

# *Rede neural artificial aplicada à agricultura*

## *Artificial neural network applied to agriculture*

---

Cibelle Degel Barbosa\*

As técnicas de bioinformática surgiram como uma importante ferramenta para estudos aplicados a diversas áreas da agricultura. Conjuntos de dados derivados de experimentos agrícolas podem ser analisados utilizando-se técnicas específicas de bioinformática, dentre elas as redes neurais artificiais. O presente trabalho tem por objetivo a apresentação da aplicação da técnica de bioinformática, denominada rede neural artificial, nas pesquisas voltadas para a agricultura.

Palavras-chave: Bioinformática. Modelos computacionais. Experimentos agrícolas.

*Bioinformatics techniques have emerged as a powerful tool to studies in various areas of Agriculture. Data sets derived from agricultural experiments can be analyzed using specific bioinformatics techniques, including artificial neural networks. This paper aims to present the application of a bioinformatics technique named artificial neural network, on research carried in Agriculture.*

*Key words: Bioinformatics. Computational models. Agricultural experiments.*

### ***Introdução***

A agricultura tem aprimorado suas metodologias em busca de mais eficiência aliada à redução de custos e impacto ambiental. Dessa forma, a informática se torna uma importante aliada e, atualmente, diversos sistemas permitem gerenciar o plantio, manejar a colheita e otimizar a distribuição dos produtos.

É crescente a necessidade de se viabilizarem soluções para o desenvolvimento sustentável do agronegócio brasileiro, por meio da geração, adaptação e transferência de conhecimentos e tecnologias de informação e de bioinformática, em benefício da sociedade.

A interação entre a biologia e a informática não é mais uma novidade, e atualmente vem passando por um impulso renovado. A biologia inspira vários modelos computacionais, dentre eles, as técnicas de bioinformática<sup>1</sup>.

\* Doutora em Produção Vegetal. Professora do Instituto Federal Fluminense.

<sup>1</sup> A bioinformática é uma técnica interdisciplinar que combina conhecimentos de química, física, biologia, computação, matemática e estatística no processamento de dados biológicos. Pode-se definir a bioinformática como a ciência da computação aplicada à pesquisa biológica, ou ainda como a análise matemática do conteúdo informacional dos genomas. Essa é uma área especialmente importante em pesquisas genômicas, em razão da complexidade dos dados gerados (BORÉM e MIRANDA, 2005).

Uma das técnicas de bioinformática mais utilizada é a rede neural artificial. Essa tecnologia se enquadra no contexto da agricultura em qualquer situação na qual se deseja prever algo ou reconhecer algum padrão. As redes neurais possibilitam prever, por exemplo, de forma bastante precisa, o comportamento de doenças e pragas, mediante análises de interação de dados climáticos (temperatura, umidade relativa do ar, precipitação, entre outros) e fitotécnicos (variedade, tipo de cultivo, região geográfica, entre outros) (RUGGIERO et al., 2003).

### ***Bioinformática***

Dentre outros, as técnicas de bioinformática, podemos citar as redes neurais artificiais, as máquinas de vetores de suporte, as cadeias escondidas de Makov, as árvores de decisão e os algoritmos genéticos.

No Brasil, a bioinformática foi utilizada de maneira sistemática e em larga escala pela primeira vez em 1997, no projeto de sequenciamento do genoma da bactéria *Xylella fastidiosa*, causadora da doença do amarelinho nos laranjais (SIMPSON et al., 2000).

As ferramentas de bioinformática conduzem ao aceleração dos programas de melhoramento genético, à redução do número de ciclos de seleção, ao direcionamento para a melhoria de caracteres qualitativos e quantitativos de interesse e ao aumento do ganho genético e redução dos custos, com a operacionalização dos esquemas de seleção de novos genótipos (VALOIS, 1998).

Pesquisas propõem a aplicação dessas técnicas nas áreas de modelagem matemática e simulação, para sua incorporação em processos com alto conteúdo tecnológico como previsão de safras, agroclimatologia, agricultura de precisão, sistemas especialistas para diagnósticos de pragas e doenças, entre outros (RUGGIERO et al., 2003).

### ***Rede neural artificial<sup>2</sup>***

As redes neurais artificiais possuem como características a tolerância a falhas, adaptabilidade a novas condições, resolução de problemas com base no conhecimento passado e reconhecimento de padrões (HAYKIN, 2001).

A solução de problemas através de redes neurais artificiais é bastante atrativa, já que a forma como estes são apresentados internamente pela rede cria a possibilidade de um desempenho superior ao dos modelos convencionais (BRAGA et al., 2000).

<sup>2</sup> Redes neurais artificiais são técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência (BRAGA et al., 2000). São compostas por unidades de processamento simples, que calculam determinadas funções matemáticas, denominadas neurônios ou nós. O neurônio é uma unidade de processamento de informação fundamental para operação de uma rede neural artificial. Pode-se dizer que redes neurais artificiais consistem em um modo de abordar a solução de problemas de inteligência artificial.

Segundo Galvão et al. (1999), em função de sua estrutura não-linear, as redes neurais artificiais conseguem captar características mais complexas dos dados, o que nem sempre é possível com a utilização das técnicas estatísticas tradicionais. Para Sudheer et al. (2003), a maior vantagem das redes neurais artificiais sobre os métodos convencionais é que elas não requerem informação detalhada sobre os processos físicos do sistema a ser modelado.

Na programação matemática ou otimização, a modelagem é feita pelo uso de relações lineares e/ou não-lineares. A modelagem em uma rede neural artificial é baseada em dados. Não existe a criação de restrições (BENITE, 2003).

Não se pode negar a utilidade dos modelos tradicionais, porém os mesmos apresentam características que geram dificuldades operacionais para sua efetiva aplicação, como o problema inerente em se trabalhar com modelos estatísticos complexos, suas hipóteses restritivas a serem satisfeitas e a dificuldade em se alcançarem conclusões e resultados por não especialistas (BENITE, 2003).

De acordo com Mohammadi e Prasanna (2003), existem dois tipos básicos de métodos de agrupamento: os métodos baseados em distâncias e os métodos baseados em modelos.

Nos métodos baseados em distâncias, uma matriz de distâncias entre pares de indivíduos é utilizada como entrada de dados, na análise realizada por meio de um algoritmo de agrupamento específico. Nos métodos baseados em modelos, se assume que as observações de cada grupo constituem amostras aleatórias de algum modelo paramétrico particular, aspecto característico das redes neurais artificiais.

Existem diversos tipos de redes neurais e diferentes maneiras de classificá-las. Talvez a mais importante seja quanto à forma de aprendizado, que pode ser: supervisionado e não supervisionado.

No aprendizado supervisionado, são sucessivamente apresentados à rede conjuntos de padrões de entrada e seus correspondentes padrões de saída. Durante este processo, a rede realiza um ajustamento dos pesos das conexões entre os elementos de processamento, segundo uma determinada lei de aprendizagem, até que o erro entre os padrões de saída gerados pela rede alcance um valor mínimo desejado (BRAGA et al., 2000). Por exemplo, Perceptrons, Adaline e Madaline, Redes de Função de Base Radial, são algumas dentre as dezenas de redes com métodos de aprendizado supervisionado.

No aprendizado não supervisionado a rede “analisa” os conjuntos de dados apresentados, determina algumas propriedades dos conjuntos de dados e “aprende” a refletir estas propriedades na sua saída. A rede utiliza padrões, regularidades e correlações para agrupar os conjuntos de dados em classes. As propriedades que a rede vai “aprender” sobre os dados podem variar em função do tipo de arquitetura utilizada e da lei de aprendizagem (BRAGA et al., 2000). Por exemplo, Mapa Auto-Organizável de Kohonen, Redes de Hopfield e Memória Associativa Bidirecional são redes com métodos de aprendizado não supervisionado.

## *Metodologia*

Muitos são os modelos de redes neurais artificiais, porém o modelo introduzido por Kohonen (1982), conhecido como Mapa Auto-Organizável de Kohonen, possui a vantagem de não exigir do pesquisador a aplicação de nenhuma teoria acerca da organização destes dados, e pode fornecer subsídios para a atualização ou mesmo formulação de novas teorias acerca do problema.

Comumente usado em problemas relacionados a agrupamentos de dados, essa rede neural propõe uma classificação para os dados de entrada com base na similaridade dos mesmos.

O modelo de Kohonen é uma rede de duas camadas que pode organizar os dados de entrada a partir de um início aleatório. O cenário resultante mostra os relacionamentos naturais entre os padrões que são fornecidos à rede. Esta combina uma camada de entrada com uma camada competitiva de unidades processadoras e é treinada pelo algoritmo de aprendizagem não supervisionada (HAYKIN, 2001).

Os padrões apresentados à rede neural são classificados pelas unidades que eles ativam na camada competitiva. Similaridades entre os padrões são mapeadas em relacionamentos de proximidades sobre a grade da camada competitiva. Depois que o treino está completo, os relacionamentos e agrupamentos entre os padrões são observados na camada competitiva. O modelo de Kohonen fornece vantagens sobre as técnicas clássicas de reconhecimento de padrões porque utiliza a arquitetura paralela de uma rede neural artificial (KOVACS, 1997).

A metodologia aqui apresentada é baseada nos conceitos propostos por Haykin (2001) e representa a abordagem tradicional do modelo de Kohonen.

A rede neural artificial é composta por uma matriz de entrada  $n \times m$ , sendo  $n$  genótipos e  $m$  elementos de entrada ou caracteres, que juntos representam o vetor de entrada  $X$ , e por  $k$  neurônios de saída, representando as classes que os genótipos podem ser agrupados. Como exemplo, foram definidos:  $n = 37$  genótipos,  $m = 8$  caracteres e  $k = 4$  classes.

A definição do número de grupos é um procedimento aleatório, cabendo ao melhorista, com base em históricos e técnicas afins, a identificação do número ótimo de grupos.

Dada uma entrada, somente um neurônio de saída deve ser ativado, registrando assim, a classe à qual o genótipo pertence. As classes devem agrupar genótipos com características semelhantes. Desta forma, é feita uma classificação por similaridade de valores.

O processo consiste em encontrar o neurônio com o melhor casamento por similaridade (vencedor)  $i(X)$ , no passo de tempo  $t$ , usando o critério da mínima distância entre os genótipos.

Um padrão de entrada para a rede neural é denotado da seguinte forma:

$$X_n = [x_{n1}, x_{n2}, \dots, x_{n8}], n = 1, 2, \dots, 37$$

Considera-se que o vetor de peso sináptico representa o indivíduo característico do grupo formado e é definido de forma aleatória, com base nos dados de entrada. O vetor de peso sináptico é representado por:

$$W_k = [w_{k1}, w_{k2}, \dots, w_{k8}], k = 1, 2, 3, 4$$

O vetor de peso sináptico é o critério para aceitação ou rejeição do agrupamento de um genótipo ou indivíduo.

A medição da similaridade entre a entrada e o neurônio é realizada através da distância Euclidiana média entre os vetores  $X_n$  e  $W_k$ , e é calculada por:

$$\sqrt{\frac{1}{m} \sum_{j=1}^m (x_{nj} - w_{kj})^2}$$

A unidade da camada de saída com a menor distância Euclidiana média vence a competição. Ao se usar o índice  $i(X)$  para identificar o neurônio com maior similaridade com o vetor  $X_n$  que é apresentado à rede no momento,  $i(X)$  é tal que:

$$i(X) = \arg \min_k \|X_n - W_k\|$$

Posteriormente, é realizado o ajuste dos vetores de pesos sinápticos dos neurônios, de acordo com a fórmula de atualização exposta a seguir.

Dado o vetor de peso sináptico  $W_k(t)$  do neurônio  $k$  no tempo  $t$ , o vetor de peso atualizado  $W_k(t+1)$  no tempo  $t+1$  é definido por (KOHONEN, 1982):

$$W_k(t+1) = W_k(t) + \eta(t)(X_n - W_k(t))$$

que é aplicado ao neurônio vencedor  $i$ , onde  $\zeta(t)$  é o parâmetro da taxa de aprendizado e deve ser variável no tempo, iniciado com um valor próximo a 0,1, devendo decrescer gradualmente, mas permanecendo acima de 0,01. A taxa de aprendizado determina a velocidade com a qual a rede se estabiliza.

Ao término do processo, dado um conjunto de genótipos com suas características, a rede neural artificial irá propor uma classificação com base na similaridade de valores.

## ***Trabalhos Relacionados***

A agricultura de precisão pode ser considerada como a habilidade em se monitorar e acessar a atividade agrícola em nível local, com o objetivo de aumentar a eficiência do processo produtivo (QUEIROZ et al., 2000).

Uma das estratégias mais simples, embora pouco precisa, para programar irrigações é utilizar a média da evapotranspiração de referência, de uma série histórica de dados climáticos, através do método de balanço de água no solo. Com isso, é possível gerar um calendário de irrigações, com as respectivas datas e lâminas de água a serem aplicadas durante o ciclo da cultura. Resende e Oliveira (2010) desenvolveram um trabalho com o objetivo de aumentar a precisão desse método, utilizando-se redes neurais artificiais para ajustar e prever a evapotranspiração de referência diária, obtendo sucesso.

Em Moreira e Cecílio (2008) foram desenvolvidas redes neurais artificiais para estimativa mensal e anual das temperaturas mínima, média e máxima do ar, na região Nordeste do Brasil. Em geral, as redes neurais artificiais desenvolvidas possibilitaram maior acurácia na estimativa das temperaturas do ar em comparação com as equações de regressão encontradas na literatura especializada.

A aplicação de redes neurais artificiais na tarefa de previsão da produção de álcool no Brasil, no ano de 2006, a partir de dados de produção anteriores, foi apresentada em Oliveira et al. (2010). Foi também apresentada uma comparação entre os resultados obtidos por meio da rede neural artificial com os obtidos utilizando-se técnicas de séries temporais, sendo que a rede neural artificial obteve melhores resultados.

O processamento e análise de imagens na área agrícola, através do sensoriamento remoto, tem sido de fundamental importância em vários aspectos. Por exemplo, imagens coletadas por sensores localizados em satélites permitem a identificação de solos degradados, áreas alagadas, identificação de culturas, planejamento agrícola, auxiliando na preservação ambiental e em muitas outras atividades.

A análise de imagens, além do sensoriamento remoto, também é usada para quantificar doenças e raízes de plantas, identificação e seleção de grãos, cálculo de área foliar de uma cultura, entre outras.

A quantificação das classes de uso do solo, obtida pela classificação das imagens de satélite permite uma política mais racional de planejamento territorial, urbano e ambiental. Em França (2010) foi realizada uma classificação com a utilização de redes neurais artificiais, com índices de exatidão global satisfatórios.

Vieira et al. (2009) apresentaram um trabalho cujo objetivo foi definir um procedimento de classificação automática, utilizando redes neurais artificiais, para identificação de áreas cafeeiras em imagens de satélite. Foi aplicada uma rede neural artificial treinada para discriminar classes de uso da terra na classificação de dados de sensoriamento remoto.

Chagas et al. (2009) avaliaram a eficiência de redes neurais artificiais na

classificação do uso da terra, a partir de imagens de um sensor, com ênfase nos níveis de degradação das pastagens.

A utilização de imagens aéreas, obtidas à baixa altura, para o mapeamento da infestação de plantas invasoras em cultura de soja, foi realizada por Neto et al. (2005), utilizando a classificação digital de imagens realizada por redes neurais. A foto foi classificada segundo as classes temáticas “cultura”, “invasora” e “entrelinha”.

Silva et al. (2005) utilizaram o processamento digital de imagens, associado às técnicas multivariadas e redes neurais artificiais, como ferramentas de apoio para melhor identificação dos estágios iniciais do desenvolvimento da Sigatoka Negra.

A variabilidade genética pode ser conceituada como quaisquer diferenças entre espécies ou indivíduos dentro da espécie. O conhecimento da divergência genética entre um grupo de parentais é importante no melhoramento genético vegetal, sobretudo para identificar combinações híbridas de maior efeito heterótico (CARVALHO et al., 2003). As combinações híbridas de maior efeito heterótico aumentam a probabilidade de se recuperarem genótipos superiores nas gerações segregantes.

Na predição da divergência genética, vários métodos multivariados podem ser aplicados. Dentre eles, as redes neurais artificiais, que auxiliam os estudos da variabilidade genética presentes nas populações. Cabe ao melhorista avaliar o potencial dessas técnicas para o seu programa de melhoramento genético e adaptar aquelas, dentro de suas limitações de recursos, que contribuem para o aumento da produtividade e da eficiência.

Em Plotze (2004) espécies vegetais foram classificadas, identificando divergência genética, utilizando a rede neural artificial como técnica de reconhecimento de padrões e agrupamento.

O processo de automação pode contribuir na atividade agrícola através da melhora de qualidade do processo, redução de perdas ou riscos, aumento de produtividade, melhor controle de custos e aumento do retorno de investimento, planejamento do negócio e proteção do meio-ambiente, proporcionando uma maior competitividade.

A robótica, ou máquinas computadorizadas para executar atividades específicas sem a interferência humana, tem sido objeto de estudo na área agrícola. O desenvolvimento de um sistema adequado de sensores, em conjunto com a técnica de redes neurais artificiais, capaz de reconhecer estágios de amadurecimento de frutos, permite que robôs sejam capazes, por exemplo, de colher frutas individualmente de acordo com seu tamanho e estágio de amadurecimento. Isso possibilitaria eliminar a fase de seleção, e a fase de embalagem e empacotamento poderia ser realizada logo após a colheita.

Nos estudos genômicos, a bioinformática consiste principalmente na análise computacional de sequências de DNA, RNA e proteínas. Aplica-se em função da necessidade de ferramentas sofisticadas para analisar o crescente volume de dados gerado na biologia molecular.

As ciências ômicas tratam da análise global dos sistemas biológicos, integrando diferentes áreas do conhecimento, como a bioquímica, genética, fisiologia e computação, com o objetivo de isolar e caracterizar genes, proteínas e metabólitos, assim como estudar as interações entre eles, com base em técnicas experimentais, *softwares* e bancos de dados. Espindola et al. (2010) apresentam uma revisão cujo objetivo foi realizar uma abordagem dos recursos de bioinformática aplicados às ciências ômicas.

### ***Considerações Finais***

A informatização do meio rural é uma evolução inevitável. Esse processo iniciou-se com os métodos administrativos e de comercialização, porém atualmente, o uso de técnicas de inteligência artificial proporciona ao agronegócio a tomada de decisão, com base em procedimentos matemáticos e de simulação computacional. Cada vez mais a manipulação de grandes quantidades de dados só se torna possível através do uso de métodos e recursos computacionais.

### ***Referências***

- BENITE, M. *Aplicação de modelos de redes neurais na elaboração e análise de cenários macroeconômicos*. São Paulo, 2003. 123p. Dissertação (Mestrado em Engenharia) - Universidade de São Paulo, Escola de Engenharia de São Carlos, 2003.
- BORÉM, A.; MIRANDA, G. V. *Melhoramento de Plantas*. Viçosa: UFV, 2005. 525 p.
- BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B. *Redes neurais artificiais: teoria e aplicações*. Rio de Janeiro: LTC, 2000. v. 1. 250 p.
- CARVALHO, L. P. DE; LANZA, M. A.; FALLIERI, J.; SANTOS, J. W. DOS. Análise da diversidade genética entre acessos de banco ativo de germoplasma de algodão. *Pesquisa Agropecuária Brasileira*, Brasília, v. 38, n. 10, p. 1149-1155, 2003.
- CHAGAS, C. DA S.; VIEIRA, C. A. O.; FERNANDES FILHO, E. I.; CARVALHO JUNIOR, 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.
- ESPINOLA, F. et al. Recursos de bioinformática aplicados às ciências ômicas como genômica, transcriptômica, proteômica, interatômica e metabolômica. *Bioscience Journal*, América do Norte, v. 26, n. 3, p. 463-477, 2010.
- FRANÇA, M. M. Análise do uso da terra no município de Viçosa-MG mediado por classificações supervisionadas com redes neurais artificiais e Maxver. *Revista Brasileira de Geografia Física*, América do Norte, v. 2, n. 3, p. 92-101, 2010.

GALVÃO, C. O.; VALENÇA, M. J. S.; VIEIRA, V. P. P. B.; DINIZ, L. S.; LACERDA, E. G. M.; CARVALHO, A. C. P. L. F.; LUDERMIR, T. B. *Sistemas inteligentes: Aplicações a recursos hídricos e ciências ambientais*. Porto Alegre: UFRGS/ABRH, 1999. 246p.

HAYKIN, S. *Redes neurais: princípios e prática*. Porto Alegre: Bookman, 2001. 900 p.

KOHONEN, T. Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, Germany, v. 43, p. 59-69, 1982.

KOVACS, Z. L. *Redes neurais artificiais: fundamentos e aplicações*. São Paulo: Collegium Cognition, 1997. 174 p.

MOHAMMADI, S. A.; PRASANNA, B. M. Analysis of genetic diversity in crop plants: salient statistical tools and considerations. *Crop Science*, v. 432, p. 1235-1248, 2003.

MOREIRA, M. C.; CECÍLIO, R. A. Estimativa das temperaturas do ar utilizando redes neurais artificiais, para a região Nordeste do Brasil. *Revista Brasileira de Agrometeorologia*, v. 16, n. 2, p. 181-188, 2008.

NETO, O. C. P.; JORGE, L. A. DE C.; GUIMARÃES, M. DE F. Quantificação de plantas daninhas em soja através de classificador digital por redes neurais. In: CONGRESSO BRASILEIRO DE AGROINFORMÁTICA, 5., 2005, Londrina. SBI-AGRO, 2005. v. 1.

OLIVEIRA, A. C. S. DE; SOUZA, A. A. DE; LACERDA, W. S.; GONSALVES, L. R. Aplicação de redes neurais artificiais na previsão da produção de álcool. *Ciência e Agrotecnologia*, Lavras, v. 34, n. 2, p. 279-284, 2010.

PLOTZE, R. O. *Identificação de espécies vegetais através da análise da forma interna de órgãos foliares*. São Paulo, 2004. 152p. Dissertação (Mestrado em Ciências de Computação e Matemática Computacional) - Universidade de São Paulo, Instituto de Ciências Matemáticas e de Computação, 2004.

QUEIROZ, D. M.; DIAS, G. P., MANTOVANI, E. C. Agricultura de precisão na produção de grãos. In: BORÉM, A.; GIUDICE, M. P.; QUEIROZ, D. M.; MANTOVANI, E. C.; FERREIRA, L. R.; VALLE, F. X. R.; GOMIDE, R. L. (Eds.) *Agricultura de Precisão*. Viçosa: UFV, 2000. p. 1-41.

RESENDE, M.; OLIVEIRA, A. Comparação de diferentes estratégias de programação de irrigação suplementar em milho. *Revista Brasileira de Milho e Sorgo*, América do Norte, v. 4, 2010.

RUGGIERO, C.; DURIGAN, J. F.; GOES, A. DE; NATALE, W.; BENASSI, A. C. Panorama da cultura do mamão no Brasil e no mundo: situação atual e tendências. In: MARTINS, D. DOS S. (Ed.) *Papaya Brasil: qualidade do mamão para o mercado interno*. Vitória: Incaper, 2003. p. 13-34.

SILVA, S. H. M. G. DA; MORAES, W.; MARQUE, E. S. H.; JORGE, L. A. DE C. Processamento digital de imagens para identificação da Sigatoka Negra. In: CONGRESSO BRASILEIRO DE AGROINFORMÁTICA, 5.. 2005, Londrina. SBI-AGRO, 2005. v. 1.

SIMPSON, A. J.; REINACH, F. C.; ARRUDA, P.; ABREU, F. A.; ACENCIO, M.; ALVARENGA, R.; ALVES, L. M. et al. The genome sequence of the plant pathogen *Xylella fastidiosa*. *Nature*, v. 406, p. 151-157, 2000.

SUDHEER, K. P.; GOSAIN, A. K.; RAMASASTRI, K. S. Estimating actual evapotranspiration from limited climatic data using neural computing technique. *Journal of Irrigation and Drainage Engineering*, v. 129, n. 3, p. 214-218, 2003.

VALOIS, A. C. C. Biodiversidade, biotecnologia e propriedade intelectual. *Cadernos de Ciência & Tecnologia*, Brasília, v. 15, p. 21-31, 1998.

VIEIRA, T. G. C.; LACERDA, W. S.; BOTELHO, T. G. Mapeamento de áreas cafeeiras utilizando redes neurais artificiais: Estudo de caso na região de Três Pontas, Minas Gerais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009, Natal. INPE, 2009. p. 7947-7954.

*Artigo recebido em: 27 abr. 2011*

*Aceito para publicação em: 21 jul. 2011*