

COMPARAÇÃO ENTRE IMAGENS ASTER E LANDSAT 7 NA CLASSIFICAÇÃO DE NÍVEIS DE DEGRADAÇÃO DE PASTAGENS UTILIZANDO REDES NEURAIAS ARTIFICIAIS

Comparison between Aster and Landsat 7 images in the classification of pasture degradation levels using artificial neural networks

César da Silva Chagas¹
Carlos Antônio Oliveira Vieira²
Elpídio Inácio Fernandes Filho³
Waldir de Carvalho Júnior¹

¹ Embrapa Solos

Rua Jardim Botânico 1024, Jardim Botânico,
CEP 22460-000, Rio Janeiro, RJ.
e-mail: chagas.rj@gmail.com, waldircj@cnpes.embrapa.br

² Universidade Federal de Viçosa - UFV

Departamento de Engenharia Civil
CEP 36570000, Viçosa, MG.
e-mail: carlos.vieira@ufv.br

³ Universidade Federal de Viçosa - UFV

Departamento de Solos
CEP 36570000, Viçosa, MG.
e-mail: elpidio@ufv.br

RESUMO

O presente estudo teve como objetivo comparar a eficiência dos dados dos sensores Aster e ETM⁺/Landsat 7 na classificação do uso e cobertura da terra, com ênfase nos níveis de degradação das pastagens na Zona da Mata Mineira, através da utilização de redes neurais artificiais. Foram testadas três composições de uma imagem do sensor Aster e uma do ETM⁺/Landsat 7, para definição das melhores feições discriminantes para o classificador. As classes de uso e cobertura consideradas foram: floresta, café, área urbana/solo exposto e três níveis de degradação das pastagens (moderado, forte e muito forte). Utilizou-se o simulador de redes neurais “Java Neural Network Simulator” e o algoritmo empregado foi o back-propagation. Dentre as composições de imagens testadas o melhor resultado foi alcançado com a utilização das 9 bandas do Aster (30m) como variáveis discriminantes, que também permitiu uma melhor discriminação dos níveis de degradação das pastagens considerados. Este resultado é atribuído à melhor resolução espectral desta composição de imagem quando comparada às demais. Dentre as classes consideradas, a pastagem no nível de degradação muito forte foi a que apresentou o maior erro de classificação, em todas as composições, sendo bastante confundida com a pastagem no nível de degradação forte.

Palavras chaves: sensoriamento remoto, redes neurais, pastagens.

ABSTRACT

The present study has the objective of compare the efficiency of the Aster and ETM⁺/Landsat 7 sensor data for land use and land cover classification, with emphasis in pastures degradation levels from a study area at the Zona da Mata Mineira, through the use of artificial neural networks. Three compositions of an Aster image were tested and one of ETM⁺/Landsat 7 sensor, in order to defining the best set of discriminating features to be used into the classification process. The informational classes considered were: forest, coffee, urban area/bare soil and three levels of degradation

of the pastures (moderate, strong and very strong). The "Java Neural Network Simulator" was used to model the artificial neural networks and the learning algorithm employed was the back-propagation. The best results were obtained using a composition of 9 bands of Aster sensor (spatial resolution of 30m), among all the tested composition images as discriminating variables, which also allowed a better discrimination of the pastures degradation levels considered. This result is attributed the best spectral resolution of this composition of image when compared to the other ones. Among the considered classes, the pasture degradation in the level of very strong was the one that presented for all images the highest classification error levels. This class was quite confused with the one of pasture degradation in the level of strong.

Keywords: remote sensing, neural networks, pastures.

1. INTRODUÇÃO

Na Zona da Mata Mineira verifica-se um grande predomínio da utilização das terras com pastagens de capim gordura (*Melinis minutiflora*, Beauv.). Durante muito tempo esta gramínea exerceu um importante papel na proteção dos solos contra a erosão, sendo considerada uma planta tolerante à baixa fertilidade e à moderada deficiência hídrica. No entanto, é muito sensível ao pisoteio excessivo, a cortes freqüentes e ao fogo, podendo desaparecer quando estes são freqüentes (Quinteiro, 1997).

Segundo Sano *et al.* (2000), a recuperação de pastagens degradadas é de difícil implementação devido à falta de informações atualizadas e detalhadas a respeito de sua distribuição espacial. O sensoriamento remoto, em virtude do seu baixo custo, repetitividade e escala compatível, pode contribuir, em muito, para subsidiar políticas de recuperação de pastagens degradadas em diferentes regiões.

Neste sentido, Moreira & Assad (2000) adotaram técnicas de segmentação e classificação supervisionada em imagens do TM/Landsat 5 para identificação de áreas de pastagem com diferentes níveis de degradação, cujos resultados mostraram que a sua utilização foi eficiente para a separação da área em classes de uso da terra, bem como na identificação de cinco níveis de degradação das pastagens.

Sano *et al.* (2000) utilizaram imagens do RADARSAT e do TM/Landsat 5 na identificação dos principais tipos de pastagens cultivadas na região do Cerrado do Distrito Federal. Os resultados da análise dos dados de radiometria, em associação com a análise da imagem TM/Landsat 5, permitiram a separação dos grandes grupos por gênero, principalmente nas bandas TM3 e TM4.

Seyler *et al.* (2002) analisaram o comportamento espectral de classes de pastagens, em Piracicaba, a partir de dois métodos de classificação de imagens TM/Landsat 5, visando à distinção dos principais tipos de pastagens de outras classes de vegetação. Os autores concluíram que os métodos de classificação empregados (não supervisionada e partição paralelepédica), permitiram uma boa avaliação da proporção de pastagens com erro inferior a 10%.

Nascimento *et al.* (2006) utilizaram imagens do sensor Aster na identificação de níveis de degradação em pastagens, na região de Viçosa, MG, usando o algoritmo de classificação distância de Mahalanobis, que possui formulação similar ao classificador Maxver. A exatidão global obtida para a classificação realizada foi de 85,07% e o índice Kappa de 0,83, usando as bandas do visível e infravermelho próximo que possuem resolução de 15m.

Na última década, as redes neurais artificiais têm experimentado um grande interesse e têm sido aplicadas com sucesso no reconhecimento de padrões de imagens de satélite. Uma das principais vantagens das redes neurais é a possibilidade de manipulação eficiente de grandes quantidades de dados. Entretanto, a principal razão para o seu uso na classificação de dados de sensoriamento remoto e dados geográficos é que as redes neurais não assumem nenhuma distribuição, diferentemente da estatística paramétrica tradicional, que pressupõe que as classes informacionais apresentam uma distribuição normal (Atkinson & Tatnall, 1997). Assim, de acordo com Schalkoff (1992), a habilidade para aprender por meio de exemplos e generalizar tornam as redes neurais artificiais atrativas para a classificação supervisionada de dados de sensores remotos.

O objetivo do presente trabalho foi comparar a eficiência dos dados do sensor Aster e do sensor ETM⁺/Landsat 7 na classificação do uso e cobertura da terra, com ênfase nos níveis de degradação das pastagens na Zona da Mata Mineira, através da classificação supervisionada utilizando redes neurais artificiais.

2. MATERIAL E MÉTODOS

A área estudada compreende a totalidade do Município de Viçosa, localizado na Zona da Mata Mineira, entre as coordenadas UTM 707889 e 734079 e 7714520 e 7694030, fuso 23S (Figura 1). Assim como toda a região da Zona da Mata de Minas Gerais. O município de Viçosa é caracterizado por uma topografia acidentada, com altitude média de 650m, apresentando poucas áreas planas. O clima enquadra-se no tipo Cwa (inverno seco e verão chuvoso), de acordo com a classificação climática de Köppen, com temperatura do mês mais frio inferior a 18°C e, do mês mais quente, superior a 22°C e com precipitação média anual de 1203mm.

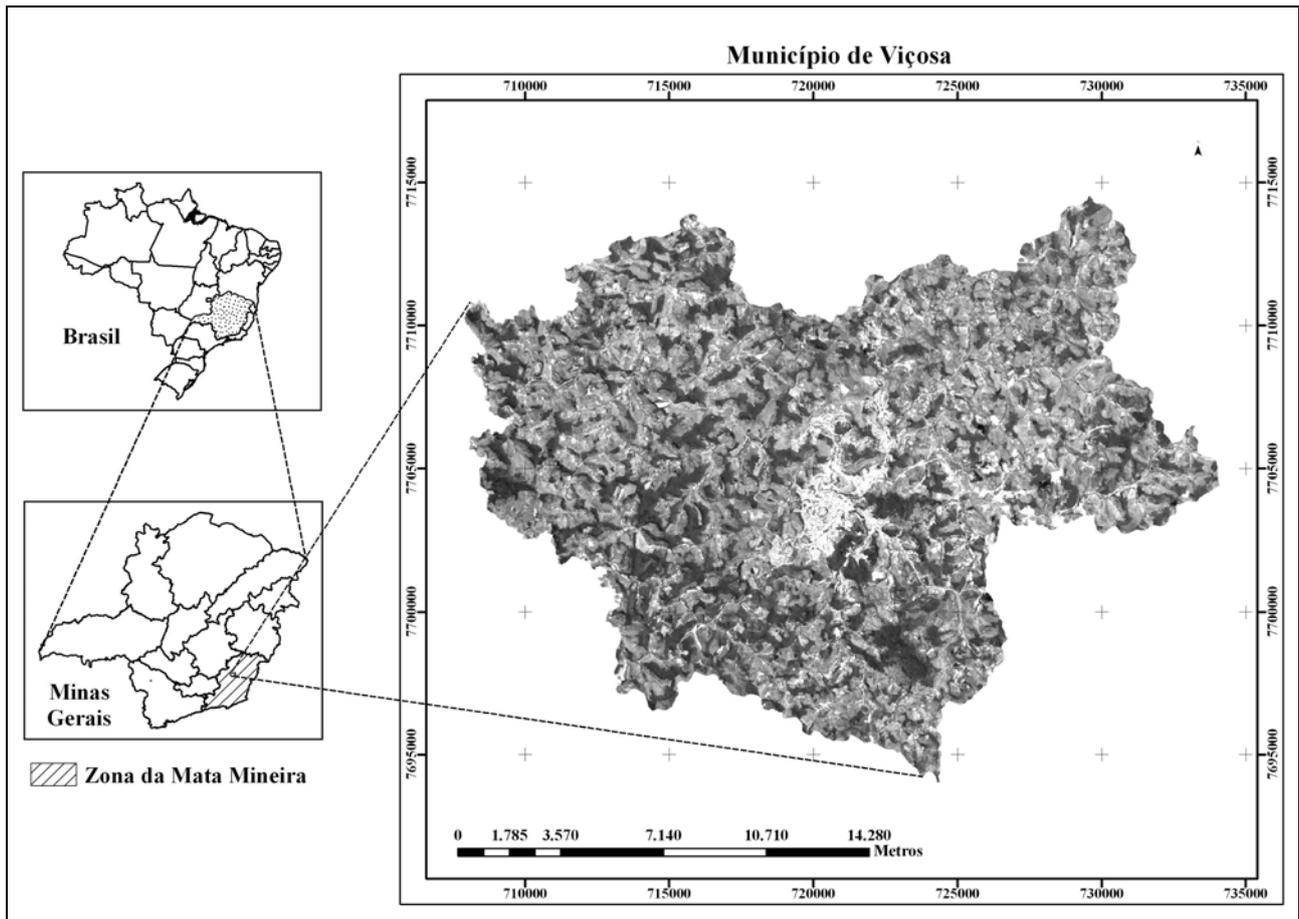


Fig. 1 - Localização da área estudada.

O simulador de redes neurais utilizado neste estudo foi o “Java Neural Network Simulator” desenvolvido pelo Instituto Wilhem-Schickard para Ciência da Computação (WSI) em Tübingen, Alemanha. Este simulador é baseado no Stuttgart Neural Network Simulator 4.2 Kernel (Zell *et al.*, 1996), com uma nova interface gráfica. O algoritmo de aprendizado utilizado foi o *backpropagation* desenvolvido nos anos 80, que é um algoritmo usado para classificação supervisionada.

Nas etapas de coleta de amostras de treinamento e validação, preparação dos dados e geração dos arquivos utilizados na classificação, e preparação dos dados após a classificação, foram utilizados os executáveis Funcpow e Gerapat desenvolvidos por Vieira (2000). Além destes, foram também utilizados o software de SIG ArcGIS 9.0 e o software de processamento de imagens digitais ERDAS Imagine 8.5.

Levando em consideração as características das pastagens da região da Zona da Mata de Minas Gerais e os indicadores visuais de degradação foram utilizados os níveis identificados por Nascimento *et al.* (2006), que são: pastagem no nível de degradação moderado (pastagem 2), pastagem no nível de degradação forte (pastagem 3) e pastagem no nível de

degradação muito forte (pastagem 4), conforme apresentado na Tabela 1 e Figura 2.

TABELA 1 - NÍVEIS DE DEGRADAÇÃO DE PASTAGENS UTILIZADOS.

Níveis de degradação	Parâmetros limitantes	Deterioração
Pastagem 1	Bom vigor e boa qualidade	Leve (não identificado)
Pastagem 2	Baixo vigor, qualidade e baixa população	Moderado
Pastagem 3	Baixo vigor, qualidade e baixa população, associado com a presença de invasoras e/ou cupins	Forte
Pastagem 4	Baixo vigor, qualidade e baixa população, associado com a presença de invasoras, cupins e solo descoberto	Muito forte

Fonte: Adaptado de Spain & Gualdrón (1988) e Moreira & Assad (2000).

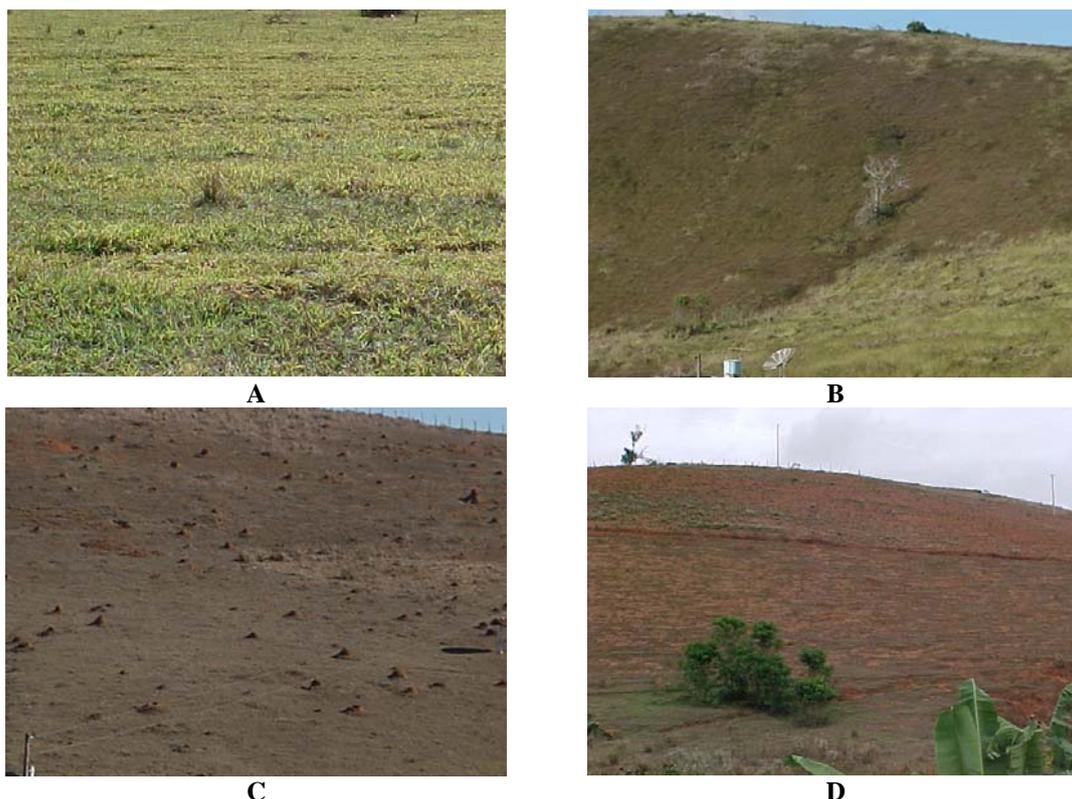


Fig. 2 - Níveis de degradação das pastagens identificados. (A) nível de degradação moderado; (B) nível de degradação forte; (C) e (D) nível de degradação muito forte.

Três diferentes composições de uma imagem do sensor Aster (Advanced Spaceborne Thermal Emission and Reflection Radiometer), obtida em 05/04/2001, e uma do sensor ETM⁺/Landsat 7, de 18/03/2001, foram avaliadas quanto à capacidade de discriminação dos níveis de degradação das pastagens no Município de Viçosa.

Especificamente as composições utilizadas foram: composição A (3 bandas do visível e infravermelho próximo do Aster com resolução espacial de 15m); composição B (6 bandas do infravermelho médio do Aster com resolução espacial de 30m), composição C (9 bandas do visível, infravermelho próximo e infravermelho médio do Aster com resolução espacial de 30m); e composição D (6 bandas do visível, infravermelho próximo e infravermelho médio do ETM⁺/Landsat 7 com resolução espacial de 30m).

Para a classificação de cada composição de imagem avaliada foram coletados dois conjuntos de amostras independentes, um para treinamento e outro para validação. O número de amostras de treinamento foi estipulado em 250 para cada classe (perfazendo um total de 1500 padrões) e o tamanho do conjunto de validação em 150 para cada classe (900 no total). Além das classes referentes aos níveis de degradação das pastagens, foram também consideradas as classes floresta (floresta primária ou secundária), café e área urbana/solo exposto, totalizando 6 classes informacionais.

A amostragem utilizada foi a do tipo aleatória estratificada. Para tanto, com base nos padrões das

classes informacionais obtidos no campo com GPS (Ground Positioning System) foram coletadas, aleatoriamente, amostras dentro de cada uma das classes consideradas. Uma vez definidos os conjuntos de amostras, todos os dados das composições (A, B, C e D) foram re-escalados entre os valores de 0 e 1, para facilitar o processo de treinamento da rede e simplificar sua estrutura (Master, 1993).

Em seguida, os conjuntos de amostras foram utilizados no treinamento e validação das redes neurais. Diferentes arquiteturas foram testadas, variando o número de neurônios na camada de entrada, correspondentes ao número de bandas das composições avaliadas (A, B, C e D); variando o número de neurônios na camada interna; e todas tendo o mesmo número de neurônios na camada de saída (6 classes de uso da terra).

O número de neurônios da(s) camada(s) interna(s) foi determinado através de tentativa e erro, conforme procedimento estabelecido por Hirose *et al.* (1991). Neste procedimento inicia-se a camada intermediária com um número mínimo de neurônios e acrescentam-se gradativamente neurônios, e/ou outra camada interna, até a rede convergir para limiares de erros pré-estabelecidos. Em seguida, começa-se o processo inverso de retirada de neurônios (pruning), enquanto o desempenho da rede estiver dentro desses limiares. Inicialmente, o erro do treinamento foi usado como critério para avaliar o desempenho da rede. O erro do treinamento mede a diferença entre os valores

estimados e os valores desejados para o conjunto de treinamento.

O treinamento das redes utilizando um aprendizado supervisionado consistiu dos seguintes procedimentos:

i) alocação aleatória dos pesos interneurônios.

Os pesos foram inicializados com pequenos valores aleatórios (entre -0,5 e 0,5) para evitar o problema de que a rede neural seja saturada com valores grandes no início do treinamento, ou a dificuldade da rede em aprender devido à presença de valores homogêneos (Vieira, 2000);

ii) determinação da taxa de aprendizado. Esta determinação para um problema específico não é uma tarefa simples. Valores típicos de η estão na faixa de 0,1 a 1,0. A taxa de aprendizado utilizada foi de 0,2 considerando 10.000 ciclos de aprendizagem.

Ao final de todo o processo de treinamento, todas as redes foram submetidas à validação, com um conjunto de amostras de treinamento independente, para escolha daquela que seria utilizada na classificação do uso e cobertura da terra da área para cada composição de imagem avaliada.

A avaliação constou da determinação do nível de exatidão ou confiança da classificação (índice Kappa) e da exatidão global da classificação de cada rede, através da análise da matriz de confusão (Congalton, 1991). Uma matriz de significância de Kappa foi também gerada para verificar a existência de diferenças significativas ou não entre os resultados obtidos e para a escolha da melhor arquitetura de rede para a classificação final das imagens (Vieira, 2000).

3. RESULTADOS E DISCUSSÃO

Para todas as composições avaliadas, houve uma tendência de estabilização dos valores de MSE (Mean Square Error, erro médio quadrático) a partir das redes com 10 neurônios na camada interna. Em seguida, todas as redes neurais foram submetidas à validação e o desempenho do índice Kappa determinado para possibilitar a escolha da melhor arquitetura para a classificação de cada composição. Os resultados obtidos são mostrados na Figura 3.

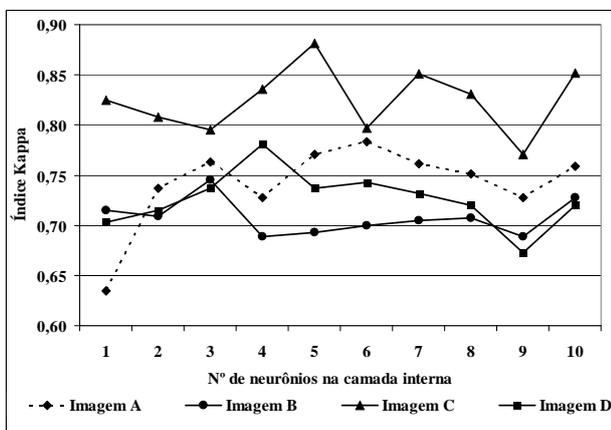


Fig. 3 - Resultados obtidos com a validação das redes.

Segundo Foody & Arora (1997), a arquitetura de uma rede neural pode ter uma influência significativa em sua habilidade para classificar dados de sensores remotos. Nesta avaliação os melhores resultados foram alcançados com a utilização dos dados da composição C que obteve valores de índice Kappa superiores, para todas as arquiteturas de redes testadas, em relação aos obtidos pelas demais composições.

Para as demais composições os resultados do índice Kappa foram bastante influenciados pela arquitetura da rede, com a composição A tendo ligeira vantagem sobre as composições B e D, principalmente para arquiteturas de rede entre 5 e 10 neurônios na camada interna, e o pior desempenho foi obtido pela composição B, independente da arquitetura de rede.

O aumento da complexidade da rede com a adição de neurônios na camada interna não melhorou substancialmente os resultados da classificação, quando se utilizou as amostras de validação, em todas as composições. De acordo com Foody & Arora (1997), em geral, redes maiores e mais complexas são mais eficientes para caracterizar corretamente um conjunto de treinamento, porém podem ser menos eficientes para generalizar a classificação para padrões que não foram treinados, do que redes mais simples.

Para cada composição foi gerada uma matriz de significância de Kappa para avaliar a existência de diferenças significativas ou não entre as redes testadas e possibilitar a escolha de uma arquitetura que possibilitasse uma melhor exatidão da classificação. Para composição A o melhor resultado foi obtido com uma rede contendo 6 neurônios na camada interna, enquanto que para a composição B o melhor resultado foi alcançado com uma rede com 3 neurônios. Já na composição C o melhor desempenho foi obtido com a utilização de uma rede com 5 neurônios na camada interna, e na composição D com 4 neurônios na camada interna.

Em seguida, foi realizada uma comparação final entre estas redes, através de uma matriz de significância de Kappa (Tabela 2) para verificar a existência de diferenças significativas ou não, entre as classificações de cada composição. Os valores de Kappa obtidos para estas classificações, sempre superiores a 0,75, mostram um desempenho do classificador de muito bom a excelente (Monserud & Leemans, 1992).

De modo geral, dados com resolução espacial mais grosseira tendem a apresentar problemas de mistura de pixels, e conseqüentemente são menos sensíveis à complexidade espacial (Rocchini, 2007). No presente estudo, embora a composição A apresente uma melhor resolução espacial (15m), os resultados obtidos com a sua utilização não foram superiores aos obtidos pelas composições B, C e D (30m), evidenciando, que a resolução espacial teve uma menor influência sobre a exatidão da classificação do que a resolução espectral.

De acordo com Rocchini (2007), nem sempre é verdadeiro, para todos os ambientes e escalas de mapeamento, que um tamanho de pixel menor favoreça

uma maior exatidão da classificação de dados de sensores remotos. Em vários casos, há a necessidade de aumento do número de bandas espectrais e uma diminuição da largura da banda (aumento da resolução

espectral) para melhorar a exatidão da classificação, e não somente uma redução do tamanho de pixel.

TABELA 2 - MATRIZ DE SIGNIFICÂNCIA DE KAPPA PARA AS CLASSIFICAÇÕES REALIZADAS.

Composição	A (Aster - 3 bandas)	B (Aster - 6 bandas)	C (Aster - 9 bandas)	D (Landsat 7 - 6 bandas)
Exatidão global	81,8	78,8	90,1	81,8
Kappa	0,783	0,745	0,881	0,781
Variância	0,000237	0,000266	0,000142	0,000236
A	50,86			
B	1,69NS	45,68		
C	5,03*	6,73*	73,93	
D	0,09NS	1,61NS	5,14*	50,84

* diferença significativa ao nível de 95%; NS - não significativo.

A utilização da composição B (bandas do infravermelho médio) isoladamente obteve resultados ligeiramente inferiores, porém não foram estatisticamente significativos, aos obtidos pela composição A. Por outro lado, o aumento do número de variáveis discriminantes, com a utilização da composição C, teve um efeito significativo sobre a exatidão da classificação com resultado estatisticamente superior aos alcançados pelas composições A e B (Tabela 2).

Embora as informações das bandas 5, 6, 7 e 8 do Aster sejam muito similares, para quase todas as classes consideradas (Figura 4), indicando grande correlação entre estas bandas, os resultados obtidos pela composição C mostram a habilidade da rede neural para estimar a importância das variáveis discriminantes na classificação, ignorando efetivamente variáveis redundantes (Foody & Arora, 1997).

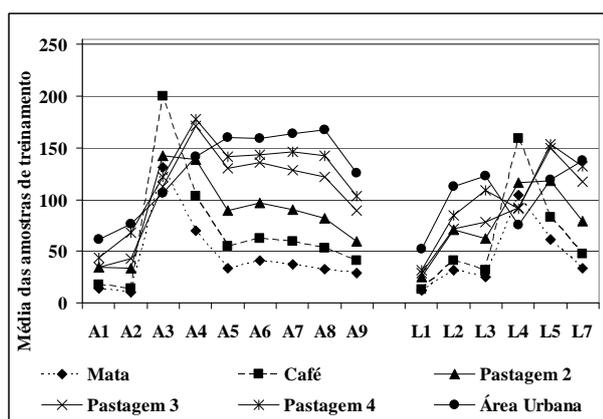


Fig. 4 - Valores médios de reflectância espectral das amostras de treinamento das classes avaliadas em cada banda dos sensores avaliados. A - Aster; L - ETM⁺/Landsat 7.

Segundo Kanellopoulos & Wilkinson (1997), nos casos onde existe considerável redundância, é possível que a adição de novas variáveis reduza o

desempenho geral da classificação, o que não foi observado, já que o maior número de bandas da composição C beneficiou o resultado final da classificação.

Classificações realizadas com subconjuntos desta composição mostraram desempenho estatístico inferior ou similar aos alcançados pela composição completa, confirmando a habilidade da rede neural para estimar a importância das variáveis discriminantes na classificação ao ignorar efetivamente a redundância observada, principalmente entre as bandas 5, 6, 7 e 8.

A utilização da composição D obteve resultado similar (Kappa = 0,781) ao obtido pela composição A (Kappa = 0,783) e ligeiramente superior ao da composição B (Kappa = 0,745), porém todos não diferiram significativamente ao nível de 95%. A composição D teve um desempenho inferior e significativamente diferente ao da composição C (Tabela 2). Neste caso, a maior exatidão obtida por esta última pode ser atribuída a sua melhor resolução espectral. Segundo Almeida & De Souza (2004), o uso de imagens com maior resolução espectral, via de regra, possibilita uma melhora na capacidade de detecção da variabilidade espectral de uma região pelo aumento do poder de discriminação.

Quando se considera cada classe individualmente, verifica-se que a exatidão obtida por cada composição teve um comportamento diferenciado. De modo geral, as classes floresta e café apresentaram exatidões elevadas (> 90%) na classificação (Tabela 3), exceto a classe café quando se utilizou a composição B (exatidão de 80%). Este resultado evidencia a importância das bandas do visível e, principalmente da banda do infravermelho próximo para discriminação da classe café, visto que estas não estão presentes na composição B. Estudo realizado por Moreira *et al.* (2004) mostrou que a utilização da banda 4 (infravermelho próximo) do ETM⁺/Landsat 7 foi fundamental para diferenciar café das classes floresta e pastagem.

TABELA 3. MATRIZ DE CONFUSÃO OBTIDA NAS CLASSIFICAÇÕES DAS IMAGENS.

Composição A - 6 neurônios na camada interna.

Classes	1	2	3	4	5	6	Total	Exatidão do usuário	Z
1	148	1	0	0	0	0	149	99,3	123,7
2	0	137	12	2	1	1	153	89,5	30,05
3	2	10	115	8	4	15	154	74,7	17,38
4	0	0	14	113	4	9	140	80,7	19,86
5	0	0	0	20	116	18	154	75,3	17,70
6	0	2	9	7	25	107	150	71,3	15,62
Total	150	150	150	150	150	150	900		
Exatidão do Produtor	98,7	91,3	76,7	75,3	77,3	71,3			

Composição B - 3 neurônios na camada interna.

Classes	1	2	3	4	5	6	Total	Exatidão do usuário	Z
1	145	18	2	0	0	0	165	87,90	28,73
2	4	120	12	0	0	0	136	88,20	26,42
3	0	12	122	10	7	0	151	80,80	20,74
4	0	0	9	89	46	0	144	61,80	11,93
5	1	0	2	42	88	5	138	63,80	12,24
6	0	0	3	9	9	145	166	87,30	28,12
Total	150	150	150	150	150	150	900		
Exatidão do Produtor	96,7	80	81,3	59,3	58,7	96,7			

Composição C - 5 neurônios na camada interna.

Classes	1	2	3	4	5	6	Total	Exatidão do usuário	Z
1	147	2	3	0	2	0	154	95,5	47,34
2	0	140	3	0	0	0	143	97,9	68,03
3	1	6	123	1	1	0	132	93,2	35,36
4	0	0	21	138	24	0	183	75,4	19,53
5	2	0	0	10	120	7	139	86,3	24,48
6	0	2	0	1	3	143	149	96,0	49,61
Total	150	150	150	150	150	150	900		
Exatidão do Produtor	98,0	93,3	82,0	92,0	80,0	95,3			

Composição D - 4 neurônios na camada interna.

Classes	1	2	3	4	5	6	Total	Exatidão do usuário	Z
1	143	7	0	0	1	1	152	94,1	40,89
2	2	143	2	0	0	1	148	96,6	54,17
3	0	0	106	1	9	4	120	88,3	24,88
4	0	0	37	128	39	1	205	62,4	14,93
5	5	0	2	14	79	6	106	74,5	14,13
6	0	0	3	7	22	137	169	81,1	22,24
Total	150	150	150	150	150	150	900		
Exatidão do Produtor	95,3	95,3	70,7	85,3	52,7	91,3			

1 - floresta; 2 - café; 3 - pastagem no nível de degradação moderado; 4 - pastagem no nível de degradação forte; 5 - pastagem no nível de degradação muito forte; e 6 - área urbana/solo exposto.

Os valores de exatidão obtidos na classificação das áreas urbanas, que apresentam comportamento espectral bastante distinto e contrário ao das classes floresta e café (Figura 4), também foram maiores que 90%, exceto quando se utilizou a composição A (71,3%) (Tabela 3). Neste caso, o resultado pode ser atribuído ao comportamento espectral desta classe muito parecido com o das classes pastagem 2, pastagem 3 e pastagem 4, na região do visível e, principalmente no infravermelho próximo (Figura 4), o que causa uma maior confusão na classificação e diminui a exatidão obtida.

Os valores de reflectância das pastagens (Figura 4), na região do visível e do infravermelho médio, aumentam com o aumento do nível de degradação, e de modo mais marcante no caso do sensor Aster. A causa dessa variação está relacionada com a maior contribuição do componente solo em relação ao componente vegetação nas respostas espectrais das pastagens à medida que o nível de degradação aumenta (Tabela 1), ocasionando uma menor absorção da radiação eletromagnética e, conseqüentemente, aumentando os valores de reflectância nas bandas do visível e infravermelho médio (Moreira *et al.*, 2004). Já

na banda do infravermelho próximo, tanto do Aster quanto do ETM⁺/Landsat 7, verifica-se um comportamento contrário.

A classe pastagem 2 foi melhor identificada quando se utilizou a composição C, com 82% de exatidão, seguida das composições B (81,3%), A (76,7%) e D (70,7%) (Tabela 3). Neste caso, verifica-se uma maior contribuição das bandas do infravermelho médio sobre as bandas do visível na discriminação desta classe, quando se compara as três composições do Aster e, uma maior eficiência do Aster sobre o ETM⁺/Landsat 7, em função de sua melhor resolução espectral. Para a composição C (melhor classificação), a maior confusão observada com esta classe foi com a classe pastagem 3, com 14% dos pixels sendo incorretamente assinalados a esta última.

Do mesmo modo, a classe pastagem 3 foi melhor identificada quando se utilizou a composição C, com 92% de exatidão, seguida das imagens D (85,3%), A (75,3%) e B (59,3%). Para todas as composições testadas, verifica-se que a classe pastagem 3 teve uma maior confusão com a classe pastagem 4 (Tabela 3), o que pode ser atribuído ao comportamento espectral bastante similar entre estas classes. Já o pior desempenho da composição B parece estar relacionado com a ausência das bandas do visível, principalmente, a banda 2 e do infravermelho próximo nesta composição (Figura 4).

A classe pastagem 4, que tem uma forte

contribuição do componente solo em seu comportamento espectral, foi também melhor identificada pela composição C, com 80% de exatidão, contra 77,3% para a composição A, 58,7% para a composição B e 52,7% quando se utilizou a composição D. No caso das composições C e B, a maior confusão foi verificada com a classe pastagem 3 (16% e 30,67%, respectivamente, composições C e B), e na composição A com a classe área urbana/solo exposto (16,67%). Para a composição D, a classe pastagem 4 foi confundida com as classes pastagem 3 (26%) e área urbana/solo exposto (14,67%).

O resultado da classificação final das composições testadas é mostrado na Figura 5. A comparação visual entre as classificações das imagens e a imagem de referência apresentada na Figura 5, mostra, de maneira geral, uma boa concordância das classificações obtidas pelas composições A, C e D, e uma baixa concordância quando se utilizou a composição B. Esta última apresenta uma tendência a superestimar as classes café, pastagem 2 e pastagem 4, enquanto as classes floresta e pastagem 3 parecem subestimadas. O pior desempenho obtido pela composição B está em concordância com a menor exatidão e menor índice Kappa obtidos. Nesta comparação, chama atenção, ainda, a área classificada como pertencente à classe área urbana/solo exposto, quando se utilizou a composição A, que nitidamente foi subestimada.

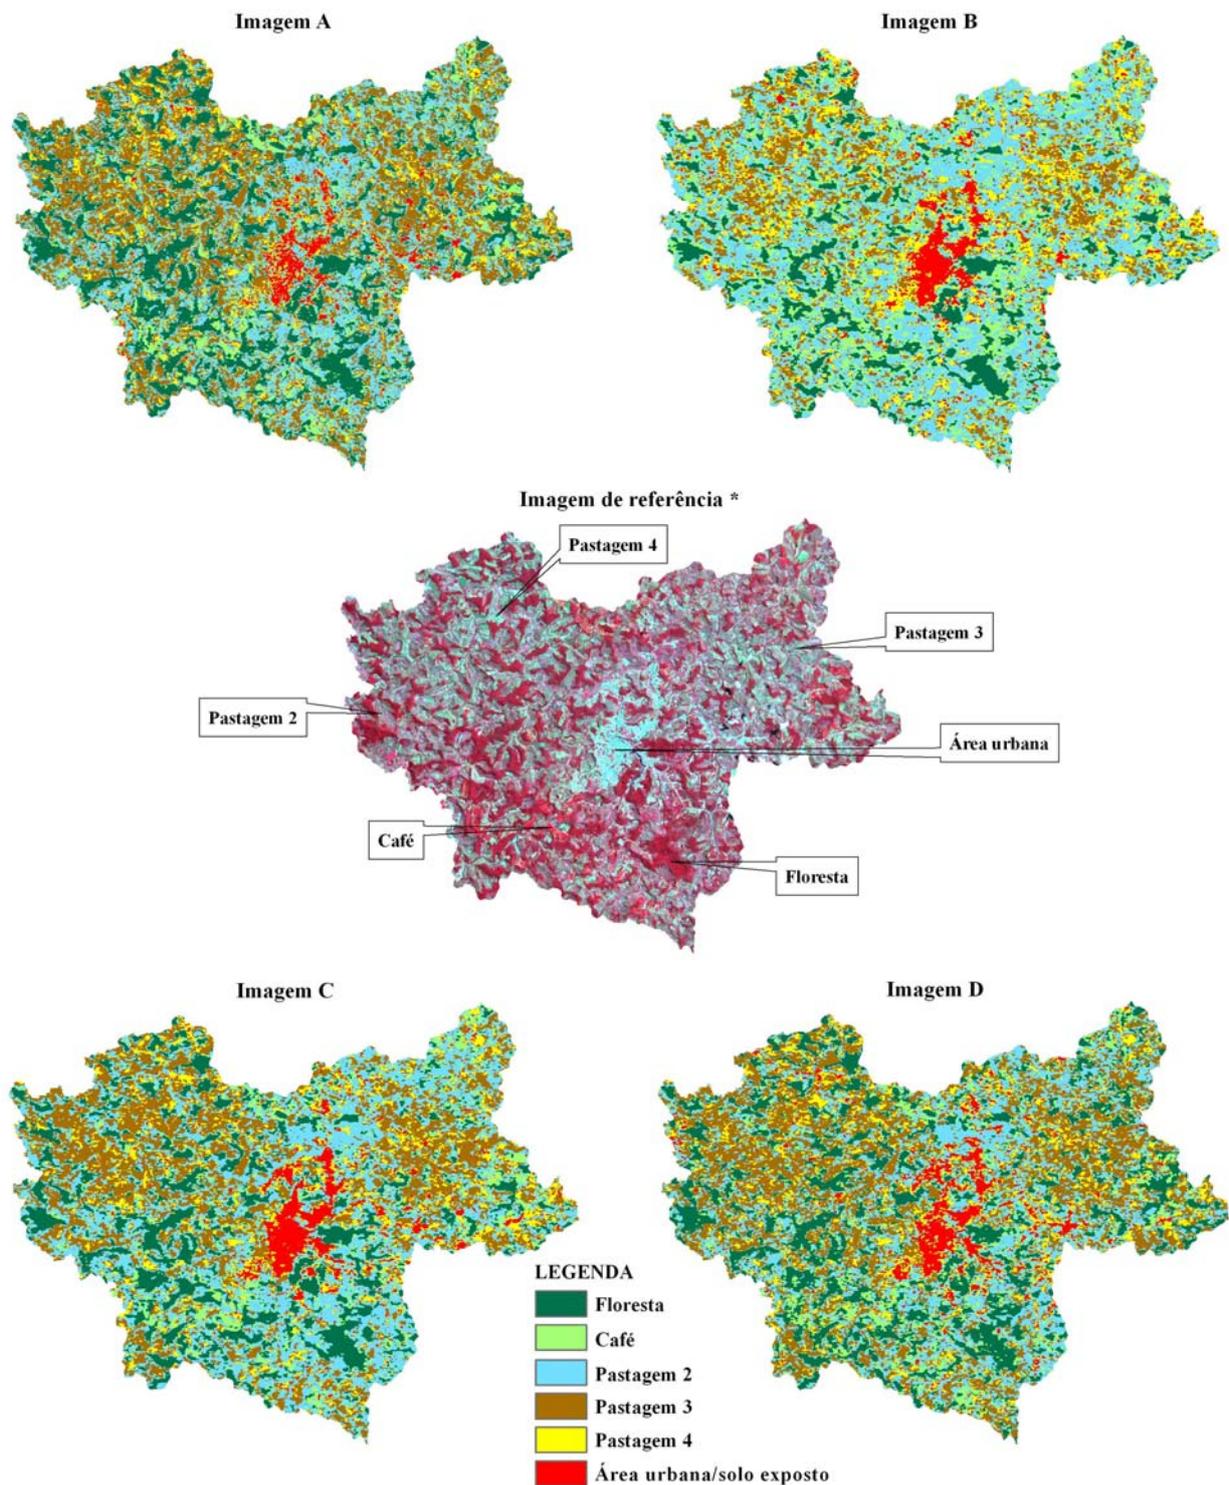


Fig. 5 - Mapas temáticos obtidos com a classificação das imagens. * composição colorida 3R/2G/1B da imagem Aster.

4. CONCLUSÕES

1. O presente estudo mostrou que a utilização de redes neurais para classificação de níveis de degradação de pastagens na Zona da Mata Mineira é uma alternativa válida. Neste sentido a exatidão geral da classificação mostrou-se bastante influenciada pelo tipo e número de variáveis discriminantes (bandas) e pela arquitetura de rede.

2. Os valores do índice Kappa obtidos pelas classificações foram superiores a 0,75, considerado de muito bom a excelente, para quase todas as classificações, exceto para composição B, cujo desempenho para este índice foi moderado. Levando em conta a dificuldade causada pela similaridade do comportamento espectral dos níveis de degradação das pastagens, pode-se considerar que os resultados são bastante satisfatórios.

3. O melhor resultado para o índice Kappa foi obtido pela composição C (9 bandas do Aster, com resolução espacial de 30m), que foi atribuído a sua melhor resolução espectral, quando comparada às demais.

4. Considerando apenas a degradação das pastagens, a composição C (9 bandas do Aster) foi a que permitiu a melhor discriminação das classes de pastagem consideradas. A classe que apresentou o maior erro em todas as classificações foi a classe pastagem 4 (nível de degradação muito forte), bastante confundida com a classe pastagem 3 (nível de degradação forte).

REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, T. I. R.; DE SOUZA, C. R. F. Principal component analysis applied to feature-oriented band ratios of hyperspectral data: A tool for vegetation studies. **International Journal of Remote Sensing**, v.25, p.5005-5023, 2004.

ATKINSON, P. M.; TATNALL, A. R. L. Neural networks in remote sensing. **International Journal of Remote Sensing**, v.18, n.4, p.699-709, 1997.

CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v.49, n.12, p.1671-1678, 1991.

FOODY, G. M.; ARORA, M. K. An evaluation of some factors affecting the accuracy of classification by an artificial neural network. **International Journal of Remote Sensing**, v.18, n.4, p.799 - 810, 1997.

HIROSE, Y.; YAMASHITA, K.; HIJIYA, S. Back-propagation algorithm which varies the number of hidden units. **Neural Networks**, v.4, p.61-66, 1991.

KANELLOPOULOS, I.; WILKINSON, G. G. Strategies and best practice for neural network image classification. **International Journal of Remote Sensing**, v.18, n.4, p.711-725, 1997.

MASTER, T. **Practical neural network recipes in C++**. Academic, San Diego, California. 1993. 493p.

MONSERUD, R. A.; LEEMANS, R. Comparing global vegetation maps with the Kappa statistic. **Ecological Modelling**, v.62, p.275-293, 1992.

MOREIRA, M. A.; ADAMI, M.; RUDORFF, B. F. T. Análise espectral e temporal da cultura do café em imagens Landsat. **Pesquisa Agropecuária Brasileira**, v.39, n.3, p.223-231, 2004.

MOREIRA, L.; ASSAD, E. D. Segmentação e classificação supervisionada para identificar pastagens degradadas. Workshop Brasileiro de Geoinformática, 2, 2000, São Paulo, SP. **Anais...[S.I.]**: Sociedade Brasileira de Computação, 2000. 15p.

NASCIMENTO, M. C.; RIVA, R. D. D.; CHAGAS, C. S.; OLIVEIRA, H.; DIAS, L. E.; FERNANDES FILHO, E. I.; SOARES, V. P. Uso de imagens do sensor Aster na identificação de níveis de degradação em pastagens. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 10, p. 196-202, 2006.

QUINTEIRO, F. Q. L. Levantamento do uso da terra e caracterização de ambiente da bacia hidrográfica do Rio Turvo Sujo com a utilização de aerofotos não-convencionais. Viçosa: UFV, 1997. 91p. Dissertação Mestrado.

ROCCHINI, D. Effects of spatial and spectral resolution in estimating ecosystem α -diversity by satellite imagery. **Remote Sensing of Environment**, 2007. doi: 10.1016/j.rse.2007.03.018.

SANO, E. E.; CHAVES, J. M.; BEZERRA, H. S.; FEITOZA, L. Identificação dos principais tipos de pastagens cultivadas do Cerrado a partir de Sensoriamento Remoto. International Symposium: Soil Functioning under Pastures in Intertropical Areas, 2000, Brasília, DF. **Anais...** Brasília: Embrapa Cerrados - IRD, 2000. CD-ROM.

SCHALKOFF, R. J. **Pattern Recognition: Statistical, Structural and Neural Approaches**. New York: John Wiley and Sons. 1992.

SEYLER, F.; CHAPLOT, V.; MULLER, F.; CERRI, C. E. P.; BERNOUX, M.; BALLESTER, V.; FELLER, C.; CERRI, C. C. C. Pasture mapping by classification of Landsat TM images. Analysis of the spectral behaviour of the pasture class in a real medium-scale environment: the case of the Piracicaba Catchment (12400 km², Brazil). **International Journal of remote Sensing**, v.23, p.4985 - 5004, 2002.

SPAIN, J. M.; GUALDRÓN, R. Degradación e rehabilitación de pasturas. In: LASCANO, C.; SPAIN, J. M. (Ed.). **Establecimiento y renovación de pasturas**. Cali: CIAT, 1991. 426p.

VIEIRA, C. A. O. **Accuracy of remotely sensing classification of agricultural crops: a comparative study**. University of Nottingham, 2000. 327p. (PhD Thesis).

ZELL, A.; MAMIER, G.; VOGT, M.; MACHE, N.; HÜBNER, R.; DÖRING, S.; HERRMANN, K.; SOYEZ, T.; SCHMALZL, M.; SOMMER, T.; HATZIGEORGIOU, A.; POSSELT, D.; SCHREINER, T.; KETT, B.; CLEMENTE, G.; WIELAND, J.; GATTER, J. **Stuttgart Neural Network Simulator v4.2**. University of Stuttgart: Institute for Parallel and Distributed High Performance Systems/University of Tübingen - Wilhelm-Schickard-Institute for Computer Science - Department of Computer Architecture. 1996.