

APLICAÇÃO DE CLASSIFICADORES CONVENCIONAIS E REDE NEURAL ARTIFICIAL PARA MAPEAMENTO DE UMA IMAGEM VANT

APPLICATION OF CONVENTIONAL CLASSIFIERS AND ARTIFICIAL NEURAL NETWORK FOR MAPPING A VANT IMAGE

Márcia Rodrigues de Moura FERNANDES¹, Ronie Silva JUVANHOL¹; Daniel Henrique Breda BINOTI¹; Gilson Fernandes da SILVA¹; Márcio BERNARDI²; Josué Pedro dos Santos BORGES², Hélio Garcia LEITE³

¹Programa de Pós-Graduação em Ciências Florestais. Universidade Federal do Espírito Santo. Jerônimo Monteiro, ES – Brasil. Email: marciarmfe@gmail.com; roniejuvanhhol@gmail.com; danielhbbinoti@gmail.com; fernandes5012@gmail.com

²Eldorado Brasil, Três Lagoas-MS. Emails: marcio.bernardi@eldoradobrasil.com.br; josue.borges@eldoradobrasil.com.br

³Programa de Pós-Graduação em Ciências Florestais. Universidade Federal de Viçosa, Departamento de Engenharia Florestal. Viçosa, MG – Brasil. Email: hgleite@gmail.com

Introdução
Materiais e métodos
 Caracterização da área de estudo
 Material
 Métodos
Resultados e discussão
Comparação entre os classificadores
Conclusão
Referências bibliográficas

RESUMO - Este estudo teve por objetivo avaliar a eficiência de dois classificadores convencionais e uma rede neural MLP para o mapeamento do uso da terra a partir de uma imagem VANT. Foram definidas quatro classes na imagem para a classificação automática: eucalipto, pastagem, matocompetição e solo exposto. O algoritmo utilizado no simulador de redes neurais artificiais *NeuroDic*® 2.0 foi o *resilient-propagation*. Para aplicação dos classificadores convencionais MAXVER e ISODATA foi utilizado o *software* Erdas Imagine®11. A melhor classificação foi obtida pelo algoritmo MAXVER e o pior desempenho, com o algoritmo ISODATA. Ao final, pode-se concluir que a rede neural mostrou ser um paradigma eficiente para a classificação de imagens.

Palavras-chave: sensoriamento remoto, algoritmo de classificação, índice *Kappa*.

ABSTRACT - This aim of this study is to evaluate the efficiency of two conventional classifiers and neural network MLP for land use mapping from a Vant image. Four classes were defined on the image for automatic classification: eucalyptus, pasture, weed competition and exposed soil. The algorithm used in the artificial neural network simulator “*NeuroDic*® 2.0” was the *resilient-propagation*. For conventional classifiers MAXVER and ISODATA the *software* Erdas Imagine®11 was employed. The results show that the best classification was obtained by the algorithm MAXVER and worse performance with algorithm ISODATA, according to the *Kappa* index. Finally, it can be concluded that the neural network has proved to be an efficient paradigm for image classification.

Keywords: remote sensing, classification algorithm, *Kappa* index.

INTRODUÇÃO

O Sensoriamento remoto pode ser definido como a medição ou aquisição da informação de alguma propriedade de um objeto ou fenômeno, por um dispositivo de registro que não esteja em contato físico com o objeto ou fenômeno em estudo. Esse dispositivo pode ser dividido em orbital, quando as informações são coletadas por sensores localizados em órbitas, como as imagens de satélites (Jensen, 2009), ou sub-orbital, quando o processo é realizado por equipamentos aerotransportados não localizados em órbitas, como as fotografias aéreas (Piroli, 2010).

As técnicas de processamento de imagens podem ser categorizadas em três grupos: técnicas de pré-processamento, técnicas de realce e técnicas de classificação. As técnicas de classificação consistem no estabelecimento

de um processo de decisão, no qual um grupo de pixels é definido como pertencente a uma determinada classe (Novo, 2010), podendo ser divididas em não-supervisionada e supervisionada.

A primeira não requer qualquer informação sobre classes de interesse, somente examinando sem auxílio do analista, os agrupamentos espectrais do alvo são fornecidos e as classes mapeadas.

Esse tipo de classificação trabalha com a lógica conhecida denominada análise de agrupamento (*clustering*), sendo útil quando não se possui informações sobre a área imageada, sendo as classes definidas no algoritmo de classificação (Rosa, 2009).]

Ela pode ser realizada pelo algoritmo ISODATA (*Iterative Self-Organizing Data*

Analysis Techniques), que tem por finalidade agrupar os pixels, dividindo os dados da imagem no espaço multispectral, em um determinado número de classe estipulado pelo usuário (Jensen, 1996).

A classificação supervisionada consiste na identificação prévia das classes de informação, chamadas áreas de treinamento, que são representações do comportamento médio das classes que serão mapeadas automaticamente (Novo, 1992).

Esse tipo de classificação é utilizado quando existe conhecimento sobre as classes que devem ser representadas na imagem. Uma das principais técnicas utilizadas para classificações supervisionadas é a máxima verossimilhança realizada pelo algoritmo MAXVER (*Maximum Likelihood*), que consiste na classificação da imagem ponto a ponto, a partir de classes fornecidas pelo usuário (Rosa, 2009).

No início dos anos 90, as redes neurais artificiais (RNA) deram grande impulso à

análise de dados de Sensoriamento Remoto (Kavzoglu & Mather, 2003).

Por isso, na classificação de imagens, a utilização de redes neurais artificiais (RNA) pode ser uma alternativa mais eficiente que utilizar métodos estatísticos (Cruz & Galo, 2003).

Assim, uma das principais vantagens das redes neurais é a possibilidade de manipulação eficiente de um grande conjunto de dados, sendo seu uso na classificação de dados de sensoriamento remoto e dados geográficos motivado por não assumir nenhuma distribuição, diferentemente da estatística paramétrica tradicional, que pressupõe que as classes informacionais apresentam distribuição normal (Atkinson & Tatnall, 1997).

Nesse contexto, este trabalho teve por objetivo avaliar o desempenho dos classificadores convencionais e de uma rede neural artificial para o mapeamento de uma imagem VANT.

MATERIAIS E MÉTODOS

Caracterização da área de Estudo

A área de estudo localiza-se no Estado do Mato Grosso do Sul, no município de Três Lagoas, entre as coordenadas 20°47'17"S e 51°42'10"W, com 327 m de altitude, sendo seu tipo climático o Aw (quente e úmido) de acordo com a classificação de Köppen.

Material

Foi utilizada, neste estudo, como exemplo de aplicação, uma imagem de VANT (Veículo Aéreo Não Tripulado), obtida no ano de 2014. Foram usadas as bandas: verde (500 nm até 575 nm) vermelho (575 nm até 675 nm) e infravermelho próximo (675 nm até 900 nm), com resolução espacial de 1 m.

Os métodos de classificação utilizados foram: classificação supervisionada e não supervisionada na imagem. Para a classificação supervisionada, a rede MLP (Haykin, 2001) e o algoritmo MAXVER foram empregados, enquanto, para a classificação não supervisionada foi utilizado o algoritmo ISODATA.

O simulador de redes neurais empregado foi o NeuroDic® 2.0. Os algoritmos MAXVER e ISODATA foram executados no *software* Erdas Imagine®11. Foram definidas quatro classes na imagem para a classificação automática, sendo conhecidas: eucalipto, pastagem, matocom-

petição (MC) e parte superficial do solo exposta (solo exposto).

Métodos

O algoritmo de aprendizado utilizado na RNA foi o *resilient-propagation* (RProd+) que é uma variação do método *backpropagation*, proposto com o objetivo de tornar o processo de convergência mais eficiente. O método *resilient-propagation*, ao invés de considerar as variações das magnitudes do gradiente da função erro, leva somente em conta a variação do seu sinal (Riedmiller & Braun, 1993).

Desta forma, a taxa de aprendizagem do método se torna dinâmica, pois quando os sinais do gradiente forem os mesmos, considerando duas iterações, significa que se pode incrementar a taxa de aprendizado em virtude de se estar relativamente distante de um ponto de mínimo da função erro (Silva et al., 2010).

Uma vez definidos os conjuntos de amostras contendo as informações relativas à imagem utilizada, a função de ativação logística foi escolhida, em que o resultado de saída do neurônio em relação a um determinado conjunto de sinais de entrada assume valores reais entre 0 e 1, tendo-se sua expressão matemática dada por:

$$g(u) = \frac{1}{1+e^{-\beta.u}} \quad (\text{Equação 1})$$

Em que: β = constante real associada a um nível de inclinação da função logística frente a seu ponto de inflexão; u = potencial de ativação produzido pela diferença do valor produzido entre o combinador linear e o limiar de ativação.

Foram estabelecidas cinco redes para o treinamento, sendo testadas diferentes arquiteturas, sempre com 12 neurônios na camada de entrada, com as bandas *RGinfra GainFilter*, *RGinfra; InverterFilter*, *RGinfra; SolarizeFilter*, *RGifra*, variando o número de camadas ocultas e todas tendo o mesmo número de neurônios na camada de saída (quatro classes de uso da terra). O critério de parada utilizado foi o número de ciclos de aprendizagem, fixado em 15.000.

Ao final de todo o processo de treinamento, a seleção da melhor rede para a classificação da imagem se deu pela avaliação dos seguintes parâmetros: erro quadrático médio, bias e correlação entre valores observados e preditos.

O algoritmo MAXVER é um classificador baseado no método estatístico de máxima verossimilhança. A distribuição utilizada na classificação é a normal (Novo, 2008), ou seja, os objetos pertencentes à mesma classe apresentarão resposta espectral próxima à média dos valores para aquela classe (Ribeiro et al., 2007).

Além disso, considera a ponderação entre as médias dos valores dos *pixels* das classes utilizando parâmetros estatísticos e cada *pixel* é destinado à classe que apresenta a mais alta probabilidade, isto é, a máxima verossimilhança (Meneses & Almeida, 2012).

A equação reduzida do algoritmo de classificação por máxima verossimilhança (Tso & Mather, 2001), é dada por:

$$-\ln[P(x_i|w_i)] = \ln|C_i| + (x_i - \mu_i)^T \cdot C_i^{-1} \cdot (x_i - \mu_i) \text{ (Equação 2)}$$

Em que: x e w = “eventos”; P = probabilidade de coexistência ou interseção destes eventos; C = matriz de covariância da classe w_i , μ_i = vetor médio para a classe w_i ; i = determinante da equação.

Na classificação supervisionada é importante que o analista tenha um conhecimento acerca da localização espacial de algumas amostras das classes de interesse, pois esta classificação se baseia no pressuposto de que cada classe espectral pode ser descrita a partir de amostras fornecidas pelo analista (Richards & Jia, 2006).

Desta forma, foram definidas e coletadas 30 amostras de treinamento para cada classe de uso da terra representada na imagem, utilizando a ferramenta *Signature Editor* (ERDAS, 2011).

O algoritmo ISODATA desenvolve-se baseado em critérios de minimização e aplicação de métodos heurísticos em um procedimento iterativo para a determinação de centroides de classes de padrões (Castro & Prado, 2002).

Os agrupamentos iniciais são pré-definidos e distribuídos ao longo do eixo diagonal do espaço atributo, que é representado por uma linha que se origina no ponto correspondente ao número máximo do nível de cinza de cada componente espectral. Se duas classes estão muito próximas e abaixo do limite estipulado, ocorrerá uma fusão das classes.

Se a distância que a amostra apresenta da média das classes (centroide) for maior que a das classes existentes, esta será dividida em duas classes (Ripley, 2000).

A cada iteração é recalculada a média das classes espectrais e os pixels são reagrupados seguindo os seguintes critérios: as classes com desvio padrão muito grande serão subdivididas para formar classes menores; classes que estão estatisticamente muito próximas são fundidas; e classes com número pequeno de pixels são eliminadas (IBGE, 2001).

Para avaliar a exatidão dos mapas quanto aos classificadores, foram obtidos 100 pontos amostrais adotados como verdade terrestre na imagem e determinado o nível de exatidão ou confiança da classificação (coeficiente *Kappa*) e da exatidão global por meio da análise da matriz de confusão (Congalton, 1991).

A matriz de confusão tem sido reconhecida como a mais importante técnica de estimativa da exatidão de produtos de dados de sensores remotos (Story & Congalton, 1986; Skidmore & Turner, 1989).

A exatidão global (P_0) foi computada pela divisão da soma da diagonal principal (número de classificações corretas) pelo número total de amostras tomadas, segundo a equação:

$$P_0 = \frac{\sum_{i=1}^m X_i}{N} \cdot 100 \quad \text{(Equação 3)}$$

Em que: P_0 = exatidão global (%); N = total de elementos amostrados amostras; X_i = elementos da diagonal principal e m = número de classes presentes na matriz.

O coeficiente *Kappa* foi obtido segundo a equação:

$$K = \frac{n(\sum_{i=1}^c x_{ii}) - \sum_{i=1}^c (x_{i+} x_{+i})}{n^2 - \sum_{i=1}^c (x_{i+} x_{+i})} \quad (\text{Equação 4})$$

Em que: *n* = número total de pixel amostrado; *x_{ii}* = número de pixel da *i*-ésima classe classificados corretamente; *c* = número total de classes; *x_{i+}* = número de pixels selecionados (amostras) para comporem a *i*-ésima classe (linha) e; *x_{+i}* = número de pixels classificados como pertencentes à *i*-ésima classe (total da coluna).

Como referência para os resultados obtidos na matriz de confusão, foi utilizada a classificação

sugerida por Landis & Koch (1977), conforme tabela 1.

Tabela 1 - Qualidade de classificação de acordo com o coeficiente *Kappa*.

Coeficiente <i>Kappa</i>	Exatidão
< 0	Péssima
0-0,2	Ruim
0,21-0,4	Razoável
0,41-0,6	Moderada/Boa
0,61-0,8	Muito Boa
0,81-1,0	Excelente

Fonte: Landis & Koch (1977).

RESULTADOS E DISCUSSÃO

Na avaliação do desempenho da classificação supervisionada do uso da terra pela rede MLP, obteve-se uma exatidão global de 55,90% e índice de concordância *Kappa* de 0,7432. De acordo com Landis e Koch (1977), a qualidade da classificação apresentou um desempenho muito bom.

O maior erro na classificação foi observado na classe eucalipto, com 31,25% dos pixels que deveriam ser assinalados a esta classe sendo assinalados a outras, principalmente à classe pastagem, com a qual apresentou a maior

confusão (21,87%), e à classe solo exposto (9,38%). Por sua vez, a maior confusão verificada para a classe pastagem foi com a classe solo exposto, com 8,51% dos pixels sendo assinalados erroneamente a esta última.

Observou-se ainda que as classes matocompetição, solo exposto e pastagem apresentaram, respectivamente, exatidão de 100%, 93,75% e 87,23% dos pixels corretamente classificados (Tabela 2). Estas foram as classes que apresentaram os melhores resultados.

Tabela 2 - Matriz de confusão da classificação, pelo coeficiente *Kappa*, pela rede MLP.

Imagem classificada	Imagem referência						
	Eucalipto	Mato-competição	Pastagem	Solo exposto	Total	Erro de omissão	Acurácia do usuário
Eucalipto	22	0	1	0	23	4,35%	95,65%
Matocompetição	0	5	1	1	7	28,57%	71,43%
Pastagem	7	0	41	0	48	14,58%	85,42%
Solo exposto	3	0	4	15	22	31,82%	68,18%
Total	32	5	47	16	100	-	-
Erro de comissão	31,25%	0%	12,77%	6,25%	-	-	-
Acurácia do produtor	68,75%	100%	87,23%	93,75%	-	-	-
Exatidão Global	55,90%	<i>Kappa</i>	74,32%	-	-	-	-

O desempenho da classificação supervisionada do uso da terra com o algoritmo MAXVER resultou em uma exatidão global de 90,00% e em um coeficiente *Kappa* de 0,8434, sendo considerada a qualidade da classificação com desempenho excelente. A classe que apresentou o maior erro na classificação foi a classe solo exposto, com 23,08% dos pixels que deveriam ser assinalados a esta classe, sendo assinalado na classe MC, a qual apresentou a

maior confusão (23,08%).

Observa-se também que a classe pastagem teve 8,77% dos seus pixels assinalados erroneamente à classe MC. Sendo assim, as classes eucalipto e MC apresentaram as melhores acurácias com 93,75% e 100%, respectivamente, dos pixels corretamente classificados (Tabela 3).

Assim, como para a rede MLP, a acurácia foi de 100% para a classe MC.

Tabela 3 - Matriz de confusão da classificação, pelo coeficiente *Kappa*, pelo algoritmo MAXVER.

Imagem classificada	Imagem referência						
	Eucalipto	Mato-competição	Pastagem	Solo exposto	Total	Erro de omissão	Acurácia do usuário
Eucalipto	15	0	1	0	16	6,25%	93,75%
Mato-competição	1	14	5	3	23	39,13%	60,87%
Pastagem	0	0	51	0	51	0%	100%
Solo exposto	0	0	0	10	10	0%	100%
Total	16	14	57	13	100	-	-
Erro de comissão	6,25%	0%	10,53%	23,08%	-	-	-
Acurácia do produtor	93,75%	100%	89,47%	76,92%	-	-	-
Exatidão Global	90,00%	<i>Kappa</i>	84,34%	-	-	-	-

O desempenho da classificação não supervisionada do uso da terra pelo algoritmo ISODATA resultou em uma exatidão global de 85,00% e em um coeficiente *Kappa* de 0,7359, sendo considerada a exatidão da classificação muito boa.

A classe que apresentou o maior erro na classificação foi a classe Pastagem, com 18,52% dos pixels que deveriam ser assinalados

a esta classe, sendo assinalados na classe solo exposto, em que foi obtida uma maior confusão (14,81%). Para a classe MC, obteve-se 8,33% dos seus pixels assinalados erroneamente na classe eucalipto e pastagem. Sendo assim, as classes solo exposto e eucalipto apresentaram as melhores acurácias com 88,89% e 89,47%, respectivamente, dos pixels corretamente classificados (Tabela 4).

Tabela 4 - Matriz de confusão da classificação, pelo coeficiente *Kappa*, pelo algoritmo ISODATA.

Imagem classificada	Imagem referência						
	Eucalipto	Mato-competição	Pastagem	Solo exposto	Total	Erro de omissão	Acurácia do usuário
Eucalipto	17	3	0	1	21	19,05%	80,95%
Matocompetição	2	30	1	0	33	9,09%	90,91%
Pastagem	0	3	22	1	26	15,38%	84,62%
Solo exposto	0	0	4	16	20	20,00%	80,00%
Total	19	36	27	18	100	-	-
Erro de comissão	10,53%	16,67%	18,52%	11,11%	-	-	-
Acurácia do produtor	89,47%	83,33%	81,48%	88,89%	-	-	-
Exatidão Global	85,00%	<i>Kappa</i>	73,59%	-	-	-	-

COMPARAÇÃO ENTRE OS CLASSIFICADORES

Um número considerável de trabalhos tem comparado o emprego de algoritmos para o reconhecimento de padrões em imagens orbitais (Benediktsson et al., 1990; Bischof et al., 1992; Civco, 1993) ou fotografias aéreas. De maneira geral, a utilização de redes neurais na classificação de dados de sensores remotos tem apresentado resultados melhores àqueles obtidos com os algoritmos MAXVER e ISODATA. Entretanto, quando se considera as classes, individualmente, para algumas classes a abordagem por redes neurais fornece maior exatidão, enquanto para outras os métodos convencionais são superiores. Este efeito resulta dos modelos estatísticos muito distintos

assumidos nos diferentes classificadores e do modo como eles dividem o espaço característico.

Dentre as classes avaliadas, a menor exatidão para a rede neural foi obtida para a classe eucalipto (68,75%), solo exposto (76,92%) para o classificador MAXVER e pastagem (81,48%) para o classificador ISODATA.

Por sua vez, a maior exatidão individual foi obtida para a classe matocompetição (100%) para a rede neural e o classificador MAXVER e a classe eucalipto (89,47%) para o classificador ISODATA.

Chagas et al. (2009) destacaram que a

abordagem por redes neurais requer mais tempo e mais recursos computacionais para treinar o sistema com as diferentes configurações de parâmetros testadas que a abordagem clássica, pelo algoritmo MAXVER.

Por outro lado, conforme Yool (1998), a abordagem por redes neurais leva vantagem sobre os métodos convencionais de classificação supervisionada, como o algoritmo MAXVER, por se mostrarem inadequados e ineficientes para o mapeamento de grandes áreas.

A classificação não-supervisionada, baseada em métodos de agrupamentos particionais, como o ISODATA, apesar de ser amplamente utilizada, apresenta algumas limitações.

Gonçalves et al. (2008) menciona que como o número de agrupamento ou classes, K , é conhecido a priori, na hipótese de se escolher um valor K' inadequado, o método irá impor, pelo uso de técnicas de otimização, K'

agrupamentos aos dados.

O usuário deve também especificar os parâmetros para controlar o processo de agrupamento, entre eles: os centroides iniciais de cada agrupamento, o número máximo de iterações, limiares para realizar a divisão, fusão ou exclusão de agrupamentos.

O ISODATA é muito influenciado por esses parâmetros, podendo gerar partições diferentes quando são feitas várias simulações para um mesmo conjunto de dados.

Outras limitações são: o alto custo computacional quando o conjunto de dados a ser analisado é muito grande (a cada iteração todos os pixels da imagem são comparados com todos os centros de agrupamentos) e a existência de suposições sobre a forma de agrupamentos.

O resultado da classificação final das imagens é apresentado na figura 1, na qual se verifica, visualmente, as classes mapeadas em relação à imagem referência.

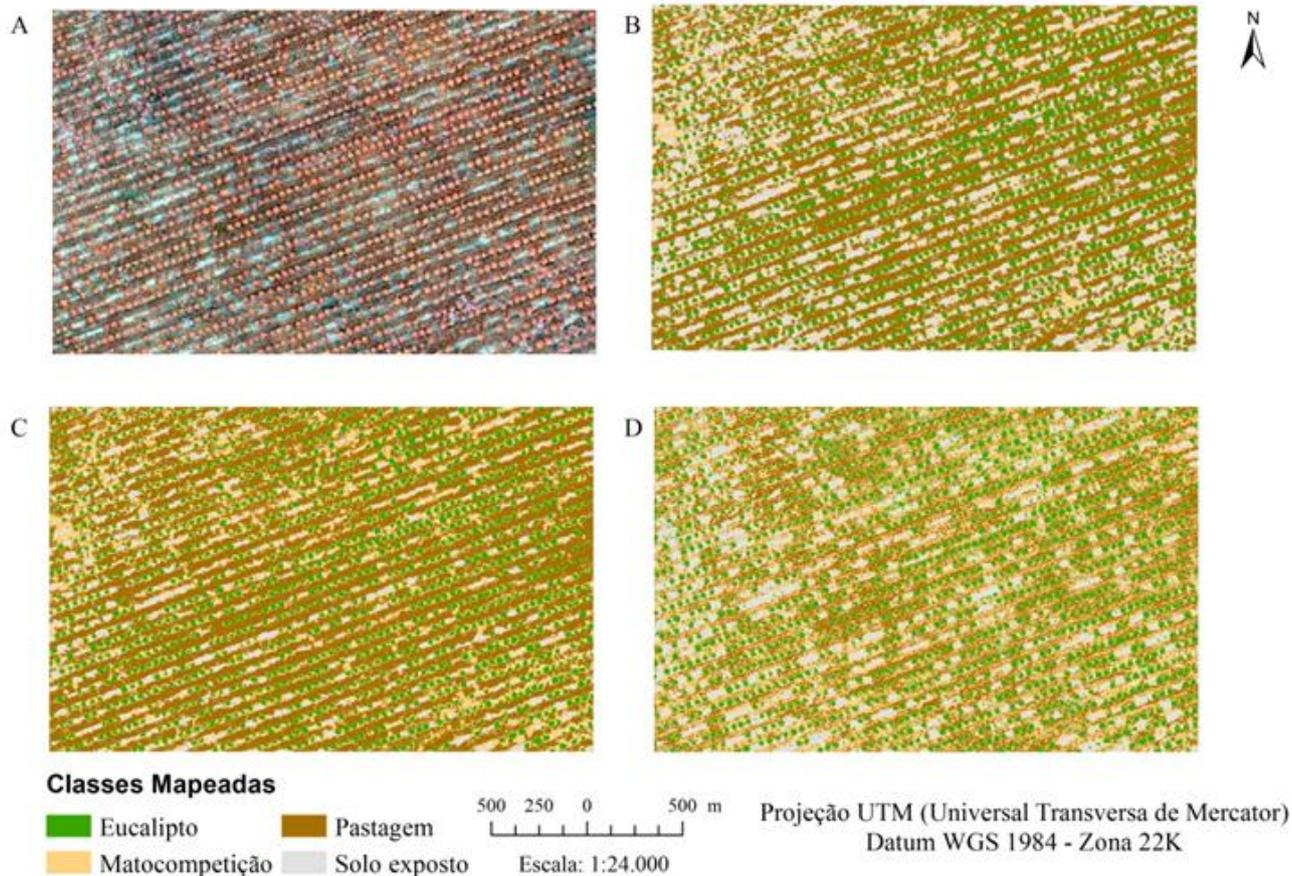


Figura 1 - Mapa de uso da terra classificado. (A) Imagem referência; (B) Redes Neurais Artificiais; (C) Algoritmo MAXVER; (D) Algoritmo ISODATA.

CONCLUSÕES

O algoritmo MAXVER obteve o melhor desempenho de classificação de acordo com o

coeficiente *Kappa*. Não houve uma tendência no erro de classificação nas classes mapeadas

entre os algoritmos testados. O maior erro para a rede MLP foi obtido na classe eucalipto, solo

exposto para o MAXVER e pastagem para o ISODATA.

AGRADECIMENTOS

Os autores agradecem à Eldorado Brasil pela disponibilidade da imagem VANT.

REFERÊNCIAS

- 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.
- BENEDIKTSSON, J. A.; SWAIN, P. H.; ERSOY, O. K. Neural network approaches versus statistical methods in classification of multisource remote sensing data. *Transactions on Geoscience and Remote Sensing*, v.28, p.540-552, 1990.
- BISCHOF, H.; SCHNEIDER, W.; PINZ, A. J. Multi-spectral classification of Landsat images using neural network. *Transactions on Geoscience and Remote Sensing*, v.30, p.482-490, 1992.
- CASTRO, A. A. M. & PRADO, P. P. L. Algoritmos para reconhecimento de padrões. *Revista Ciências Exatas*, v.5-8, p.129-145, 2002.
- CHAGAS, C. S.; VIEIRA, C. A. O.; FERNANDES FILHO, E. L.; JÚNIOR, C. W. Utilização de redes neurais artificiais na classificação de níveis de degradação em pastagens. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v.13, n.3, p.319-327, 2009.
- 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.
- CRUZ, N. C. & GALO, M. L. B. T. Aplicação de redes neurais artificiais na classificação de imagens multitemporais e multisensor. In: Colóquio Brasileiro de Ciências Geodésicas, 3. 2003, Curitiba. *Anais...* Curitiba: UFPR, 2003. CD-ROM.
- ERDAS. ERDAS Field Guide. Atlanta, Georgia: ERDAS, Inc. 2011. p. 225-290.
- GONÇALVES, M. L.; NETTO, M. L. A.; JÚNIOR ZULLO, J.; COSTA, J. A. F. Classificação não-supervisionada de imagens de sensores remotos utilizando redes neurais auto-organizáveis e métodos de agrupamentos hierárquicos. *Revista Brasileira de Cartografia*, n. XX/YY, 2008.
- HAYKIN, S. (Coord.). *Redes neurais: princípios e prática*. Porto Alegre: Bookman, 900p., 2001.
- IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. *Introdução ao processamento digital de imagens – Manuais Técnicos em Geociências n° 9*. Rio de Janeiro: IBGE, 2001. 94p.
- JENSEN, J. R. *Introductory Digital Image Processing - A Remote Sensing Perspective*. Prentice Hall, Inc., New Jersey, p. 197-256, 1996.
- JENSEN, J. R. *Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres*. Tradução: José Carlos Neves Epiphânio (Coord.) São José dos Campos: Parêntese, 2009.
- KAVZOGLU, T. & MATHER, P. M. The use o *backpropagation* artificial neural networks in land cover classification. *International Journal of Remote Sensing*, v.24, n.23, p.4907-4938, 2003.
- LANDIS, J. R. & KOCH, G. G. The measurement of observer agreement for categorical data. *Biometrics*, v. 33, n. 1, p. 159-174, 1977.
- MENESES, P. R. & ALMEIDA, T. (Coords). *Introdução ao Processamento de Imagens de Sensoriamento Remoto*. Brasília, Distrito Federal/ CNPQ, UnB, 266p., 2012.
- NEURODIC - BINOTI, D. H. B.; LEITE, H. G.; BINOTI, M. L. M. S. NeuroForest. 2012. Patente: Programa de Computador. Número do registro: 12859-4 título: "NeuroForest", Instituição de registro: INPI - Instituto Nacional da Propriedade Industrial. <http://neuroforest.ucoz.com/index/neurodic/0-11>.
- NOVO, E. M. L. M. *Sensoriamento remoto: Princípios e aplicações*. São Paulo: Edgard Blücher, 4ed. 2010.
- NOVO, E. M. L. M. *Sensoriamento Remoto: Princípios e Aplicações*. São Paulo: Edgard Blücher, 3ed. 2008. 363p.
- NOVO, E. M. L. M. *Sensoriamento remoto: princípios e aplicações*. São Paulo: Edgard Blücher, 1992.
- PIROLI, E. L. (Coord.). *Introdução ao geoprocessamento*. Ourinhos: Unesp/Campus Experimental de Ourinhos, 46p., 2010.
- RIBEIRO, E. J. C.; BAPTISTA, G. M. M.; BIAS, E. S. Comparação dos métodos de classificação supervisionada de imagem Máxima Verossimilhança e Redes Neurais em ambiente urbano. In: Simpósio Brasileiro de Sensoriamento Remoto, XIII, *Anais...* Florianópolis: INPE, 2007, p. 5471-5478.
- RICHARDS, J. A. & JIA, X. (Coords). *Remote Sensing Digital Image Analysis: An Introduction*. Australia: Springer - Verlag berlin Heidelberg, 439p., 2006.
- RIEDMILLER, M. & BRAUN, H. A direct adaptive method for faster *backpropagation* learning: the RPROP algorithm. *Proceedings of the International Joint Conference on Neural Networks*, San Francisco, Califórnia, USA, p. 586-591, 1993.
- RIPLEY, B. D. *Pattern recognition an neural networks* 4 ed. Cambridge: University Press. 2000. p. 287- 322.
- ROSA, R. *Introdução ao sensoriamento remoto*. Uberlândia: EDUFU, 2009.
- SILVA, I. V.; SPATTI, D. H.; FLAUZINO, R. A. (Coords). *Redes Neurais Artificiais: para engenharia e ciências aplicadas, curso prático*. Artliber: São Paulo, 399p., 2010.
- SKIDMORE, A.; TURNER, B. Assessing the accuracy of resource inventory maps. *Proceedings for Global Natural Resource Monitoring and Assessments: Preparing for the 21th Century*. Venice, v.2, p.524-535, 1989.
- STORY, M. & CONGALTON, R. G. Accuracy assessment: A user's perspective. *Photogrammetric Engineering and Remote Sensing*, v.61, p.391-401, 1986.
- TSO, B. & MATHER, P. M. (Coords). *Classification Methods for remotely sensed data*. New York: Taylor & Francis, 332 p., 2001.
- YOOL, S. R. Land cover classification in rugged areas using simulated moderate-resolution remote sensor data and an artificial neural network. *International Journal of Remote Sensing*, v.19, p.85-96, 1998.

Submetido em 10 de setembro de 2015
Aceito em 24 de novembro de 2016