

# Mapeamento de áreas cafeeiras utilizando redes neurais artificiais: Estudo de caso na região de Três Pontas, Minas Gerais

Tatiana Grossi Chquiloff Vieira<sup>1,2</sup>  
Wilian Soares Lacerda<sup>3</sup>  
Tiago Gonçalves Botelho<sup>1,2</sup>

<sup>1</sup>Empresa de Pesquisa Agropecuária de Minas Gerais - EPAMIG/CTSM  
Caixa Postal 76 - 37200-000 - Lavras - MG, Brasil  
{tatiana, tiago.botelho}@epamig.ufla.br

<sup>2</sup> Bolsista FAPEMIG

<sup>3</sup>Universidade Federal de Lavras – Departamento de Ciência da Computação  
Caixa Postal 3037 - 37200-000 - Lavras - MG, Brasil  
lacerda@dcc.ufla.br

**Abstract.** Coffee's spectral pattern is very similar to that of forest, making it more difficult to classify automatically these land use types. The use of artificial neural networks (ANN) in the classification of remotely sensed data is being considered promising in the discrimination of more complex classes of land use/land cover. The objective of this work is to evaluate the performance of a multilayer perceptron ANN to identify coffee lands in Landsat images. The work was carried out in a study area selected in the region of Três Pontas, state of Minas Gerais in Brazil. To validate the results, the land use and occupation map generated by visual classification was overlapped with the map generated by the ANN. In relation to the reference map, the kappa index of the ANN map was 46.66%, a moderate value. The results showed that the ANN methodology could be a good alternative to evaluate the ambiguity between coffee and forest lands and to identify which classes presented higher confusion.

**Key words:** remote sensing, artificial neural network, automatic classification, land use mapping, sensoriamento remoto, redes neurais artificiais, classificação automática, mapeamento, uso da terra.

## 1. Introdução

Nos últimos anos, com o aumento de satélites em órbita da Terra, o volume de dados coletados tornou-se muito grande e praticamente impossível de ser tratado por métodos convencionais de interpretação visual (Moreira, 2003). Isso, sem dúvida, foi o grande estímulo para que pesquisas relacionadas à classificação automática de imagens fossem intensificadas. A utilização de redes neurais artificiais (RNAs), com o propósito de classificação, pode constituir uma alternativa vantajosa quando comparada aos classificadores baseados em métodos estatísticos, uma vez que nenhuma hipótese prévia sobre a distribuição dos dados a serem classificados é exigida não restringindo a possibilidade de incorporação de dados não espectrais na classificação (Cruz e Galo, 2003).

As RNAs têm sido aplicadas com sucesso nas áreas de processamento de imagens e reconhecimento de padrões. A RNA usa elementos de computação não-linear (chamados neurônios) organizados como redes, de maneira análoga à que se acredita que os neurônios estejam interconectados no cérebro (Gonzales et al., 2000). No caso particular de aplicações em classificação de imagens de sensoriamento remoto, diversos trabalhos (Hepner, 1990; Benediktsson et al., 1990; Liu et al., 1991) fizeram uso de RNA, aplicando uma rede de perceptrons multicamadas (MLP) para resolver o problema de classificação. Este tipo de rede caracteriza-se por assumir regiões de decisão semelhantes àquelas formadas por um classificador estatístico, porém com entradas não correlacionadas e distribuições diferentes para os dados (Lippmann, 1987).

Nesse contexto, o objetivo deste trabalho é definir um procedimento de classificação automática utilizando redes neurais artificiais para identificação de áreas cafeeiras em

imagens de satélite. Foi aplicada uma RNA treinada para discriminar classes de uso da terra em Três Pontas, MG, na classificação de dados de sensoriamento remoto tomadas em três épocas distintas, pelo sensor TM/Landsat.

## 2. Redes neurais artificiais na classificação de imagens de satélite

Redes neurais artificiais consistem em um modo de abordar a solução de problemas de inteligência artificial. Representa um sistema de processamento de informação não algorítmico que, em algum nível, se assemelha à estrutura do cérebro humano, inspirada nos neurônios biológicos.

Uma RNA é formada por um conjunto de elementos processadores simples, uma rede de interconexão e uma regra de aprendizado, sendo o processamento feito de forma paralela por cada um dos nodos da rede. Estes sistemas são capazes de interagir com o meio exterior adaptando-se a novas situações, o que os tornam particularmente úteis em aplicações que necessitem tomadas de decisão em tempo real.

Segundo Brondino (1999), as RNAs são organizadas em camadas (Figura 1) que definem sua estrutura topológica ou sua arquitetura (maneira como os elementos de processamento são organizados). Assim sendo, existem redes neurais de camada simples (*perceptron*) constituídas por um grupo de neurônios arranjados em apenas uma camada, e as redes multicamadas, formadas por várias camadas escondidas ou pela combinação de várias redes de camadas simples. Nessa estrutura, a camada de entrada é aquela na qual os padrões são apresentados à rede; as camadas intermediárias (ou escondidas) são responsáveis por grande parte do processamento, podendo ser consideradas como extratoras de características; e a camada de saída é aquela onde o resultado final é concluído e apresentado.




Figura 1. Arquitetura de uma MLP

As redes do tipo MLP (*Multi Layer Perceptron*) têm sido utilizadas com sucesso para a solução de vários problemas envolvendo altos graus de não-linearidade. O algoritmo de aprendizado mais utilizado para o treinamento destas redes é o algoritmo retro-propagação (*backpropagation*) (Rumelhart et al., 1986 apud Picoli, 2006). Seu treinamento é do tipo supervisionado e é baseado numa regra de aprendizagem que “corrige” o erro durante o treinamento (Bocanegra, 2002). Na correção, o erro é retroalimentado através da rede e o ajuste do peso é feito usando um método recursivo.

Lippmann (1987) considera que o algoritmo *backpropagation* permite o ajuste de pesos em cada uma das camadas da rede, sendo projetado para minimizar a soma do erro quadrático entre a saída calculada por uma estrutura multicamadas e a desejada. Durante o treinamento, a intenção é que este erro diminua; para que isso ocorra, é necessário que os pesos sejam ajustados a cada iteração. Os primeiros pesos a serem ajustados são os da camada de saída, posteriormente os pesos das camadas anteriores serão ajustados sequencialmente.

### 3. Material e método

#### 3.1 Material

A área de estudo encontra-se na Região Sudeste, estado de Minas Gerais, no município de Três Pontas, MG. Posiciona-se geograficamente entre as coordenadas 21° 17' 10.10" a 21° 27' 57.44" de latitude sul e 45° 30' 4.69" a 45° 45' 3.33" de longitude oeste. Com uma área total de 510,84 km<sup>2</sup> (25,8 km sentido leste-oeste por 19,8 km no sentido norte-sul). A região possui declividade predominantemente suave ondulado, clima ameno e tropical de altitude.

Para realização da classificação automática com RNA foram utilizadas três imagens multiespectrais do satélite Landsat 5, sensor TM. As imagens possuem datas de passagem de: 16 de agosto de 2007, 24 de abril de 2008 e 17 de julho de 2008. As imagens adquiridas por este sensor referem-se às bandas 3 e 5, de cada data, sendo estas bandas as mais empregadas no mapeamento da cobertura do solo.

Neste trabalho foram utilizados os sistemas de informações geográficas SPRING (Câmara et al., 1996), versão 4.3.3 e o Idrisi (Clark, 2006).

#### 3.2 Pré-processamento dos dados

Para a realização da classificação, os dados de sensoriamento remoto foram submetidos aos pré-processamentos necessários para que a rede fosse capaz de reconhecer as mesmas classes nas imagens multiespectrais, ou seja: correção atmosférica, restauração e registro geométrico.

As imagens obtidas por sensores remotos são o produto de interações da radiação com a atmosfera e com a superfície. Na maioria das aplicações o alvo de interesse é a superfície e a interferência da atmosfera pode ser considerado como um ruído que atrapalha na obtenção de informações sobre os alvos de interesse. A fim de minimizar esse ruído foi realizada a correção atmosférica para as duas bandas espectrais de todas as imagens. Na realização da correção atmosférica foi utilizado o modelo 6S (*Second Simulation of Satellite Signal in the Solar Spectrum*).

As imagens originais, isto é, com pixel de 30 m x 30 m foram restauradas para imagens com pixels de 10 m x 10 m, conforme recomendações de Fonseca (1988). De acordo com a autora, a restauração é realizada por um filtro linear. A restauração permite que a imagem ampliada fique melhor visualmente para que fossem definidas as amostras de cada classe para o conjunto de treinamento da rede neural artificial.

Uma vez obtidas as imagens restauradas, estas foram georreferenciadas, para associar os *pixels* da imagem a uma coordenada geográfica. O georreferenciamento foi realizado utilizando a abordagem de vizinho mais próximo, para evitar que o interpolador interferisse nos resultados. Neste processo, foi tomada como referência para registro uma imagem já registrada da mesma área de estudo.

A restauração e o registro de imagens foram realizados no Sistema para Processamento de Informações Georreferenciadas (SPRING-INPE).

#### 3.3 Topologia e treinamento da rede neural artificial

As classes de saída foram definidas com base nas classes classificadas visualmente e foram compostas da seguinte forma: **café em produção**: lavouras com idade superior a três anos; **mata**: formações florestais densas e florestas de galeria às margens dos córregos; **água, área urbana**: área com grande concentração de construções e **outros usos**: áreas com café em formação (menor que três anos), áreas com culturas anuais em diversos estágios de desenvolvimento, pastagens e vegetação de brejo.

A obtenção das áreas de treinamento e validação foi realizada através da extração de áreas em formato de polígonos da imagem para cada classe a ser classificada. Para auxílio na

definição das amostras de treinamento foi utilizado um mapa temático de uso da terra da região selecionada classificada visualmente. Foram selecionadas entre 3 à 6 polígonos de tamanhos variados para cada classe. Após a aquisição das áreas de treinamento, foi realizada a assinatura espectral do conjunto de treinamento; utilizou-se o módulo Makesig do Idrisi. Os conjuntos de treinamento têm que ser definidos num plano de informação vetorial ou numa imagem raster e têm que possuir um identificador inteiro. Para que este módulo possa funcionar, têm que se indicar também todas as bandas que poderão ser usadas na classificação, sendo três imagens com duas bandas cada, totalizando seis imagens.

Após a realização da seleção e estudo das classes a serem classificadas, que trata da distribuição de cada elemento da imagem a uma das classes previamente selecionadas, foi definida uma arquitetura para a rede neural classificar as imagens. Esse procedimento foi executado utilizando o módulo de classificação por redes neurais artificiais do tipo *multi-layer perceptron*, do *software* Idrisi.

Segundo as considerações de Hush e Horne (1993) citados por Galo et al. (2000), e outros autores que descreveram os aspectos teóricos ou a aplicação de redes neurais artificiais na classificação de dados de sensoriamento remoto, e tendo em vista a abordagem de classificação supervisionada pretendida, foi adotado um modelo de rede neural com estrutura de múltiplas camadas, treinada com algoritmo *backpropagation*.

A definição da arquitetura de uma rede neural multicamadas implica na determinação prévia da dimensionalidade dos dados de entrada e das classes de ocorrência. O número de elementos da camada de saída foi definido com base no número de classes a serem classificadas na imagem, sendo cinco nós, com valores reconhecidos em virtude do conjunto de treinamentos estabelecidos nas amostras. Para dimensionar o número de camadas escondidas e o número de nós que constituem cada camada intermediária foram realizadas simulações com diferentes arquiteturas de redes neurais. Essas simulações constaram, na verdade, do treinamento e análise do desempenho da rede treinada sobre a análise do índice estatístico kappa, conforme descrito por Lands e Koch (1977), para cada arquitetura testada. Este índice é gerado pelo software após a classificação pelo módulo onde a rede neural está implementada. Ele avalia o índice kappa da classificação em relação ao conjunto de treinamento.

Para definição da arquitetura ideal para classificação foram realizados diversos testes, no qual foram realizadas as seguintes alterações na arquitetura da rede: número de camadas; número de neurônios nas camadas; número do conjunto de pixels para o conjunto de treinamento e teste; fator de *momentum* e taxa de aprendizado.

### **3.4 Processamentos pós-classificação**

Como existe um mapa classificado visualmente da área de estudo, foi realizado um cruzamento deste com o classificado pela rede neural artificial, com o objetivo de validar a classificação gerada pela rede neural. Para realização deste cruzamento foi utilizado a Linguagem Espacial para Geoprocessamento Algébrico (LEGAL), do SPRING. Para análise do desempenho da rede neural foram avaliadas três classes: Áreas de interseção (pixels de áreas de café classificadas igualmente pela rede neural e pelo método visual); Áreas de classificação errada pela RNA (pixels que a rede neural classificou como café, porém não é café); Áreas deixadas de classificar pela RNA (pixels que a rede neural classificou como sendo outra classe, mas é café).

A Figura 2 representa toda metodologia realizada para obter a classificação e a validação dos dados pela RNA.

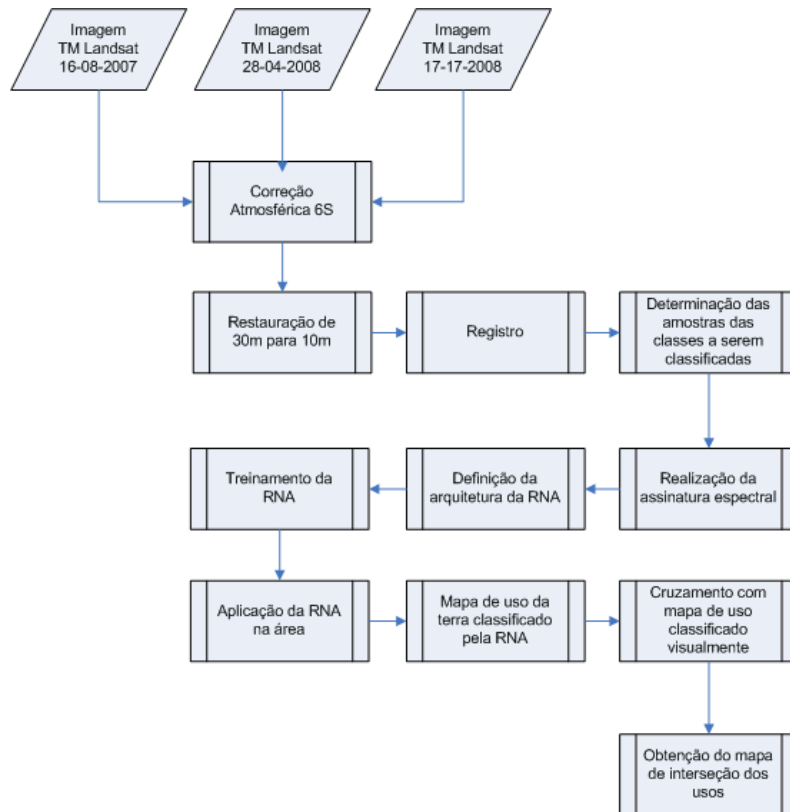


Figura 2. Fluxograma das atividades realizadas para realização da classificação e validação dos dados.

#### 4. Resultados

A RNA que apresentou melhor resultado foi uma rede com duas camadas escondidas, trinta neurônios na primeira, vinte e cinco na segunda camada e cinco neurônios na saída. Outros parâmetros definidos foram: um conjunto de sessenta pixels por categoria para o conjunto de teste e treinamento, taxa de aprendizado da rede de 0.02; fator de *momentum* de 0.53 para agilizar na convergência da rede; e constante de sigmóide de 1. Como critério de parada do treinamento da rede foi estabelecido erro médio quadrático (EMQ) de 0,0001 ou 10.000 iterações. A parada do treinamento da RNA aconteceu pelo número de iterações do algoritmo *backpropagation*, resultando em um valor de EMQ de 0,002084, para os dados de treinamento, e 0,003457 para os dados de teste. Na tentativa de obter um índice melhor para esta arquitetura, foram realizadas modificações nos parâmetros de aprendizado da rede, fator de *momentum* e o número de iterações, entretanto não foi observado melhoria no resultado.

A Tabela 1 demonstra as configurações utilizadas para teste na tentativa de obter a rede que melhor classifique a imagem.

Tabela 1. Configurações utilizadas para realização dos testes.

Configuração	Pixel <sup>1</sup>	Camadas escondidas	Neurônios		Taxa de aprendizado	Momentum	Iterações	EMQ	
			1ª Camada	2ª Camada				Trein.	Teste
1	65	2	30	22	0,02	0,53	10000	0,003440	0,004056
2	55	1	5	-	0,02	0,50	10000	0,004432	0,004886
3	60	2	25	30	0,01	0,53	10000	0,002168	0,003851
4	60	2	30	25	0,02	0,53	10000	0,002084	0,003457
5	60	2	21	11	0,01	0,50	10000	0,002876	0,003841

(<sup>1</sup> Número de pixels selecionados para o conjunto de treinamento e teste.)

Nos testes realizados com outras arquiteturas. Observou-se que aumentando o número de camadas, a rede produziu resultados melhores, com um número de neurônios da primeira camada superior aos da segunda camada.

A Figura 3 mostra o mapa de uso da terra obtido por classificação visual e conferido em campo. Esse mapa será utilizado como referência para avaliar a acurácia da classificação da RNA.

A cena classificada resultante da aplicação da arquitetura anterior da rede neural treinada é apresentada na Figura 4; segundo a análise da matriz de confusão da classificação gerada no Idrisi o índice kappa apresentado pela rede MLP em relação às amostras de treinamento foi de 92%.

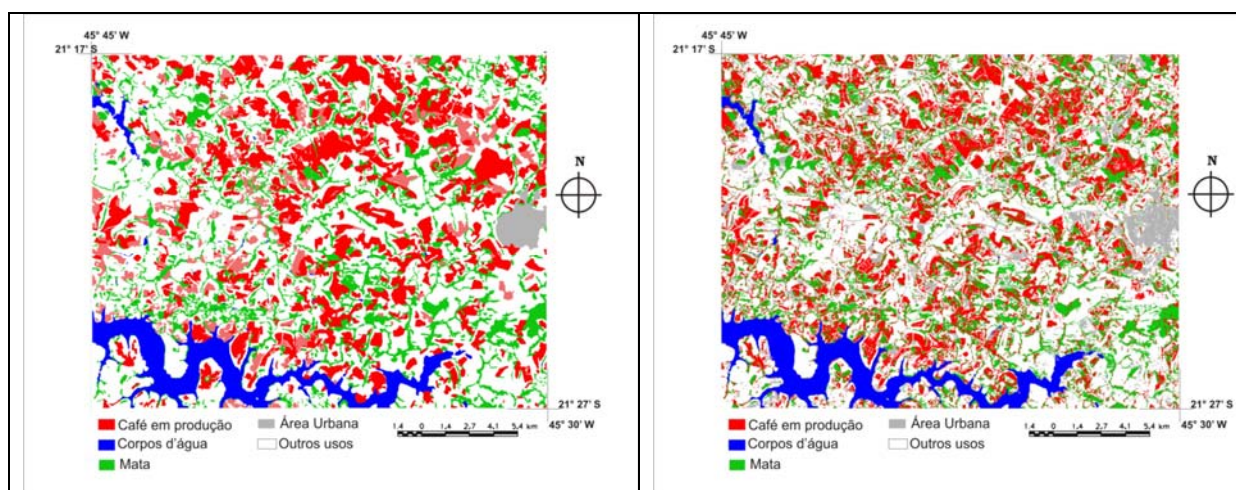


Figura 3. Mapa de uso da terra classificado visualmente. Figura 4. Mapa de uso da terra classificado pela RNA.

Em relação ao mapa de referência, o kappa do mapa classificado pela RNA ficou em 46,66%, o que, segundo Galparsoro e Fernández (2001) é um valor moderado. A matriz de confusão entre os mapas é apresentada na Tabela 2.

Tabela 2. Matriz de confusão entre os mapas de referência e o classificado pela RNA.

Plano-1 (nas linhas): Mapa de Referência – km <sup>2</sup>						
Plano-2 (nas colunas): Mapa Classificado – km <sup>2</sup>						
	<b>Café em Produção</b>	<b>Mata</b>	<b>Corpos D'água</b>	<b>Área Urbana</b>	<b>Outros Usos</b>	<b>Total</b>
<b>Café em Produção</b>	60.83	21.74	0.06	1.71	23.70	108.05
<b>Mata</b>	15.13	37.88	0.34	1.85	21.06	76.27
<b>Corpos D'água</b>	0.10	0.76	27.91	0.57	0.50	29.84
<b>Área Urbana</b>	0.10	0.09	0.00	5.08	0.90	6.17
<b>Outros Usos</b>	35.22	21.99	1.13	29.85	202.34	290.52
<b>Total</b>	111.38	82.46	29.44	39.06	248.50	510.84

O mapa de referência e o gerado pela classificação da RNA foram cruzados no SPRING, utilizando a Linguagem Espacial para Geoprocessamento Algébrico (LEGAL) (Figura 5). Deste cruzamento obteve-se que a área de café classificada corretamente pela RNA, totaliza 61,06 km<sup>2</sup>, ou 56,1% da área referente à cultura do café. A área em que a RNA classificou erroneamente como café totalizou 50,33 km<sup>2</sup>.




Figura 5. Mapa de cruzamento entre o mapa de referência e o classificado pela RNA.

## 5. Considerações finais

Neste trabalho, foi realizada a classificação de imagens de sensoriamento remoto por uma rede neural artificial (RNA) e seu resultado comparado com a classificação obtida por classificação visual.

O índice kappa obtido com a rede neural treinada e as amostras de treinamento foi de 92% indicando que a RNA conseguiu um bom índice de treinamento. A RNA que apresentou melhor resultado foi com duas camadas escondidas, trinta neurônios na primeira e vinte e cinco na segunda camada, taxa de aprendizado de 0,02 e fator de *momentum* de 0,53. Entretanto, o índice kappa do resultado obtido com a RNA treinada e os dados classificados visualmente foi de 46,66% o que corresponde a um índice moderado. Esse valor do índice de classificação por parte da rede neural pode ser devido aos fatores ambientais que interferem no padrão espectral da imagem decorrentes de variados estágios fenológicos e vigor vegetativo, espaçamento, culturas intercalares, tratos culturais e relevo acidentado causando sombra.

No caso da cultura cafeeira o reconhecimento de padrões por métodos automatizados é dificultado também pela similaridade do padrão espectral café/mata. Fragmentos de vegetação nativa como cerrado e mata densa são os que mais dificultam o desempenho dos algoritmos para interpretação automática de imagens. Uma possibilidade para melhorar a classificação por RNA seria a filtragem dos dados já classificados removendo as pequenas áreas (pixels soltos) classificadas, o que refinaria o mapa obtido por esta técnica.

## Agradecimentos

Os autores agradecem ao apoio da Fundação de Amparo à Pesquisa de Minas Gerais-FAPEMIG com recursos financeiros para o desenvolvimento do projeto e bolsas.

## Referências Bibliográficas

Benediktsson, J. A., Swain, P. H., Ersoy, O. K. Neural Network Approaches Versus Statistical Methods in Classification of Multisource Remote Sensing Data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 28, n. 4, p. 540-552, 1990.

Bocanegra, C.W.R. **Procedimentos para tornar mais Efetivo o Uso das Redes Neurais Artificiais em Planejamento de Transportes**. 2002, 146p. Dissertação (Mestrado em Engenharia Civil – Transportes) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos. 2003.

Brondino, N.C.M. **Estudo da Influência da Acessibilidade no Valor de Lotes Urbanos Através do Uso de Redes Neurais**. 1999, 97p. Dissertação (Doutorado em Engenharia Civil – Transportes) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos. 1999.

Câmara, G., R. C. M. Souza, U. M. Freitas e J. Garrido. SPRING: Integrating remote sensing and GIS by object-oriented data modelling. **Computers & Graphics**, v.20, n.3, May/June 1996, p.395-403. 1996.

Clark Labs, IDRISI Andes, v.15.00, Clark University, Worcester, 2006.

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.

Fonseca, L. M. G. **Restauração de imagens do satélite Landsat por meio de técnicas de projeto de filtros FIR**. 1988, 148p. Dissertação (Mestrado em Engenharia Eletrônica) - Instituto Tecnológico de Aeronáutica, São José dos Campos, 1988.

Galo, M. L. B. T.; Novo, E. M. L. M.; Galo, M. Ambigüidade entre classes de vegetação resultantes: Aplicação de uma rede neural artificial. In: Simpósio Latino Americano de Percepção Remota, 12., 2000, Puerto Iguazú, Misiones, Argentina **Anais...** Puerto Iguazú, p. 1043-1054.

Galparsoro, L. U. Fernández, S. P. **Medidas de concordância: el índice Kappa**. 2001. Disponível em: <<http://www.fisterra.com/mbe/investiga/kappa/kappa.htm>>. Acesso em: 01 nov. 2008

Gonzales, R. C.; Woods, R. E. **Processamento de Imagens Digitais**. São Paulo: Edgard Blücher Ltda., 2000. 527 p.

Hepner, G. F. Artificial Neural Networks Classification using a Minimal Training Set: Comparison to Conventional Supervised Classification. **Photogrammetric Engineering and Remote Sensing**, v. 56, n. 4, p. 469-473, 1990.

Lands, J. R.; Koch, G. G. The measurement of observer agreement for categorical data. **Biometrics**, Washington, v. 33, p. 159-154, 1977.

Lippmann, R. P.. An introduction to computing with neural nets. **IEEE ASSP Magazine**, v.4, p. 4-22, 1987.

Liu, Z. K., Xiao, J. Y. Classification of remotely-sensed image data using artificial neural networks. **International Journal of Remote Sensing**, v. 12, n. 11, p. 2433-2438, 1991.

Moreira, M. A.; **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 2 ed. - Viçosa: UFV, 2003. 307 p.

Picoli, M. C. A. **Estimativa da produtividade agrícola da cana-de-açúcar utilizando agregados de redes neurais artificiais: estudo de caso usina Catanduva**. 2006. 90p. (INPE-14669-TDI/1222). Dissertação (Mestrado em Sensoriamento Remoto), Instituto Nacional de Pesquisas Espaciais, São José dos Campos: INPE, 2006.

Rumelhart, D. E., Hinton, G. E.; Williams, R. J. Learning representations by backpropagation errors. **Nature**, v. 323, p. 533-536, 1986.

Rumelhart, D. E.; McClelland, J. L. **Parallel Distributed Processing: Explorations on the Microstructure of Cognition**, v.1, Cambridge: MIT Press, 1986.

Vieira, T. G. C.; Alves, H. M. R.; Lacerda M. P. C.; Veiga R. D.; Epiphany J. C. N. Crop parameters and spectral response of coffee (*Coffea arabica* L.) areas within the state of Minas Gerais, Brazil. **Coffee Science**, v.1, n.2, p.111-118. 2006.