

O USO DE REDES NEURAS ARTIFICIAIS NA ANÁLISE DA AMBIGÜIDADE ENTRE CLASSES DE ÁGUA E PLANTAS AQUÁTICAS

*The use of artificial neural network in the ambiguity analysis between classes
defined by water spectral variability and aquatic plants*

MIRIAM CRISTINA ESPINHOSA¹
MARIA DE LOURDES BUENO TRINDADE GALO²

Universidade Estadual Paulista
Faculdade de Ciências e Tecnologia

¹ Programa de Pós Graduação em Ciências Cartográficas

² Departamento de Cartografia

R: Roberto Simonsen 305, CEP: 19060-900, Presidente Prudente, SP.
e-mail: mce@prudente.unesp.br, mlourdes@prudente.unesp.br

RESUMO

A aplicação de Redes Neurais Artificiais (RNA) na classificação de dados de Sensoriamento Remoto tem se mostrado uma abordagem promissora na discriminação de classes de maior complexidade. Uma RNA foi, então, utilizada para desenvolver uma análise da ambigüidade entre classes definidas em função das variações espectrais da água e ocorrência de plantas aquáticas emersas em uma área teste do reservatório de Barra Bonita, SP. Os dados de entrada utilizados na classificação constituíram-se de imagens orbitais ETM+/Landsat, às quais foi aplicado um modelo linear de mistura espectral, gerando imagens-fração correspondentes de água, vegetação e solo. No processo de classificação, uma RNA multicamadas *feedforward* foi treinada com o algoritmo *backpropagation*, a partir de amostras representativas das áreas infestadas por plantas aquáticas e variações na resposta espectral da água. O procedimento metodológico adotado mostrou-se adequado para o mapeamento das classes de água e macrófitas aquáticas. O resultado da classificação pela rede neural atendeu a proposta de avaliar a ambigüidade entre as classes e permitiu explicitar quais classes de saída apresentavam maior grau de mistura com outras ocorrências.

Palavras chave: Redes Neurais Artificiais, Classificação de Imagens, Ambigüidade entre classes.

ABSTRACT

Artificial Neural Networks (ANN) represent a potential approach for classification of remote sensing images, since they can form complex decision regions and separate meshed class. So, an ANN was used to develop an ambiguity analysis between classes defined by water spectral variability and aquatic plants infestation in a test area of the Barra Bonita, SP, reservoir. The classification input data was constituted by images derived from a linear mixing model applied to ETM+/Landsat spectral bands. In order to undertake a supervised classification, a multilayer neural net was trained by backpropagation algorithm, using representative samples extracted from aquatic plants infestation areas and water body spectral variability. The approach was adequate for mapping water spectral variability and detect infested areas by aquatic macrophytes. Additionally, the classification obtained by neural net can be used for the purpose to evaluate meshed classes allowing to represent more ambiguous classes in test area.

Keywords: Artificial Neural Network, Image Classification, Classes Ambiguity.

1 INTRODUÇÃO

No Brasil, lagos e rios são importantes no fornecimento de água e suporte a sistemas de produção agrícola e industrial, assim como para o consumo humano, navegação, irrigação e geração de energia elétrica. No entanto, décadas de desmatamento indiscriminado e uso inadequado da terra estimularam o carregamento de material sedimentável e nutrientes para o leito dos rios e reservatórios. Além disso, o carregamento de parte dos fertilizantes utilizados em culturas agrícolas e a grande carga de esgotos residenciais e industriais têm levado cursos e reservatórios de água, naturais ou artificiais, a uma condição de desequilíbrio caracterizada pela grande disponibilidade de nutrientes que acelera o crescimento de vegetação aquática indesejável (CAVENAGHI, 2003).

O Sensoriamento Remoto pode se constituir em uma ferramenta útil para mapear a ocorrência dessas plantas aquáticas, avaliar a evolução das comunidades e subsidiar estimativas do potencial atual e futuro de danos destas populações ao meio ambiente e à utilização da água para suas várias finalidades, especialmente para a geração de energia elétrica. A identificação de focos iniciais de plantas de alto risco para a produção de energia elétrica é bastante importante na tomada de decisões quanto à erradicação ou não destes focos.

O uso de mapas na investigação de fenômenos ecológicos, ambientais e geográficos tem se popularizado, principalmente graças ao desenvolvimento dos sistemas de cartografia computadorizada. Essa tecnologia, em conjunto com outras ferramentas, tem contribuído para uma mudança na abordagem tradicional de mapeamento, na qual o mapa era o produto final de um processo projetado para

representar um padrão espacial através de símbolos, delimitações de classes, etc., na direção de uma abordagem mais analítica, baseada nas necessidades de informação do usuário (DEMERS, 1997).

Nesse contexto, um dos aspectos básicos da aplicação do Sensoriamento Remoto em mapeamentos temáticos é a definição de um sistema de classificação que seja adequado ao estudo que se pretende desenvolver. Normalmente, os procedimentos de classificação automática apresentam limitações decorrentes principalmente da resolução das imagens orbitais, da ocorrência de *pixels* misturados e da ambigüidade das classes, os quais podem resultar em mapeamentos pouco exatos. Uma maneira de avaliar o problema da classificação de *pixels* misturados é o uso de modelos que descrevam o fenômeno da mistura espectral e separem as contribuições de cada material dentro do *pixel*, uma vez, que a radiação captada por um sistema sensor resulta da mistura de materiais diferentes acrescida da contribuição da atmosfera (GALO, 2000b).

No que se refere à classificação de dados de Sensoriamento Remoto, a utilização de Redes Neurais Artificiais (RNA) tem se apresentado como uma alternativa promissora em relação aos classificadores baseados em conceitos estatísticos, uma vez que nenhuma hipótese prévia sobre a distribuição dos dados a serem classificados é exigida (BENEDIKTSSON *et al*,1990), e face à maior flexibilidade que esses modelos possuem quanto à entrada de dados para a classificação. Uma outra questão relevante na classificação dos dados orbitais por RNA é a possibilidade de representação da ambigüidade nas classes, onde um único *pixel* pode ser associado a mais de uma classe com diferentes graus de pertinência (grau de inclusão de um elemento num conjunto). Esses graus de pertinência associados a cada classe podem ser avaliados pelos valores de ativação calculados para cada elemento de processamento da camada de saída da rede (GALO *et al*, 2002).

Sendo assim, o objetivo do trabalho é verificar o potencial da aplicação de Redes Neurais Artificiais na classificação de áreas de infestação por plantas aquáticas emersas e variações de água, e analisar a ambigüidade entre as classes de saída com características similares, através de planos de informações gerados individualmente a partir dos valores de ativação fornecidos pela rede e pela tabulação cruzada desses planos.

2 ASPECTOS TEÓRICOS DO SENSORIAMENTO REMOTO

Os elementos da superfície terrestre podem ser investigados através de imagens que registrem as interações entre a radiação eletromagnética e os diferentes constituintes do planeta, sendo analisadas através de técnicas e ferramentas específicas. Nesse contexto, o Sensoriamento Remoto tem se mostrado uma ferramenta importante na análise das características do meio ambiente, no qual a coleta de dados ocorre sem perturbar o ambiente ao redor.

De acordo com Moreira (2001), a radiação eletromagnética (REM) interage com os alvos da superfície terrestre podendo ser absorvida, refletida, transmitida e emitida seletivamente. Com o desenvolvimento tecnológico atual, é possível medir com razoável precisão e à distância, as propriedades espectrais desses alvos. O uso de sistemas sensores em nível orbital, para obtenção de dados da radiação refletida e/ou emitida pelos alvos da superfície terrestre é muito importante para o reconhecimento da superfície da Terra de maneira rápida e eficaz.

Conforme descreve Novo (1989), os diferentes sistemas sensores são caracterizados pela sua resolução, definida como medida da habilidade que o sensor possui de distinguir entre respostas espectralmente semelhantes e espacialmente próximas. A resolução espacial de um sensor é a medida da menor separação linear ou angular entre dois objetos da superfície terrestre; a resolução espectral é a medida da largura das faixas espectrais nas quais o sensor opera; a resolução radiométrica indica a sensibilidade do sensor em distinguir entre dois níveis de intensidade do sinal de retorno, enquanto que a resolução temporal, refere-se ao intervalo de tempo entre a aquisição de duas imagens de uma mesma área.

Para que se possam extrair informações a partir de dados de Sensoriamento Remoto, é de suma importância o conhecimento do comportamento espectral dos alvos da superfície terrestre e dos fatores que interferem nesse comportamento. Em qualquer informação, é sempre importante considerar o nível de aquisição dos dados, ou seja, a plataforma na qual está instalado o sistema sensor (terrestre, aérea ou orbital). No que se refere aos alvos de interesse (água e vegetação) e considerando as características dos sensores remotos orbitais, quanto à sua resolução espacial e espectral e os mecanismos de interação da radiação eletromagnética com a água, percebe-se uma variabilidade espectral bem tênue nos corpos d'água, de modo que os estudos envolvendo qualidade da água têm se limitado à detecção de particulados em suspensão e de vegetação aquática emersa (VELINI *et al.*, 2002).

Na interação da REM da água a maioria do fluxo radiante incidente sobre a água não é refletido, mas absorvido ou transmitido. Nos comprimentos de onda do visível, pouca luz é absorvida, uma pequena quantidade é refletida e a maior parte é transmitida. A água absorve fortemente nas regiões do infravermelho próximo e médio, deixando pouca radiação para ser refletida ou transmitida resultando em um forte contraste entre a água e os limites de terra. Os fatores que afetam a variabilidade espectral na reflectância de um corpo d'água são, geralmente, determinados pelo ambiente. Os três fatores mais importantes são: profundidade do corpo d'água, presença de materiais em suspensão e a rugosidade da superfície do corpo d'água (CURRAN, 1983).

No caso da vegetação, a REM que chega na superfície da Terra se decompõe em três frações: uma parte da radiação é absorvida pelos pigmentos contidos na folha, outra parte é refletida pelas folhas (reflexão) e a terceira parte sofre o processo de transmissão através das camadas das folhas.

Curran (1983) relata que são três os principais mecanismos que influenciam a quantidade de energia eletromagnética refletida pelas folhas: pigmentos, espaços ocupados pela água e ar e estruturas celulares. Essa energia refletida pode ser afetada também pelo conteúdo de água, maturação ou idade da folha e a condição de iluminação (folhas expostas ao sol e folhas constantemente à sombra).

3 PROCESSAMENTO DIGITAL DE IMAGENS MULTIESPECTRAIS

Nas últimas décadas, a extração de informação a partir de dados de Sensoriamento Remoto tem sido realizada com sucesso, mediante a utilização técnicas de Processamento Digital de Imagens (PDI), possibilitando o desenvolvimento de análises direcionadas à caracterização dos processos ambientais.

Ao caracterizar as imagens de Sensoriamento Remoto, Richards (1986) salienta que elas apresentam um formato essencialmente digital: espacialmente os dados são compostos por elementos discretos de resolução, chamados *pixels*, com uma posição definida na cena; e radiometricamente esses dados são quantizados em níveis de brilho discretos.

Novo (1989) classifica as técnicas de PDI em três conjuntos: técnicas de pré-processamento, técnicas de realce e técnicas de classificação digital. A decisão de quais técnicas aplicar em cada situação deve ser ditada pelos objetivos a serem alcançados e pelas especificidades da situação.

Dentre os métodos existentes de transformação dos dados de satélites, o modelo linear de mistura é uma alternativa promissora, pois separa as contribuições de cada material dentro do *pixel*, considerando que a radiação captada por um sistema sensor resulta da mistura de diferentes materiais, acrescida da contribuição da atmosfera.

Segundo Shimabukuro e Smith (1991), o fenômeno de mistura espectral decorre do fato de que a radiância registrada por um equipamento sensor é a soma das radiâncias de todos os materiais dentro do campo de visada instantânea (IFOV) deste sensor, ou seja, a radiação detectada é resultante da mistura de diferentes materiais acrescida da contribuição da atmosfera.

Devido a geralmente pequena resolução espacial dos sensores orbitais, a resposta espectral contida no *pixel* é uma mistura de três componentes presentes no alvo: solo, vegetação e água. O modelo linear de mistura espectral foi desenvolvido para decompor um *pixel* da imagem original, resultando na geração desses três componentes (MOREIRA, 2001). A equação utilizada na decomposição da imagem é descrita abaixo:

$$r_i = a * vege_i + b * solo_i + c * \acute{a}gua_i + e_i, \quad (1)$$

onde: r_i é a resposta espectral do *pixel* na banda i ; a, b e c são as proporções de vegetação, solo e água, respectivamente; $vege_i$, $solo_i$ e $\acute{a}gua_i$ são as respostas

espectrais dos componentes vegetação, solo e água, respectivamente, e e_i é o erro na banda i , sendo o subscrito i a banda considerada.

A classificação de imagens de Sensoriamento Remoto consiste em estabelecer um processo de decisão no qual um *pixel* ou um grupo de *pixels* é definido como pertencente a uma determinada classe (VENTURIERI e SANTOS, 1998). Os métodos de classificação digital podem ser agrupados em função da presença ou não de uma fase de treinamento na qual o analista interage com o computador.

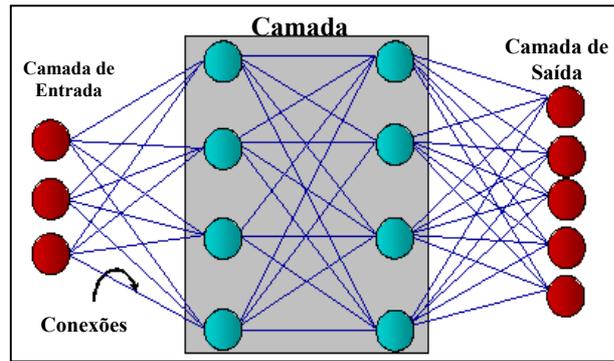
Para a análise de dados multiespectrais, Richards (1986) destaca dois procedimentos abrangentes de classificação: não-supervisionada e supervisionada. O método é não-supervisionado quando o classificador não utiliza nenhum conhecimento prévio sobre as classes existentes na imagem e define, sem a interferência do analista, a estratificação da cena, atribuindo a cada *pixel* uma determinada classe espectral. Por outro lado, o método é dito supervisionado quando implica na interação do analista e o sistema de análise e, além disso, esse analista tem um conhecimento prévio da cena, o que o habilita a fornecer informações específicas, possibilitando o treinamento do algoritmo de classificação.

4 APLICAÇÃO DE REDES NEURAIS NA CLASSIFICAÇÃO SUPERVISIONADA

A tentativa inicial de reproduzir o alto desempenho do cérebro humano em tarefas cognitivas extremamente complexas, motivou o desenvolvimento dos modelos de RNA. Tais modelos representam um tipo especial de processamento da informação, que consiste de muitas células primitivas que trabalham em paralelo e estão conectadas através de ligações diretas, cuja principal função é distribuir padrões de ativação, de maneira similar ao mecanismo básico do cérebro humano (ZELL *et al.*, 1995).

Segundo Brondino (1999), as RNA são organizadas em camadas 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 (*feedforward*), formadas por várias camadas intermediárias 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 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. A Figura 1 mostra a organização das camadas de uma rede multicamadas *feedforward*.

Figura 1 - Diagrama esquemático de uma RNA de *feedforward* com duas camadas escondidas.



Gonzales e Woods (2000) esclarecem que o número de elementos de processamento (nós) da primeira camada corresponde à dimensionalidade do vetor de atributos dos dados de entrada, a camada de saída terá tantos elementos quantas forem as classes a serem separadas. O problema maior está na definição do número de camadas escondidas e do número de nós que as compõem. Na prática este problema tem sido geralmente resolvido por tentativa e erro e/ou pela experiência prévia do operador no domínio de uma dada situação.

As redes *feedforward* tem sido muito utilizadas para soluções de problemas envolvendo altos graus de não-linearidade. Tais redes usam o treinamento supervisionado realizado por um algoritmo chamado de retro-propagação de erro (*error backpropagation*), o qual é baseado na regra de aprendizagem que “corrige” o erro durante o treinamento (BOCANEGRA, 2002). Esse algoritmo *backpropagation*, derivado da Regra Delta Generalizada, permite um ajuste de pesos em cada uma das camadas da rede e é projetado para minimizar a soma do erro médio quadrático entre a saída calculada por uma arquitetura multicamadas e a saída desejada.

O processo de treinamento pelo algoritmo *backpropagation* começa com a definição de um conjunto arbitrário de pesos para as conexões da rede e envolve duas fases distintas. Na primeira, um vetor de treinamento com a respectiva saída desejada é apresentado à rede e propagado através de suas camadas computando uma saída para cada elemento de processamento. As saídas dos nós da última camada são, então, comparadas com as saídas desejadas e, a partir disso, são calculados os termos de erro. A segunda fase envolve um retrocesso, ou seja, uma passagem de volta através da rede a partir da última camada, durante a qual, o erro é repassado para cada elemento de processamento e os pesos correspondentes são alterados. Em um treinamento bem sucedido, o erro diminui com o aumento do

número de iterações e o procedimento converge para um conjunto estável de pesos (GALO, 2000a).

Seja E_p , a função do erro médio quadrático para o padrão p , d_{pj} o valor da saída desejado (para o padrão p e o nó j) e O_{pj} , o valor da saída obtido, então a função do erro médio quadrático (E_p) é dada por (RAIA, 2000):

$$E_p = \frac{1}{2} \sum_j (d_{pj} - O_{pj})^2 \quad (2)$$

Após o aprendizado da rede, ela classifica os padrões da área de interesse usando o conjunto dos pesos ajustados durante a fase de treinamento, reconhecendo um dado padrão como pertencente a determinada classe, quando a saída para essa classe for "alta", e "baixa" para as demais classes (GONZALES e WOODS, 2000). Em linhas gerais, o critério de decisão adotado estabelece que, para um dado padrão de entrada, o elemento de processamento da camada de saída (associado a uma classe específica) que produzir o maior resultado numérico definirá a classe à qual o padrão será atribuído. Para algumas implementações de rede neural, além dessa saída ser maior para uma das classes, ela deve ter um valor superior ao limite de tolerância, para que o padrão possa ser atribuído àquela classe (GALO, 2000a).

Porém, ao considerar que um *pixel* de uma imagem pode ser associado a mais de uma classe ou tipo de cobertura da terra, com diferentes graus de pertinência, vários autores argumentam que a lógica dos problemas de decisão na classificação dos dados de Sensoriamento Remoto é inerente aos conjuntos nebulosos (*Fuzzy*) (GALO *et al*, 2002).

A introdução dos conjuntos *Fuzzy* para tratar conceitos inexatos, ambíguos ou abstratos, foi primeiramente introduzida por Zadeh, em 1960. Um conjunto *Fuzzy* é uma abordagem usada para caracterizar classes que, por várias razões, não tem ou não podem definir limites rígidos entre elas (CÂMARA *et al*, 2000).

As classes no modelo *Fuzzy* podem ser de dois tipos: classes discretas cujos membros apresentam uma pertinência total para uma das categorias de referência e classes contínuas nas quais a pertinência de um indivíduo em relação a cada classe é parcial. As classes contínuas são uma generalização do caso discreto onde o indicador da função que, na teoria dos conjuntos convencionais aponta para 0 ou 1, é substituído pela abordagem de conjuntos *Fuzzy*, na qual os valores calculados estão entre 0 e 1 (LEGUIZAMÓN *et al*, 1996).

No contexto de classificação de imagens, Zhang e Foody (1998) ressaltam que um *pixel* pode estar parcialmente associado a múltiplas classes e esse grau de associação é definido por um valor de pertinência *fuzzy*. Existem várias maneiras de derivar os valores de pertinência e essa tarefa depende da técnica de classificação adotada. No caso da classificação por RNA o grau de pertinência associado a cada classe é avaliado pelos valores de ativação de saída calculados para cada elemento.

5 MATERIAIS E MÉTODOS

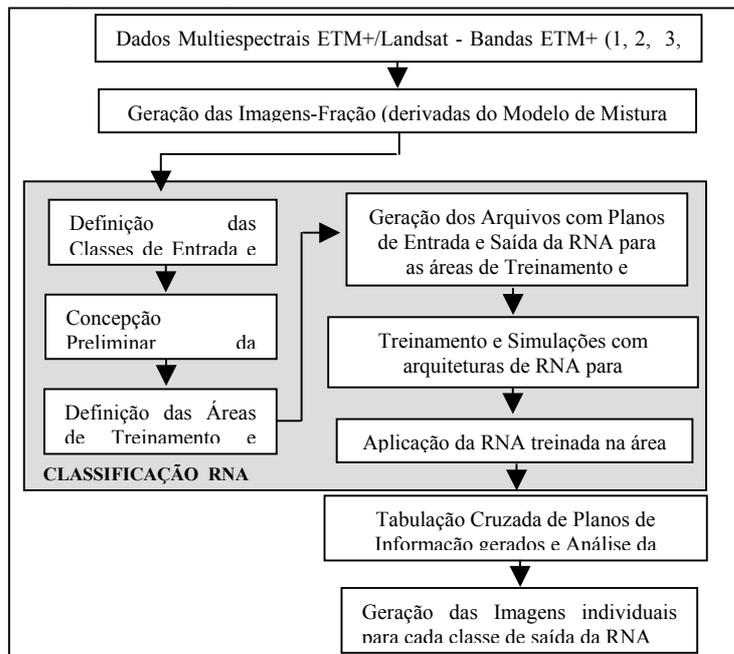
A abordagem proposta neste trabalho foi aplicada a uma área teste identificada no reservatório de Barra Bonita localizado ao longo do Rio Tietê. A cena utilizada

foi obtida no período de junho de 2001, e sua definição levou em conta a maior presença de macrófitas aquáticas emersas no leito do rio. Os dados multiespectrais utilizados correspondem a imagens orbitais ETM+/Landsat7, disponibilizados pelo Projeto AES/TIETÊ de “Monitoramento dos Problemas com Macrófitas nos Reservatórios da AES - Desenvolvimento de Programas de Manejo Integrado das Principais espécies presentes”.

No desenvolvimento do trabalho foram utilizados os *softwares* SPRING e IDRISI, os quais fornecem ferramentas necessárias para a análise dos dados de Sensoriamento Remoto, e o Simulador de Redes Neurais (SNNS - *Stuttgart Neural Networks Simulator* da Universidade de *Stuttgart*) para a classificação por Redes Neurais Artificiais.

As atividades desenvolvidas neste trabalho estão ilustradas no fluxograma da Figura 2.

Figura 2 – Fluxograma ilustrando as atividades desenvolvidas no trabalho



A primeira atividade realizada no contexto deste trabalho foi aplicar um modelo linear de mistura espectral às bandas espectrais ETM+ 1, 2, 3, 4, 5 e 7. As proporções dos componentes (vegetação, solo e água) foram estimadas utilizando o Método dos Mínimos Quadrados Ponderado, o qual busca iterativamente a solução de um sistema de equações lineares e produz um indicador de erro de estimação para cada banda espectral. Operacionalmente o uso dessas imagens resulta em uma redução no tempo de processamento digital, pois se utilizam imagens cujos

atributos são reduzidos, ao invés de um conjunto de bandas espectrais originais. Ao término do processo foram geradas as imagens-fração correspondentes aos componentes “puros”: vegetação, solo e água, individualmente.

Para a classificação dos dados pela RNA usando o simulador SNNS, foi necessário definir a priori os dados de entrada e as classes de saída a serem mapeadas. Os dados de entrada constituíram-se das imagens-fração (vegetação, solo e água) derivadas do modelo de mistura espectral. Como classe de saída foram identificadas as seguintes ocorrências: água1, água2, macrófita1, macrófita2 e fundo, no qual a classe “água1” corresponde à água limpa e aparece em tonalidade escura nas bandas espectrais do Infravermelho, a classe “água2” refere-se a água com presença de sedimentos, e aparece em tonalidades um pouco mais claras na cena, enquanto que as classes “macrófita1” e “macrófita2” estão associadas a tipos de macrófitas distintas, percebidas devido à sua variabilidade espectral e textura. A classe “fundo” refere-se a área externa ao leito do rio no trecho estudado. Com isso, ficou definida a arquitetura preliminar da rede multicamadas, uma vez que o número de elementos da camada de entrada (imagens-fração) e da camada de saída (classes de interesse) foram especificados.

Como a abordagem proposta prevê um procedimento de classificação supervisionada, a aquisição dos dados para o treinamento e validação de uma arquitetura de RNA implicou na extração de sub-áreas (ou segmentos) da imagem, em cada um dos planos de entrada da rede (imagens-fração vegetação, solo e água) e na definição de um plano de saída associado a cada uma das classes de interesse. Nesse processo, foi selecionada uma área de treinamento correspondente a 1,30 % (392 x 170 *pixels*) da cena total contendo exemplos representativos das classes de interesse, e uma amostra de validação correspondendo a 5,73 % (561 x 527 *pixels*), na qual também se procurou englobar todas as possíveis classes de saída definidas, e que foram identificadas pela sua maior concentração e dispersão espacial.

Para a realização da classificação supervisionada no simulador foi utilizado um modelo de RNA com estrutura de múltiplas camadas e alimentação progressiva (*feedforward*), treinada pelo algoritmo *backpropagation*. As simulações, realizadas durante a etapa de treinamento, foram feitas a partir da aplicação de diferentes arquiteturas de rede aos dados de validação, com o intuito de selecionar a melhor arquitetura, ou seja, a que melhor represente os alvos de interesse (classes de saída). As arquiteturas testadas constituíram-se em variações da concepção inicial, com 3 elementos de processamento na camada de entrada, cinco na camada de saída, modificando-se o número de elementos e camadas escondidas. Ao todo foram testadas várias arquiteturas, sendo a que forneceu melhor resultado àquela com 21 elementos na primeira camada escondida e 11 na segunda camada escondida.

O processo de treinamento implicou na definição prévia dos parâmetros que são requeridos para a classificação. Nesse sentido, estabeleceu-se uma taxa de aprendizagem (que corresponde ao quanto de erro é repassado aos nós a cada iteração), igual a 0,01. A função de ativação adotada foi a sigmóide ou logística,

usada para calcular o valor de ativação em cada nó das camadas intermediárias e de saída. O modo de atualização escolhido foi pela estrutura topológica, que leva em conta a organização das camadas na rede. Os pesos aleatórios iniciais foram definidos no intervalo entre 0,1 e -0,1.

A validação dos dados foi feita a cada n ciclos (variando a cada simulação), sendo que a partir daí era disponibilizado o erro médio quadrático sobre esse conjunto de padrões de validação. Durante essa fase, o conjunto de validação foi utilizado para determinar o desempenho da rede com dados que não foram previamente utilizados no treinamento. Com base nesse erro e no resultado da aplicação da rede treinada à área estabelecida para validação, foi selecionada a arquitetura de rede mais adequada para classificar o conjunto de dados espaciais.

Escolhida a arquitetura mais adequada de RNA, esta foi aplicada na classificação da área de treinamento (área teste), em um arquivo que registra os valores de ativações de saída para cada *pixel* da imagem, em relação a cada classe de interesse. Esse resultado foi, posteriormente utilizado na análise da ambigüidade.

Desse modo, a partir do arquivo de saída do simulador SNNS, foram criados arquivos individuais contendo os valores de ativação, resultantes do processo de classificação, associados a cada classe de saída. Foram gerados, então, quatro planos de informações individuais para as classes “água1”, “água2”, “macrófita1” e “macrófita2”. Posteriormente, para cada *pixel* da cena, esses valores foram generalizados em intervalos iguais, definindo graus de associação “Muito Baixo” (MB), “Baixo” (B), Médio (M), “Alto” (A) e “Muito Alto” (MA) especificados, de acordo com o valor de ativação obtido para a classe em questão. A elaboração desses novos planos de informação foi realizada a fim de representar a ambigüidade entre as classes de saída da rede neural.

As imagens geradas individualmente para cada classe, foram submetidas a uma operação de tabulação cruzada entre as duas classes passíveis de apresentar ambigüidade, possibilitando a comparação entre os planos de informação “água1” e “água2”, e os planos “macrófita1” e “macrófita2” e que resultou em duas novas imagens contendo os graus de associação de cada *pixel* com as classes de saída analisadas.

6 RESULTADOS E ANÁLISES

As proporções da mistura espectral contidas em cada elemento de resolução foram obtidas através da identificação e aquisição de amostras de *pixels* considerados “puros” para cada um dos componentes de solo, vegetação e água, definidas com base no comportamento espectral desses alvos. A Tabela 1 mostra os coeficientes do modelo linear usado para a transformação nos componentes de solo, vegetação e água, ou seja, para gerar as imagens-fração correspondentes a cena contendo todo reservatório de Barra Bonita.

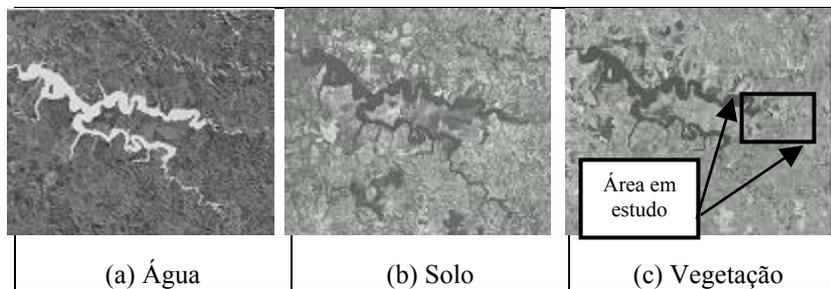
Tabela 1 - Valores obtidos a partir da amostragem dos *pixels* “puros” identificados na imagem.

	SOLO	VEGETAÇÃO	ÁGUA
ETM+1	0,216	0,180	0,180
ETM+2	0,169	0,125	0,118
ETM+3	0,184	0,098	0,086
ETM+4	0,208	0,337	0,082
ETM+5	0,310	0,145	0,052
ETM+7	0,200	0,067	0,047

A Tabela 1 indica a contribuição de cada banda na definição de cada componente de mistura. Pode-se verificar que há uma maior participação da banda ETM+5 (0,310) na formação da componente solo, enquanto que a banda ETM+4 contribui mais na formação da componente vegetação (0,337). A componente água tem maior proporção da banda ETM+1 (0,180), ou seja, possui maior participação dessa banda definida no menor comprimento de onda.

As imagens-fração geradas a partir da transformação são mostradas na Figura 3, na qual também é indicada, em destaque na componente vegetação (Figura 3(c)), a área de estudos efetivamente analisada nesse trabalho.

FIGURA 3 - Imagens-fração correspondentes as componentes “puras” água (a); solo (b) e vegetação(c), destacando a área de estudo em (c).



Observando individualmente as imagens-fração pode-se verificar que na componente água, apresentada na Figura 3(a), os corpos d'água estão associados a um tom de cinza claro, destacando-se do entorno e constituindo-se na feição mais representativa na cena. A componente solo (Figura 3(b)), mostra que a vegetação e a água estão associadas a um tom de cinza escuro e o solo exposto aparece em tons de cinza mais claros na cena, enquanto que a componente vegetação (Figura 3(c)) destaca as áreas de ocorrência de plantas aquáticas, as quais aparecem em tons claros (principalmente na área em destaque).

Para a classificação pela RNA, a arquitetura foi selecionada considerando que o número de elementos de processamento da camada de entrada (3 nós) e o da

camada de saída (5 nós) estavam definidos previamente, sendo necessário estabelecer o número de camadas escondidas.

As características das simulações e o número de classes de saída definidas pela rede, considerando os dados de treinamento e validação utilizados, são mostrados na Tabela 2, na qual especifica-se: a arquitetura de rede testada, o número de ciclos usados para treinar cada arquitetura, o erro médio quadrático e, o número de classes discriminadas. Para especificar cada arquitetura de rede treinada adotou-se o seguinte padrão: [número de nós na camada de entrada – número de nós da primeira camada escondida – número de nós da segunda camada escondida – número de nós na camada de saída]. Vale ressaltar que partiu-se inicialmente de uma arquitetura com uma camada escondida, que não apresentou resultados satisfatórios, e posteriormente com duas camadas escondidas, que são normalmente suficientes para separar classes com características espectralmente similares, já que produzem superfícies de decisão mais complexas.

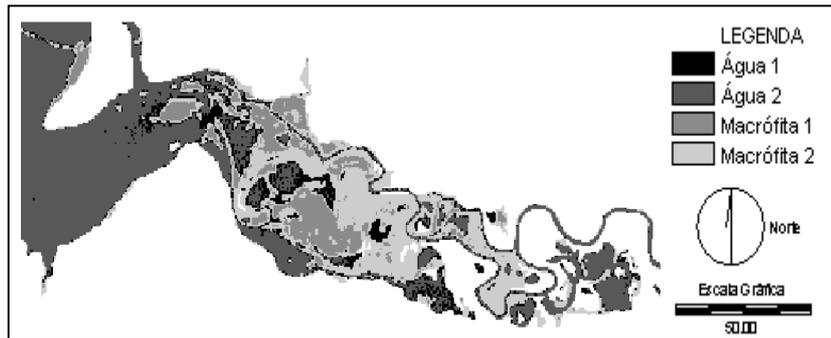
TABELA 2 - Resumo das simulações realizadas para o treinamento da rede.

Arquitetura de RNA	Número de Iterações	Erro de Validação	Classes Discriminadas
[3-13-7-5]	5000	0,01014	05
[3-21-11-5]	5500	0,01015	05
[3-37-29-5]	1000	0,03184	04
[3-25-16-5]	4000	0,00997	04
[3-49-41-5]	1500	0,02980	04

Pela Tabela 2 percebe-se que o erro obtido é bastante reduzido, porém algumas arquiteturas não apresentaram resultados satisfatórios na definição de todas as classes de saída. Embora a arquitetura [3-25-16-5] tenha apresentado um erro menor em relação às demais arquiteturas (0,00997), a mesma não conseguiu discriminar todas as classes estipuladas. Dessa forma, a arquitetura [3-21-11-5], cujo erro foi de 0,01015, foi selecionada por separar todas as classes e resultar em uma distribuição espacial das classes mais adequada, o que foi verificado visualmente na imagem classificada.

A classificação da área de estudos (área teste), resultante da aplicação da arquitetura [3-21-11-5] treinada com 5500 ciclos ou iterações, é mostrada nas Figura 4. Na legenda dessa Figura e da Figura 5 constam apenas quatro classes de interesse (Água1, Água2, Macrófita1 e Macrófita2), sendo que a classe não água (fundo) foi desconsiderada na representação.

FIGURA 4 – Classificação resultante da aplicação da arquitetura [3-21-11-5] a área de estudos.



A Figura 4 indica que foram detectadas as grandes áreas de infestação por macrófitas aquáticas emersas e a dispersão dessas plantas no leito do rio. A grande concentração dessas plantas aquáticas sugere um alto grau de infestação por esse tipo de vegetação nessa região do reservatório. Os tipos de macrófitas (“macrófita1” e “macrófita2”) ficaram bem discriminados com a utilização dessa arquitetura de RNA e se mostraram consistentes com o padrão observado nas imagens-fração água, vegetação e solo.

Considerando não apenas o número de classes discriminadas a partir das diferentes arquiteturas, mas também como essas classes estão espacialmente definidas na imagem, percebeu-se que apesar da pouca diferenciação entre as classes de água (“água1” e “água2”) e plantas aquáticas emersas (“macrófita1” e “macrófita2”) a delimitação geral ficou bem definida.

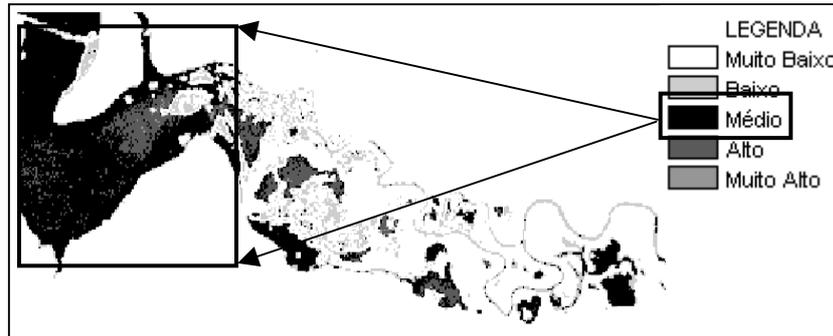
A questão da ambigüidade entre as classes associadas às variações de água (1 e 2) e macrófitas (1 e 2) foi verificada a partir da geração dos arquivos de imagens individuais para cada classe de saída da rede neural, resultando em quatro planos de informação (“água1”, “água2”, “macrófita1” e “macrófita2”) os quais foram analisados individualmente a partir da tabulação cruzada realizada.

As imagens mostradas nas Figuras 5 a 8 indicam o grau de aderência de cada *pixel* da imagem em relação à cada classe, através de um critério de associação definido como: Muito Baixo (MB), Baixo (B), Médio (M), Alto (A) e Muito Alto (MA). O atributo “Muito Baixo” refere-se aos *pixels* que não apresentaram associação com a classe de saída especificada, enquanto que os *pixels* representados por “Muito Alto” indicam um alto grau de associação, podendo ser considerados como totalmente inseridos na classe em questão. Tanto o índice “Muito Baixo” como “Muito Alto” não representam ambigüidade na atribuição dos *pixels* às classes, enquanto que os *pixels* associados a “Baixo” e “Alto” apresentam pequena ambigüidade. São os *pixels* que receberam a indicação de “Médio” (grau de

associação) que representam maior ambigüidade entre duas classes de saída, indicando que ocorre confusão entre elas.

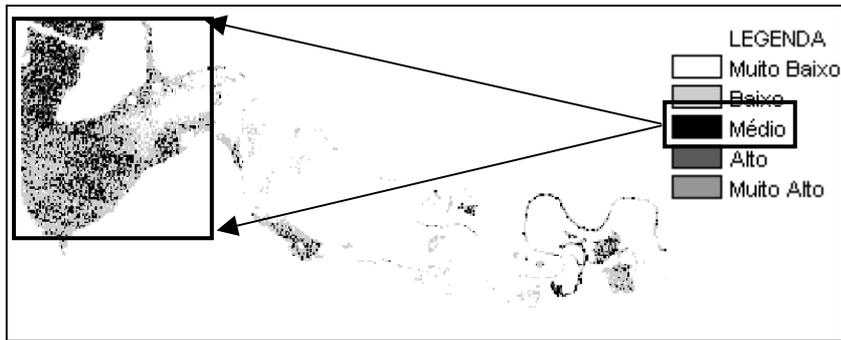
A Figura 5 ilustra o grau de associação dos *pixels* com a classe de saída da RNA “Água1”.

FIGURA 5 – GRAU DE ASSOCIAÇÃO DOS *PIXELS* COM A CLASSE “ÁGUA1”.



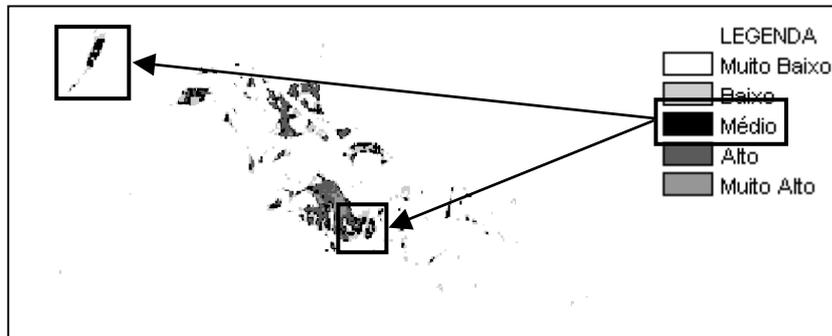
A Figura 5, que representa o plano de informação referente à classe “água1”, indica que a maior aderência dos *pixels* a essa classe está condizente com posição das amostras selecionadas na fase de treinamento da rede neural. Essas regiões foram associadas ao atributo “Alto” indicando o alto grau de associação desses *pixels* com a classe em questão. O atributo “Baixo” é relacionado aos *pixels* que não pertencem totalmente a essa classe, apresentando pouca ambigüidade em relação ao outro tipo de água. Nessa figura, o atributo “Médio” ilustra que as classes (“água1” e “água 2”) apresentaram maior ambigüidade entre si, ou seja, tem valores similares de resposta espectral, o que ocorre principalmente no início do leito do rio, como pode ser verificado em destaque na Figura 5.

O grau de associação dos *pixels* com a classe de saída “Água2” é ilustrado na Figura 6.

FIGURA 6 – Grau de Associação dos *pixels* com a classe “Água2”.

Na Figura 6, referente ao plano de informação “água2”, pode-se verificar que as classes que apresentam uma certa ambigüidade em relação a essa classe estão mostradas pelos *pixels* correspondentes ao atributo “Baixo” predominantemente. Como se pode observar ocorreram poucos *pixels* indicando alta associação (“Muito Alto”) com essa classe (“água2”). A maioria dos *pixels* dessa categoria apresentou ambigüidade entre as classes de saída “água1” e “água2” destacando, dessa forma, a similaridade entre essas duas classes.

O grau de associação dos *pixels* com a classe “Macrófita1” pode ser verificado na Figura 7.

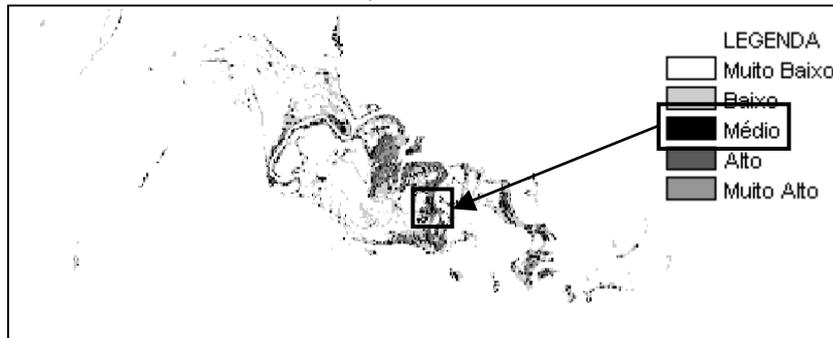
FIGURA 7 – GRAU DE ASSOCIAÇÃO DOS *PIXELS* COM A CLASSE “MACRÓFITA1”.

De acordo com a Figura 7, que representa a classe “macrófita1”, foram poucos os *pixels* associados ao atributo “Médio”, indicando que ocorre pouca ambigüidade ou confusão nessa classe. Como pode ser verificado pela figura, ocorreram áreas nas quais os *pixels* foram classificados como “Alto” e “Muito Alto” o que indica que sua identificação não apresentou grande similaridade, principalmente com a “macrófita2”. Apesar disso, em algumas pequenas regiões com a presença de

macrófitas aquáticas, os *pixels* não apresentaram associação com a classe em “macrófita1”. A ocorrência da classe “Muito Alto” mostra que a rede conseguiu discriminar a presença dessa macrófita com relativa coerência, sem maior confusão.

A Figura 8 apresenta o grau de associação dos *pixels* com a classe “Macrófita2”.

FIGURA 8– GRAU DE ASSOCIAÇÃO DOS *PIXELS* COM A CLASSE “MACRÓFITA2”.



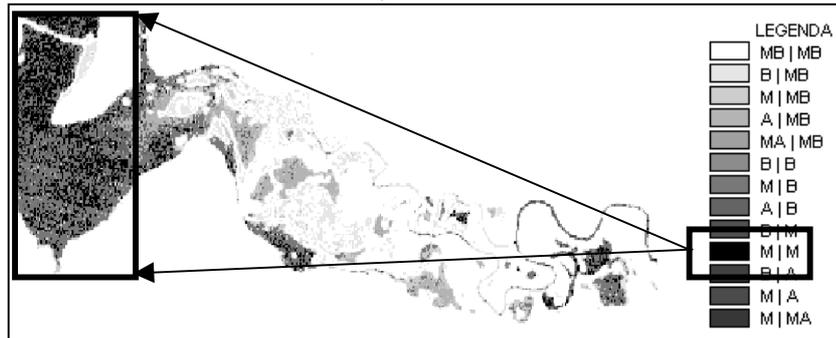
A mesma análise da Figura 7 pode ser aplicada à Figura 8, referente à classe “macrófita2”. Nessa figura, os *pixels* das regiões representadas como “Baixo” mostram o pequeno grau de associação dos *pixels* com a classe em questão. A presença do atributo “Médio” confirma a análise realizada para o plano de informação “macrófita1”, o qual indica pouca ambigüidade entre essas duas classes de saída (“macrófita1” e “macrófita2”).

De certa forma, isso mostra que as classes “macrófitas1” e “macrófitas2” foram facilmente discriminadas. Embora o grau de confusão para essas duas classes seja pequeno, ele existe, e mesmo assim a rede treinada conseguiu discriminar satisfatoriamente essas variações de plantas aquáticas.

A partir das imagens individuais, foi realizada a tabulação cruzada entre os planos de informação de água (“água1” com “água2”) e macrófita (“macrófita1” com “macrófita2”), a fim de buscar uma melhor representação da ambigüidade entre duas classes de saída.

As Figuras 9 e 10 ilustram os resultados dessa operação de tabulação cruzada.

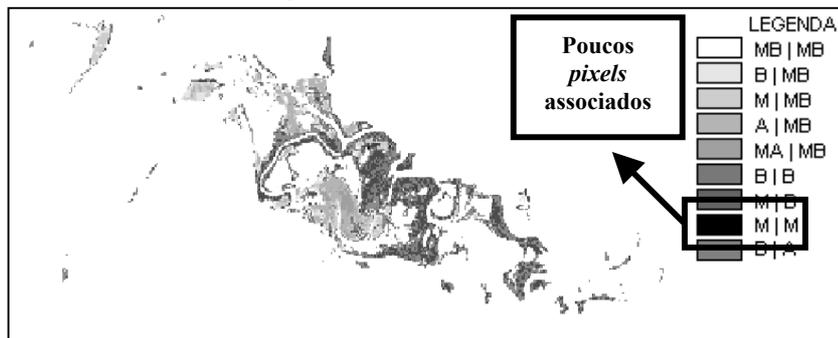
FIGURA 9 – IMAGEM RESULTANTE DA TABULAÇÃO CRUZADA ENTRE OS PLANOS DE INFORMAÇÃO “ÁGUA1” E “ÁGUA2”.



Através da tabulação cruzada dos planos de informação “água1” e “água2”, ilustrados na Figura 9, pode-se verificar a ambigüidade entre essas duas classes de saída observando os *pixels* associados ao atributo “Médio” nas duas classes. O índice “MxM” refere-se ao cruzamento dos índices “MédioxMédio” e indica os *pixels* que apresentam ambigüidade entre as classes, sendo que sua maior ocorrência na cena está evidenciada no quadro em destaque. Os índices “MxMB”, “MxA”, “MxMA” e “MxB” exibem a presença da ambigüidade, porém em menor grau, enquanto que os índice “MBxMB”, “BxB”, “AxA” e “MAxMA” indicam baixo ou alto grau de associação a uma dessas classes e, portanto, quase nenhuma confusão entre elas.

A Figura 10 ilustra a tabulação cruzada dos tipos de macrófita (“macrófita1” e “macrófita2”).

FIGURA 10 – IMAGEM RESULTANTE DA TABULAÇÃO CRUZADA ENTRE OS PLANOS DE INFORMAÇÃO “MACRÓFITA1” E “MACRÓFITA2”.



Na análise da Figura 10 referente a tabulação cruzada dos planos de informação “macrófita1” e “macrófita2” o índice “MxM” não foi representado, mostrando que os *pixels* da imagem não apresentam alto grau de ambigüidade entre as classes, embora os índices “MxMB”, “MxB”, “MBxM” e “BxB” indiquem a presença de alguma ambigüidade entre as classes associadas.

7 CONCLUSÕES

A aplicação de Redes Neurais Artificiais na classificação da água e macrófitas aquáticas emersas, utilizando imagens-fração derivadas do modelo de mistura como dados de entrada, apresentou resultados satisfatórios, permitindo uma boa separação espectral de duas ocorrências distintas de macrófitas emersas e variações na água. A utilização dessas imagens considerou o pressuposto de que essas componentes “puras” representavam melhor as classes de interesse, auxiliando assim o reconhecimento das classes de saída.

Algumas dificuldades identificadas no decorrer da pesquisa devem ser destacadas, como a questão da definição das classes e aquisição de áreas de treinamento representativas para as referidas classes, pois algumas delas apresentaram-se muito similares em termos de resposta espectral, ou foram pouco representativas nas diferentes imagens que constituíram os planos de entrada apresentados à rede. No entanto, considerou-se que a aplicação de RNA na classificação supervisionada da água e macrófitas aquáticas emersas mostrou-se uma abordagem promissora, permitindo avaliar a dispersão espacial das plantas aquáticas emersas presentes na área de estudo do reservatório de Barra Bonita.

Um aspecto relevante da abordagem desenvolvida com a utilização do simulador SNNS para a classificação dos tipos de macrófitas aquáticas emersas foi a possibilidade de verificar a ambigüidade entre as classes similares de água e macrófitas. A classificação permitiu verificar que as classes que apresentaram maior ambigüidade foram as classes de água (“água1” e “água2”), devido a uma maior similaridade nos valores de brilho dos *pixels*. Isto pode ter sido causado pela escolha das amostras referentes a essas duas classes, que apresentavam valores de brilho muito próximos. Apesar disso, a rede neural conseguiu distinguir entre essas duas variações de água.

Pelas análises realizadas mediante a tabulação cruzada dos planos de informação gerados pela saída da rede neural pode-se concluir que as classes que apresentaram maior ambigüidade referem-se às variações de água (“água1” e “água2”), enquanto que as classes de saída referentes aos tipos de macrófitas mapeadas apresentaram-se espectralmente separáveis na imagem.

Em suma, a classificação por RNA de áreas de infestação por plantas aquáticas emersas e variações espectrais na água e a análise da ambigüidade entre classes de saída com características similares apresentaram resultados satisfatórios.

AGRADECIMENTOS

Agradecemos à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo auxílio financeiro destinado a este trabalho, na forma de bolsa de demanda social; à coordenação do Projeto AES/TIETÊ de Monitoramento dos Problemas com Macrófitas nos reservatórios da AES, pela disponibilização de grande parte dos dados utilizados; ao professor Mauricio Galo do Departamento de Cartografia da FCT/UNESP, pela disponibilização dos programas de conversão de dados utilizados nesse trabalho.

REFERÊNCIAS

- BENEDIKTSSON, J. A. *et al.* Neural Networks approaches versus statistical methods in classification on 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, 146 f. Dissertação (Mestrado em Engenharia Civil – Transportes) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.
- BRONDINO, N.C.M. Estudo da Influência da Acessibilidade no Valor de Lotes Urbanos Através do Uso de Redes Neurais, 1999, 97 f. Tese (Doutorado em Engenharia Civil – Transportes) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.
- CÂMARA, G. *et al.* Técnicas de Inferência e suporte a Decisão: *Curso GIS para o meio ambiente*. 2000. São José dos Campos. INPE. Disponível em <<http://www.dpi.inpe.br/spring/portugues/material/html>>. Acesso em: maio, 2000.
- CAVENAGHI, A. L. “Caracterização da qualidade da água e sedimento relacionados com a ocorrência de plantas aquáticas em cinco reservatórios da bacia do rio Tietê”, 2003, 73 f. Tese (Doutorado em Agronomia - Proteção de Plantas) – Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista “Julio Mesquita Filho”, Botucatu.
- CURRAN, P.J. *Principles of Remote Sensing*. Longman, 1983, 282 p.
- DEMERS, M. N. *Fundamentals of Geographic Information System*. New York, John Wiley & Sons, 1997, 486p.
- GALO, M. L. B. T. Caracterização Ambiental do Parque Estadual Morro do Diabo através de dados e técnicas de Sensoriamento Remoto: Abordagens utilizando redes neurais artificiais. 2000a. 205f. Tese (Doutorado em Ciências da Engenharia Ambiental) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.
- _____. Utilização de Dados e Técnicas de Sensoriamento Remoto na Caracterização Ambiental do Parque Estadual Morro do Diabo: Relatório de

- projeto de pesquisa referente ao triênio 1997 a 2000. Presidente Prudente, FCT/UNESP/ Digitado, 2000b, p. 73.
- _____. *et al.* Aspectos relacionados com o fenômeno de Mistura Espectral e Ambigüidade na classificação usando redes neurais artificiais. Série em Ciências Geodésica. Curitiba, v.2,2002, p.219-247.
- GONZALEZ, R. C.; WOODS, R. E. Processamento Digital de Imagens. e.2. Edgard Blücher, 2000. 717p.
- LEGUIZAMÓN, S.*et al.* Unsupervised Fuzzy C-means classification for the determination of dynamically homogeneous areas. Revista SELPER, v. 12, n.12, 1996, p. 20 - 24.
- MOREIRA, M. A. Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação. São José dos Campos: Com Deus, 2001. 250p.
- NOVO, E. M. L. M. Sensoriamento Remoto: Princípios e Aplicações. São Paulo, Edgard Blücher. 1989.
- RAIA, A. A. J. Acessibilidade e Mobilidade na Estimativa de um Índice de Potencial de Viagens Utilizando Redes Neurais Artificiais. 2000. 196 f. Tese (Doutorado em Engenharia Civil – Transportes) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.
- RICHARDS, J. A. Remote Sensing Digital Image Analysis: An Introduction. New York, Springer Verlag, 1986.
- SHIMABUKURO, Y. E.; SMITH, J.A. The least-squares mixing models to generate fraction images derived from remote sensing multispectral data. IEEE Transactions on Geoscience and Remote Sensing, v. 29, n.1, 1991, p. 16-20.
- VELINI E. D *et al.* Monitoramento dos Problemas com Macrófitas nos Reservatórios da AES. Desenvolvimento de Programas de Manejo Integrado das Principais Especies Presentes. Relatório de Projeto de Pesquisa desenvolvido para a AES Tietê – ANEEL. Botucatu, p. 56. 2002.
- VENTURIERI, A.; SANTOS, J. R. Técnicas de Classificação de Imagens para Análise de Cobertura Vegetal. In: ASSAD, E. D.; SANO, E. E., eds. Sistema de Informação Geográfica: Aplicações na Agricultura. ed 2. Brasília, DF. Embrapa – SPI/Embrapa-CPAC. 1998. p.351-371.
- ZHANG, J.; FOODY, G. M. A fuzzy classification of sub-urban areas land cover from remotely sensed imagery. International Journal of Remote Sensing, v. 19, n.14, 1998, p. 1487-1492.
- ZELL, A. *et al.* SNNS: Stuttgart Neural Network Simulator. User Manual, Version 4.1. Stuttgart, University of Stuttgart. 1995. 303 p.

(Recebido em abril/04. Aceito em outubro/04.)