizando uma imagem do sensor AVNIR2, a bordo da plataforma orbital ALOS.

2. FUNDAMENTOS DA METODOLOGIA

2.1 Procedimentos do classificador de Máxima Verossimilhança

O método de classificação MV considera a ponderação das distâncias entre médias dos níveis digitais das classes e o pixel, utilizando parâmetros estatísticos, isto é, considerando a distribuição de probabilidade normal para cada classe (Crósta, 2002).

Considera que um vetor de observação x_i pertence à classe κ_i se a probabilidade que associa este pixel à classe κ_i for maior do que a probabilidade que associa o pixel a qualquer outra classe, equação 1.

$$x_i \in \kappa_i, \text{ se } P(\kappa_i | x_i) > P(\kappa_j | x_i) \text{ para todo } \kappa_i \neq \kappa_j \quad (1)$$

O cálculo da probabilidade é executado pela equação 2:

$$P(\kappa_i | x_i) = P(x_i | \kappa_i) P(\kappa_i) / P(x_i) \quad (2)$$

onde:

$P(\kappa_i)$ – Probabilidade da classe κ_i ocorrer na imagem

$P(x_i | \kappa_i)$ – Probabilidade de um pixel da classe x_i

pertencer à classe κ_i

$P(x_i)$ – Probabilidade de um pixel x_i ocorrer na imagem

O valor de $P(x_i | \kappa_i)$ é geralmente obtido assumindo-se a distribuição normal para as classes. Por isso, as

estimativas da média e da matriz variância-covariância são fundamentais.

Os conjuntos de treinamento definem o diagrama de dispersão das classes e suas distribuições de probabilidade, considerando a distribuição normal para cada classe. Estas distribuições representam a probabilidade de um pixel pertencer a uma ou outra classe, dependendo de sua posição em relação a esta distribuição. Existem situações em que duas classes, quando representadas em um diagrama, apresentam uma sobreposição de suas curvas, indicando que determinados pixels têm igual probabilidade de pertencer às duas classes. Nesta situação, estabelece-se um critério de decisão, a partir da definição de limiares. Para diminuir este conflito entre classes, deve-se proceder à aquisição de amostras significativas durante o processo de treinamento.

2.2 Procedimentos do classificador de RNA

Uma Rede Neural consiste de um determinado número de elementos de processamento chamados neurônios, armazenados em camadas, aos quais são associados pesos. O cálculo dos valores para os pesos é chamado treinamento, ou aprendizagem, da rede. O treinamento pode ser supervisionado, quando cada vetor do conjunto de entradas é associado a uma resposta e o objetivo é determinar a resposta correta para todos os vetores de entrada, ou não supervisionado, quando apenas o conjunto de entrada é fornecido e devem-se extrair propriedades de acordo com determinadas representações internas. Os neurônios são conectados entre si mediante padrões que definem a arquitetura, ou topologia, da rede. Cada neurônio possui um estado, chamado ativação, que é uma função das entradas que ele recebe. Esta ativação é responsável pelo envio de um sinal para outros neurônios e pode ser binária ou contínua, dependendo da função de ativação utilizada.

O algoritmo de aprendizado é conhecido como um algoritmo que tem a capacidade de recalculando os pesos realizando uma nova redistribuição. A camada de contribuição recebe os sinais do conjunto de medidas, e estes sinais são enviados aos neurônios da camada oculta. Cada neurônio da camada oculta calcula sua ativação e envia o sinal obtido para o neurônio da camada de saída. O neurônio da camada de saída, por sua vez, calcula o seu sinal de ativação e o transforma em uma resposta para o padrão fornecido, que é comparada com a resposta já conhecida a fim de determinar o erro associado. Com base neste erro efetua-se uma atualização dos pesos. O processo é repetido para todos os padrões fornecidos, razão pela qual são também denominados padrões de treinamento. Os pesos são atualizados de acordo com a taxa de aprendizagem. Este procedimento é concluído quando a restrição é atendida. A arquitetura do algoritmo das RNA está exemplificada conforme Figura 1.




Figura 1 – MLP Multi Layer Perceptron Classifier (IDRISI ANDES - Adaptado).

O número de neurônios na camada de contribuição ou entrada é definido pelo número de variáveis discriminantes no processo de classificação. Enquanto que o número de neurônios na camada de saída é definido pelo número de classes informacionais a ser mapeada. E o número de camadas ocultas e de neurônio por camada ocultas é definido através de tentativa e erro (Vieira, 2000).

2.3 Características do Modelo Linear de Mistura Espectral

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* ou de classes membros de referência (Roberts *et al.*, 1998).

Shimabukuro e Smith (1991) indica os componentes vegetação, solo e sombra como constituintes básicos de cenas florestadas, e descreve o modelo de mistura espectral, em cada pixel da cena, pela seguinte equação:

$$r_i = \sum_{j=1}^n (a_{ij} \cdot x_j) + e_i \quad (3)$$

Em que: r é a resposta espectral do pixel na i -ésima banda; a_{ij} é a resposta espectral do j -ésimo *endmember* na i -ésima banda; x_j é o valor de proporção a ser estimado do j -ésimo componente; e e_i é o erro associado na i -ésima banda.

O Método dos Mínimos Quadrados (MMQ), na forma restrita, é usado para resolver o modelo. As restrições aplicadas são: a) a soma de todos os componentes estimados corresponde à unidade; e b) todas as componentes estimadas devem ser maiores ou iguais a zero.

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 precisa, na escala de *subpixel* (Schowengerdt, 1997; Schweik e Green, 1999).

2.4 Características do Satélite ALOS

O satélite ALOS (do inglês: *Advanced Land Observing Satellite*) foi lançado pela agência de Exploração Aeroespacial Japonesa em janeiro de 2006, com distribuição dos dados para o Brasil em outubro de 2007.

O ALOS possui três instrumentos imageadores de Sensoriamento Remoto. São eles: o PRISM, o PALSAR e o AVNIR-2, cuja imagem é usada neste trabalho.

O AVNIR-2 (*Advanced Visible and Near Infrared Radiometer - Type 2*) possui resoluções: radiométrica de 8 bits; temporal de 46 dias (período de revisita); espacial de 10 m, com uma faixa de imageamento de 70 Km; e espectral com quatro bandas localizadas nos comprimentos de onda da faixa do azul (B), verde (G), vermelho (R) e infra-vermelho próximo (NIR) com intervalos de 8 e 13 nanômetros para as três bandas do visível e para a banda do infra-vermelho próximo, respectivamente (JAXA, 2008).

3 MATERIAIS E MÉTODOS

3.1 Área de estudo

A área de estudo, como apresenta a *Figura 2*, localiza-se no Estado de Goiás, município de Anápolis, que limita-se geograficamente ao norte com as cidades de Pirenópolis e Abadiânia, a leste com Silvânia, sul com Leopoldo de Bulhões e a oeste com Nerópolis e Ouro Verde de Goiás. É o terceiro maior município do Estado em população e compõe a região mais desenvolvida do centro-oeste, o eixo (Goiânia-Anápolis-Brasília), de clima tropical de altitude, com duas estações bem definidas uma seca que vai de maio a setembro e outra chuvosa de outubro a abril (Anápolis, 2008)

Concentra-se em uma área de tensão ecológica, onde o cerrado é predominante. Apresenta dois tipos básicos de cobertura: o cerrado propriamente dito e o campo cerrado. Uma das preocupações atuais nesta região é a descaracterização da cobertura vegetal do município pela ação do homem que há décadas, vem substituindo as matas por cultura de cereais, como arroz, o milho, o plantio de café e a formação de pastagens para alimentação do rebanho bovino (Anápolis, 2008).

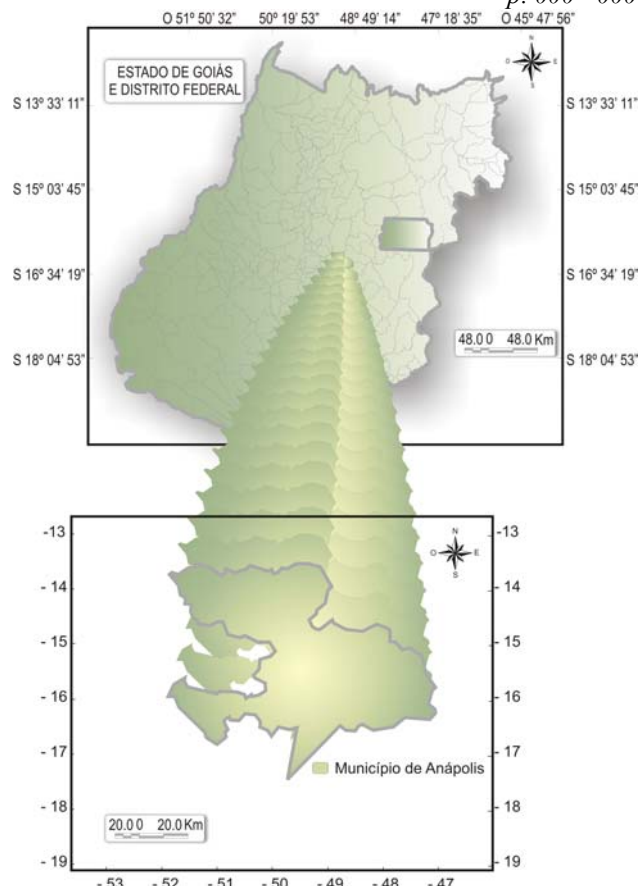


Figura 2 – Localização da área de Anápolis

3.2 Softwares utilizados

O software Idrisi Andes foi utilizado para a classificação (MV e RNA), o SPRING 4.3 para a obtenção das imagens fração (MLME), o software ArcGIS 9.2 para a posterior edição e apresentação das imagens geradas, além do programa Kappa.exe (VIEIRA, 2000), para o cálculo do índice *Kappa* e do teste estatístico Z.

3.3 Dados

Tem-se como dado de entrada para a realização deste trabalho a imagem do sensor AVNIR-2 a bordo do satélite ALOS (*Figura 3*), adquirida em dezembro de 2007, a partir desta imagem foi obtida a imagem referência através de interpretação visual como mostra a *Figura 4*.




Figura 3 – Imagem da área de estudo.




Figura 4 – Imagem de referência da área de estudo.

3.4 Classificação Supervisionada

O processo de classificação envolvendo os métodos MV e RNA utilizou a imagem referência para representar as assinaturas espectrais.

No MV, uma vez determinadas as classes, foram geradas as assinaturas espectrais para a devida classificação. Em relação a RNA, o treinamento foi composto inicialmente pelas bandas da imagem ALOS com a entrada da imagem de referência, sendo utilizando duas camadas de neurônios, a primeira com 15 neurônios e a segunda com 10, após este processo executou-se a classificação propriamente dita.

Na aplicação do MLME utilizou-se de três componentes: vegetação, solo e sombra, gerando, ao final do procedimento, três componentes fração que representam as proporções de cada um desses elementos dentro de cada *pixel* da cena. Após este processo estas frações foram utilizadas como vetor de atributos de entrada para a criação das assinaturas espectrais a serem

consideradas nos processos de classificação pelos métodos de MV e RNA. Assim as classificações MV e RNA foram feitas de duas formas: utilizando as bandas da imagem como vetor de atributos (forma convencional) e utilizando as frações resultantes do MLME como vetor de atributos.

A avaliação da classificação foi realizada através da geração da matriz de confusão de onde podem ser derivados os valores do índice *Kappa* e variância do *Kappa*, necessários para a realização do teste estatístico Z, detalhado em Vieira (2000).

Visando avaliar os aspectos qualitativos e a distribuição espacial dos erros de classificação foram geradas imagens binárias de erros. Essas imagens são obtidas pela comparação do cruzamento direto entre a imagem de referência e as imagens produzidas a partir de classificação (Gonçalves *et. al.*, 2007). Para estas imagens de erro, cada pixel pode assumir dois valores que representam o erro, seja, atribuindo 0 para (corretamente rotulados) ou 1 para (incorretamente rotulados). Foram geradas quatro imagens com erro binários, uma para cada método de classificação. Com isso, gera-se uma imagem que apresenta o número de ocorrência do erro classificados pixels, uma vez que nesta nova imagem, o comportamento destes pixels pode ser vistas em termos de frequência de ocorrência.

3.5 Avaliação da classificação

A partir da aplicação dos classificadores, pode ser gerada a matriz confusão ou matriz de erro, com o propósito de avaliar as classificações obtidas através do cálculo do índice *Kappa*.

O teste estatístico Z tem como finalidade verificar se os resultados dos classificadores são estaticamente diferentes ou iguais. Se o valor de Z calculado for maior que o tabelado, conclui-se que os métodos empregados na classificação foram estaticamente diferentes.

O cálculo pode ser acompanhado pela equação 4:

$$Z_{calc} = \frac{|K_{a2} - K_{a1}|}{\sqrt{V_{a1} + V_{a2}}} \quad (4)$$

onde:

K_{an} – Valor do Índice *Kappa*

V_{an} – Valor da Variância

5 RESULTADOS

Uma matriz de erro ideal deve apresentar os valores da diagonal principal próximos a 100%, indicando que não houve confusão entre as classes.

As imagens fração geradas segundo Shimabukuro e Smith (1991) descrevem a vegetação, solo e sombra de forma independente, representando uma variação destes elementos na imagem, esta variação é representada na forma gradual de 0 a 1, onde o valor um indica que todo o pixel contem a fração desejada, como vista na figura 5.

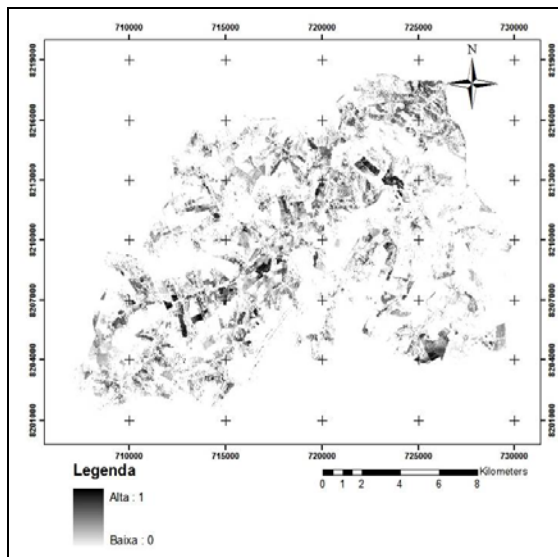


Figura 5 – Fração encontrada para o tema vegetação.

Após o processo de classificação, empregando os métodos MV e RNAs com e sem a utilização das frações, obteve-se quatro novas imagens.

Para uma análise qualitativa das imagens classificadas pelos métodos empregados, foi realizado um cruzamento dos resultados com a imagem de referência. Assim, foi gerada uma imagem com toda a possibilidade de combinação das classes presentes em ambas as imagens. A partir desse cruzamento é que foi possível obter a imagens de erro binário, que descreveu os comportamentos espaciais e posicionais na localização dos pixels errôneos (incorretamente rotulados). Duas destas imagens (Figura 6) são apresentadas a fim de permitir uma melhor comparação.




Figura 6: Ilustração de duas imagens de erros binário decorrentes do processo de classificação tradicional: (a) MV e (b) RNA.

A partir dos métodos analisados pode-se gerar uma imagem que mostra a frequência em porcentagem de erro causado pelos pixels classificados de forma errada. Combinando as imagens de erro binárias, pode-se verificar que os pixels rotulados com 25% implica em uma ocorrência na imagem, com 50%, tem duas ocorrências, com 75%, três ocorrências e com 100%, indica que os pixels foi erradamente classificadas para todos os métodos, como visto na figura 7.




Figura 7 – Imagem ilustrando as frequências de pixels errados em porcentagem.

Contudo, geradas as matrizes de erros para cada método empregado no processo, de onde se pode derivar o índice *Kappa* e variância para cada tipo de classificação, sendo eles (MV_IMG e RNA_IMG pelo método tradicional e MV_FRA e RNA_FRA método utilizando as frações) é que se passou a analisar as classificações. Estes resultados foram avaliados e interpretados segundo um teste Z, sendo visualizados na matriz de significância da tabela 1.

Tabela 1 – Matriz de significância para a classificação pelos métodos máxima verossimilhança e Redes Neurais.

	MV_IMG	MV_FRA	RNA_IMG	RNA_FRA
<i>Kappa</i>	0.6509	0.6641	0.6741	0.6304
VAR	0.0000360	0.0000366	0.0000351	0.0000360
MAXVER	108.363			
MAXFRA	1.548	109.727		
RNA	2.749	1.181	113.749	
RNAFRA	2.414	3.954	5.181	105.023

Os valores da diagonal significam as avaliações dos métodos individualmente, fora da diagonal em vermelho os valores correspondentes a avaliação comparativa entre os métodos segundo o teste z.

Com isso, o teste Z realizado a um nível de significância de 95% e grau de liberdade assumindo como infinito, os valores em vermelhos maiores ou iguais a 1,96

(valor tabelado) implicam diferença significativa entre os classificadores. Logo, pode-se perceber que nem todas as classificações foram consideradas estatisticamente diferentes.

Dentre os métodos utilizados para a classificação, o que apresentou melhor resultado foi o procedimento empregando RNA_IMG pelo método tradicional, seguido do MV_FRA, de acordo com os índices *Kappa* apresentados na tabela 1.

Como resultados finais da classificação foram gerados os mapas como apresentados nas Figuras 8, 9, 10 e 11.

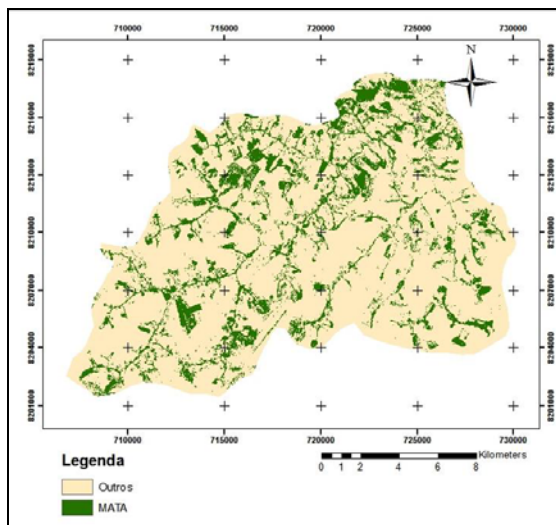


Figura 8 – Mapa classificado pelo método MV.

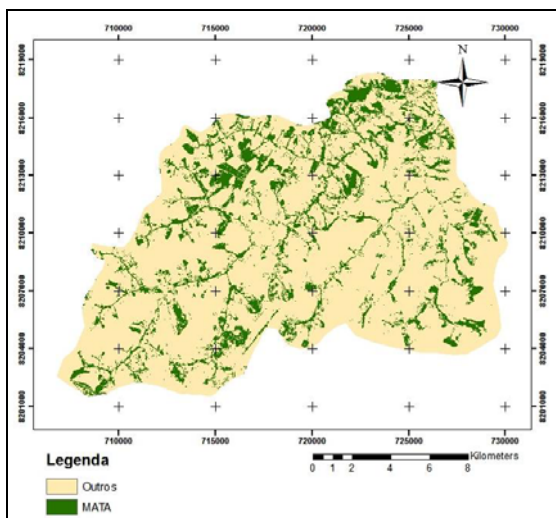


Figura 9 – Mapa classificado pelo método MAXFRA.

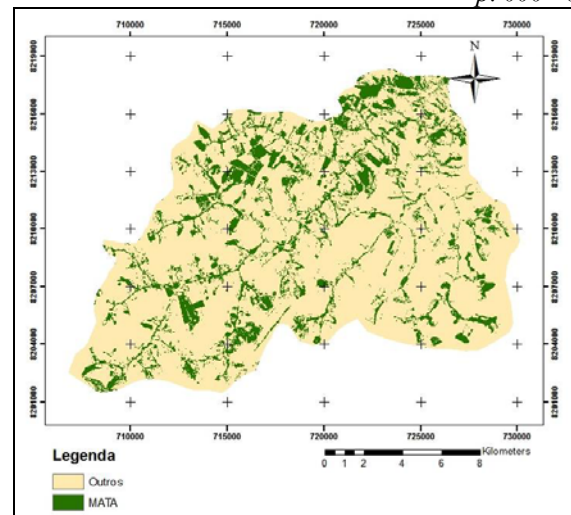


Figura 10 – Mapa classificado pelo método RNA.

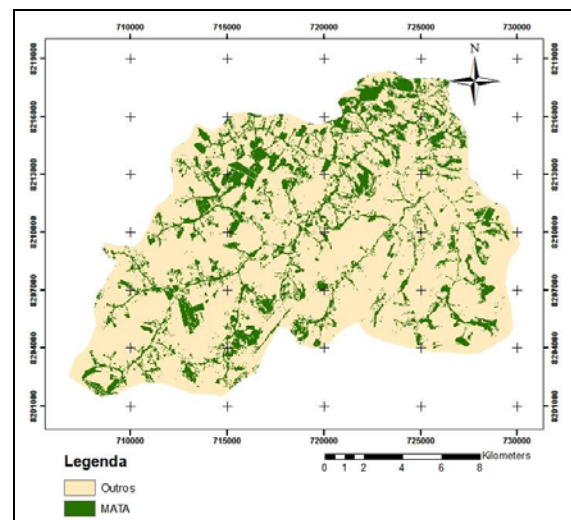


Figura 11 – Mapa classificado pelo método RNAFRA.

6 CONCLUSÃO

A partir das análises pode-se concluir que o método do modelo mistura não houve melhora significativa da classificação comparada ao uso do processo tradicional, visto que, a imagem ALOS possui alta resolução espacial, tendo assim menor efeito de pixel de mistura.

Mas de forma geral não podemos descartar o uso do modelo de mistura espectral visto que este modelo foi utilizado neste trabalho para identificação apenas de matas

Através do teste estatístico Z pode se verificar a confiabilidade dos resultados apresentados pelos classificadores utilizados, sendo que os melhores foram o RNA_IMG e o MV_FRA, de forma que estatisticamente não ocorreu uma melhora significativa ao usar as frações.

Destacando que no caso do método RNA empregando frações a classificação piorou, uma vez que

quando foram usadas as frações ao invés das imagens para estar realizando a classificação, se reduziu a dimensão da camada de entrada de 4 para 3, ocasionando essa diferença do RNA para o MV.

REFERÊNCIAS

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.

ANÁPOLIS. In: Wikipédia: a enciclopédia livre. Disponível em: <<http://pt.wikipedia.org/wiki/An%C3%A1polis>> Acesso em: 21 junho 2008.

CRÓSTA, A.P. **Processamento digital de Imagens de Sensoriamento Remoto**. Campinas; São Paulo: IG/UNICAMP, 2002,170 p.

EMBRAPA – Monitoramento por Satélite. **Satélites de Monitoramento**. Disponível em: <<http://www.sat.cnpem.embrapa.br/satelite/cbers.html>> Acesso: 28 junho 2008.

ENGESAT. **Aspectos Gerais do Alos**. Disponível em: <<http://www.engesat.com.br/?system=news&action=read&id=541>> Acesso: 28 junho 2008.

FAUSETT, Laurene V. **Fundamentals of Neural Networks - Architectures, Algorithms, and Applications**. Prentice Hall International Editions. USA, New Jersey, 1994.

FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS (FAO): **Brasil é responsável por 74% do desmatamento sul-americano, aponta FAO** – Agência Brasil EBC – Empresa Brasil de Comunicação. Disponível em <<http://www.agenciabrasil.gov.br/noticias/2007/03/13/materia.2007-03-13.6141450425/view>>. Acesso: 25 junho 2008.

GONÇALVES, R. P.; ASSIS, L. C.; VIEIRA, C. O. O.. *Comparison Of Sampling Methods To Classification Of Remotely Sensed Images*. In: IV Simpósio Internacional de Agricultura de Precisão. Viçosa, 2007. CD-ROM.

HAERTEL, V. F.; SHIMABUKURO, Y. E. Spectral linear mixing model in low spatial resolution image data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 43, n. 11, p. 2555-2562, 2005.

IBGE. **Imagens do Satélite Alos**. Disponível em: <<http://www.ibge.gov.br/alos/>> Acesso: 28 junho 2008.

INPE. **Satélite Sino-Brasileiro de Recursos Terrestres**. Disponível em: <<http://www.cbers.inpe.br/?content=aplicacoes>> Acesso: 28 junho 2008.

JAXA. **ALOS: Advanced Land Observing Satellite**. Disponível em: <<http://www.eorc.jaxa.jp/ALOS/index.htm>>. Acesso em: 10 jun. 2008

MELLO, M. P.; SILVA, G. B. S.; PEREIRA, G.; PRADO, B. R.; SHIMABUKURO, Y. E.; RUDORFF, B. F. T.; VIEIRA, C. A. O.; PETERNELLI, L. A. Avaliação do uso do modelo linear de mistura espectral na discriminação de fitofisionomias do Cerrado. In: Simpósio Nacional do Cerrado - Simpósio Internacional de Savanas Tropicais, 9-2., 2008, Brasília, DF. **Anais...** Planaltina, DF: EMBRAPA-CERRADOS, 2008 (Aceito para publicação).

NELSON, Marilyn M. & ILLINGWORTH, W. T. **A Practical Guide to Neural Nets**. Addison-Wesley Publishing Company, Inc. USA, 1991.

PINTO, S. dos A. F.; LOMBARDO, M.A. **O Uso do Sensoriamento Remoto e Sistemas de Informações Geográficas no Mapeamento e Uso da Terra e Erosão do Solo**. In: Congresso Brasileiro De Cartografia, 12., 2003, Belo Horizonte. Anais.

PREVIDELLI, I.T.S. Estimadores de máxima verossimilhança corrigidos para modelos superdispersados não-lineares. São Carlos: UFSC. **Tese de Doutorado em Economia**. 2004

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.

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.

SILVA, G. B. S.; BETIOL, G. M.; SANO, E. E. Análise comparativa de quatro métodos de classificação supervisionada para a discriminação de fitofisionomias de Cerrado. **Geografia, Ensino & Pesquisa**, v. 12, n. 1, p. 3935-3947, 2008. Disponível em: <<http://bibdigital.sid.inpe.br/rep-/sid.inpe.br/mtc-m17@80/2008/05.27.22.12>>. Acesso em: 05 jun. 2008.

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, p. 16-20, 1991.

VIEIRA, C. A. O. **Accuracy of remotely sensing classification of agricultural crops: a comparative study. Thesis (Ph.D.)** - University of Nottingham, Nottingham. 2000. 323 p.