

**MIRIAM CRISTINA ESPINHOSA**

**Utilização do Sensoriamento Remoto Orbital e  
Redes Neurais Artificiais no mapeamento de  
macrófitas aquáticas emersas em grandes  
reservatórios**

**DISSERTAÇÃO DE MESTRADO**

**Presidente Prudente**

**2004**



UNIVERSIDADE ESTADUAL PAULISTA

FACULDADE DE CIÊNCIAS E TECNOLOGIA

*Campus de Presidente Prudente*

Programa de Pós Graduação em Ciências Cartográficas

---

MIRIAM CRISTINA ESPINHOSA

**Utilização do Sensoriamento Remoto Orbital e  
Redes Neurais Artificiais no mapeamento de  
macrófitas aquáticas emersas em grandes  
reservatórios**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Cartográficas da Faculdade de Ciências e Tecnologia - UNESP, como parte dos requisitos exigidos para a obtenção do título de Mestre em Ciências Cartográficas.

Orientador: Maria de Lourdes B. T. Galo

**Presidente Prudente  
2004**

## DEDICATÓRIA

Primeiramente, a Deus, pelo dom da vida.

Aos meus pais Jaime e Maria, pelo amor e exemplo, sempre demonstrando seu apoio e compreensão nos momentos de ausência.

Aos meus irmãos: Paulo e Meire, e cunhados (Lucilene e Luis), em especial, a minha sobrinha Maria Paula, e meu sobrinho (a) que ainda está por vir, pelo estímulo dado nos momentos difíceis e pela descontração e carinho nas horas de alegria.

Ao Carlos Eduardo, pelo amor, carinho, incentivo nos momentos de desânimo e compreensão nos de ausência.

A Nilcilene (Aninha), pela grande amizade demonstrada em vários anos de convivência e pelas horas de descontração e companheirismo que serão jamais esquecidas.

## AGRADECIMENTOS

- A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo auxílio financeiro dado a essa pesquisa com a concessão de uma bolsa.
- A coordenação do Projeto AES/TIETÊ de Monitoramento dos Problemas com Macrófitas nos reservatórios da AES, pela disponibilização de grande parte dos dados utilizados nesse projeto.
- A Professora Doutora Maria de Lourdes B. T. Galo, pelo incentivo e confiança na elaboração desta dissertação.
- A todos os docentes do PPGCC, do Departamento de Cartografia pela colaboração imprescindível a esse trabalho, e ao professor Mauricio Galo pelo apoio técnico prestado.
- A todos os funcionários da FCT/UNESP, pela atenção e disposição, que de forma indireta contribuíram para a realização deste trabalho.
- Aos amigos Nilcilene Medeiros, Leticia Sabo, Narjara Cruz, Zaqueu Rodrigues e Marcelo Holzschuh, pelo auxílio prestado ao desenvolvimento da pesquisa e pelo companheirismo.
- Aos amigos: Sandra, Laysson, Juliana, William Dal Poz, Juliano Fazan, Giovani, Edmur, Luiz Fernando, Jaqueline, Marcelo Tomio, Edgar, Camila, Daniela, Marco Aurélio, Claudinei, Mário, André, Christiane, Willian Kim, Roberto Ruy, Rodrigo Bezerra, Rodrigo Zanin, Eniuce, Edinéia, Leonardo, Christopher, Carlos Alexandre, Vantier, Amanda, Augusto, Ligia, Danilo, Luiz, Marlon, Neimer, Eduardo, Pará, Édrig, Clayton, Carlos Renato, Marcel, prof. Otávio, prof. Erivaldo e Marcelo Araújo.
- Aos amigos que não estão presentes Mario Alexandre, Natacha, Marcelo (Uberaba), e meus irmãos de coração Marcelo Zuliani, Alessandro Emerich e Camilla Remeli, que mesmo distantes, me apoiaram e se mostraram companheiros e amigos, e, para aqueles que direta e indiretamente contribuíram pra realização desse trabalho.

## **EPÍGRAFE**

*“O tempo não é algo que possa voltar atrás,  
portanto plante seu jardim e decore sua alma, ao  
invés de esperar que alguém lhe traga flores”*

(Shakespeare)

## RESUMO

A utilização de dados de Sensoriamento Remoto em conjunto com técnicas de processamento digital e análise de imagens tem possibilitado o desenvolvimento de estudos integrados, com vistas ao monitoramento dos recursos naturais. Uma maneira de representar esses dados é através de mapas temáticos, obtidos por métodos de classificação multiespectral. Para a classificação de dados de Sensoriamento Remoto, a utilização de Redes Neurais Artificiais tem se apresentado como uma alternativa vantajosa em relação aos classificadores baseados em conceitos estatísticos, uma vez que nenhuma hipótese prévia sobre a distribuição dos dados a serem classificados é exigida. Assim, esse trabalho teve como objetivo detectar a ocorrência e mapear a dispersão espacial de plantas aquáticas emersas em cinco reservatórios ao longo do rio Tietê-SP (Barra Bonita, Bariri, Ibitinga, Promissão e Nova Avanhandava) através da classificação por Redes Neurais Artificiais. Para a realização da classificação usando o simulador SNNS da Universidade de *Stuttgart*, uma Rede Neural Artificial multicamadas foi treinada com o algoritmo “*backpropagation*”, a partir de amostras representativas das áreas infestadas por plantas aquáticas no reservatório de Barra Bonita, o qual apresentava maior infestação dessas plantas. Essa rede foi aplicada aos demais reservatórios visando identificar as mesmas classes de saída estabelecidas. Os dados de entrada para a rede 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. O procedimento metodológico adotado mostrou-se adequado para o mapeamento de variações espectrais de água e para detecção de locais de infestação por plantas aquáticas emersas, e os resultados obtidos mostraram que a classificação pela rede neural, treinada e aplicada a esses reservatórios foi satisfatória. Além disso, foi realizada uma verificação da ambigüidade entre as classes de saída espectralmente similares, através da tabulação cruzada dos planos de informação gerados pelos valores de ativação de saída da rede, permitindo explicitar as classes que apresentavam maior confusão na área de treinamento de Barra Bonita.

**Palavras Chaves:** Redes Neurais Artificiais; Análise de Mistura Espectral; Ambigüidade entre Classes.

## ABSTRACT

Remote sensing data and digital image analysis has allowed to develop integrated studies in mapping and monitoring of the natural resources. The information extracted from these data is mainly obtained by multispectral classification methods. Artificial Neural Networks (ANN) applied to remote sensing data classification can be an interesting alternative compared to usual classifiers based on statistical concepts, since no previous hypothesis about the distribution of data to be classified is required. In this context, the purpose of this research is to detect the occurrence and map the spatial dispersion of the aquatic plants in five reservoirs of the Tietê river, using ANN. To developed a supervised classification, a multilayer neural net was trained from representative samples extracted in Barra Bonita reservoir, using backpropagation algorithm. This net trained was applied to Bariri, Ibitinga, Promissão and Nova Avanhandava reservoirs, in order to identify the same classes defined to Barra Bonita. The classification input data was constituted by three images derived from a linear mixing model applied to ETM+/Landsat spectral bands. The method used was adequated to map the water spectral variation and detect infested areas of aquatic macrophytes. Additionally, the results obtained showed that the neural network trained to Barra Bonita, classified the same classes in the other reservoirs. Furthermore, the ambiguity analysis of the spectrally similar classes was developed by crossing comparison of images of the individual classes, generated by ANN output values.

**Keywords:** Artificial Neural Networks, Spectral Mixing Analysis, Ambiguity Analysis

## SUMÁRIO

<b>DEDICATÓRIA.....</b>	<b>3</b>
<b>AGRADECIMENTOS.....</b>	<b>4</b>
<b>EPÍGRAFE.....</b>	<b>5</b>
<b>RESUMO.....</b>	<b>6</b>
<b>ABSTRACT.....</b>	<b>7</b>
<b>SUMÁRIO.....</b>	<b>8</b>
<b>LISTA DE FIGURAS.....</b>	<b>11</b>
<b>LISTA DE TABELAS.....</b>	<b>13</b>
<b>1 INTRODUÇÃO.....</b>	<b>14</b>
1.1 Contextualização do Problema.....	14
1.2 Objetivos.....	16
1.3 Justificativa.....	17
1.4 Estrutura do trabalho.....	18
<b>2 FUNDAMENTAÇÃO TEÓRICA.....</b>	<b>19</b>
2.1 Aspectos básicos do Sensoriamento Remoto.....	19
2.1.1 Comportamento Espectral da Água.....	22
2.1.2 Comportamento Espectral da Vegetação.....	24
2.2 Processamento Digital e Análise de Imagens Multiespectrais.....	25
2.3 Modelo Linear de Mistura Espectral.....	27

2.4	Classificação de dados de Sensoriamento Remoto.....	28
2.5	Redes Neurais Artificiais .....	30
2.6	Ambigüidade entre Classes.....	43
<b>3</b>	<b>MATERIAIS E MÉTODOS.....</b>	<b>47</b>
3.1	Estudo de Caso.....	47
3.2	Material e Equipamentos.....	48
3.2.1	Dados Multiespectrais de Sensoriamento Remoto.....	48
3.2.2	Ferramentas Computacionais utilizadas no processamento e análise dos dados.....	50
3.3	Procedimento Metodológico.....	54
3.3.1	ETAPA 1 – Treinamento e Aplicação da RNA ao Reservatório de Barra Bonita.....	59
3.3.2	ETAPA 2 – Aplicação da rede treinada na classificação dos reservatórios de Bariri, Ibitinga, Promissão e Nova Avanhandava.....	67
3.3.3	ETAPA 3 – Análise da Ambigüidade das Classes de Saída na área de treinamento de Barra Bonita.....	68
<b>4</b>	<b>RESULTADOS E ANÁLISES.....</b>	<b>71</b>
4.1	Imagens-Fração derivadas do Modelo de Mistura Espectral: Dados de entrada da RNA.....	71
4.2	Características das Amostras de Treinamento e Validação da RNA para Barra Bonita.....	77
4.3	Arquiteturas de Redes Neurais Artificiais testadas.....	82
4.4	Classificação resultante da aplicação da RNA às áreas de treinamento e validação.....	85

4.5	Classificação resultante da aplicação da RNA treinada ao Reservatório de Barra Bonita.....	87
4.6	Classificação resultante da aplicação da RNA treinada aos reservatórios de Bariri, Ibitinga, Promissão e Nova Avanhandava.....	89
4.7	Ambigüidade entre as Classes de Saída: Água e Macrófitas.....	93
<b>5</b>	<b>CONCLUSÕES E RECOMENDAÇÕES FINAIS.....</b>	<b>103</b>
	<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>107</b>
	<b>BIBLIOGRAFIA CONSULTADA.....</b>	<b>111</b>

## LISTA DE FIGURAS

FIGURA 2.1 -	Curva média da vegetação fotossinteticamente ativa.....	24
FIGURA 2.2 -	Diagrama esquemático de uma RNA <i>“feedforward”</i> com duas camadas escondidas.....	34
FIGURA 2.3 -	Modelo de um neurônio não linear.....	36
FIGURA 2.4 -	Funções de ativações mais utilizadas nas RNAs.....	38
FIGURA 2.5 -	Rede Multicamadas <i>“Feedforward”</i> com retro-propagação do erro.....	39
FIGURA 2.6 -	Exemplo de função de pertinência para conjunto (a) <i>booleano</i> ; (b) <i>fuzzy</i> .....	44
FIGURA 3.1 -	Ilustração destacando os reservatórios em estudo ao longo do Rio Tietê.....	48
FIGURA 3.2 -	Distribuição das imagens orbitais ETM+/Landsat, pelas respectivas órbitas/ponto, indicando os reservatórios de interesse.....	49
FIGURA 3.3 -	Fluxograma ilustrando as atividades desenvolvidas.....	55
FIGURA 3.4 -	(a) Contorno do rio – AES; (b) Delimitação da área de estudo, contendo o reservatório de Barra Bonita (identificador igual a 1) e o fundo (com identificador igual a zero).....	58
FIGURA 3.5 -	(a) Imagem ilustrando a delimitação do espelho d’água nas imagens-fração água; (b) solo; (c) vegetação; com intervalo de valores de brilho entre 0-255.....	59
FIGURA 4.1 -	Imagens-fração correspondentes às componentes “puras” água (a); solo (b) e vegetação (c), resultantes da aplicação do modelo linear de mistura espectral.....	73
FIGURA 4.2 -	Imagens-fração correspondentes às componentes água, solo e vegetação, resultantes da aplicação do modelo linear de mistura espectral dos reservatórios de Bariri, Ibitinga, Promissão e Nova Avanhandava.....	75
FIGURA 4.3 -	Localização das amostras de treinamento e validação na área de estudo contendo o reservatório de Barra Bonita.....	78
FIGURA 4.4 -	Média e desvio padrão dos NDs das classes extraídas a partir de cada plano de entrada para a amostra de Treinamento.....	80

FIGURA 4.5 - Média e desvio padrão dos NDs das classes extraídas a partir de cada plano de entrada para a amostra de Validação.....	81
FIGURA 4.6 - Configuração final da Rede Neural Artificial.....	83
FIGURA 4.7 - Arquivos das classes de saída, na forma descritiva, gerado a partir da classificação pelo programa de conversão snns-pbm.....	84
FIGURA 4.8 - Classificação resultante da aplicação da arquitetura [3-21-11-5] a área de treinamento.....	86
FIGURA 4.9 - Classificação resultante da aplicação da arquitetura [3-21-11-5] a área de validação.....	86
FIGURA 4.10 - Imagem resultante da classificação do reservatório de Barra Bonita a partir da aplicação da arquitetura [3-21-11-5].....	88
FIGURA 4.11 - Classificação resultante da aplicação da RNA treinada ao reservatório de Bariri.....	90
FIGURA 4.12 - Classificação resultante da aplicação da RNA treinada ao reservatório de Ibitinga.....	91
FIGURA 4.13 - Classificação resultante da aplicação da RNA treinada ao reservatório de Promissão.....	91
FIGURA 4.14 - Classificação resultante da aplicação da RNA treinada ao reservatório de Nova Avanhandava.....	92
FIGURA 4.15 - Arquivo de saída da rede <i>snns-pbm</i> associando as classes de saída com seus respectivos valores de ativação.....	94
FIGURA 4.16 - Grau de associação dos <i>pixels</i> com a classe “Água1”.....	95
FIGURA 4.17 - Grau de associação dos <i>pixels</i> com a classe “Água2”.....	96
FIGURA 4.18 - Grau de associação dos <i>pixels</i> com a classe “Macrófita1”.....	96
FIGURA 4.19 - Grau de associação dos <i>pixels</i> com a classe “Macrófita2”.....	97
FIGURA 4.20 - Grau de associação dos <i>pixels</i> com a classe “Fundo”.....	98
FIGURA 4.21 - Imagem resultante da tabulação cruzada entre os planos de informação “Água1” e “Água2”.....	99
FIGURA 4.22 - Imagem resultante da tabulação cruzada entre os planos de informação “Macrófita1” e “Macrófita2”. .....	101

## LISTA DE TABELAS

Tabela 2.1 -	Principais aplicações das bandas espectrais do sensor ETM+ do satélite Landsat.....	21
Tabela 3.1 -	Datas de tomada das imagens selecionadas para a realização do monitoramento a partir de dados ETM+/ Landsat.....	49
Tabela 4.1 -	Valores obtidos a partir da amostragem dos <i>pixels</i> “puros” identificados na imagem de Barra Bonita.....	71
Tabela 4.2 -	Erro por banda e erro total de estimação dos reservatórios ao longo do rio Tietê.....	72
Tabela 4.3 -	Matriz de Correlação entre as bandas multiespectrais ETM+/Landsat e as imagens-fração água, solo e vegetação.....	76
Tabela 4.4 -	Média e desvio padrão dos NDs (Números Digitais) das classes extraídos a partir de cada plano de entrada para a amostra de Treinamento.....	79
Tabela 4.5 -	Média e desvio padrão dos NDs das classes extraídos a partir de cada plano de entrada para a amostra de Validação.....	80
Tabela 4.6 -	Resumo das simulações realizadas para o treinamento da rede.....	83
Tabela 4.7 -	Proporção de <i>pixels</i> associados a cada classe na amostra de validação.....	85
Tabela 4.8 -	Proporção de <i>pixels</i> classificados para o reservatório de Barra Bonita.....	88
Tabela 4.9 -	Proporção de <i>pixels</i> classificados para os demais reservatórios em estudo..	89
Tabela 4.10 -	Proporção de <i>Pixels</i> atribuídos às classes: “água1” (colunas) com “água2” (linhas), com mesmo grau de associação.....	100
Tabela 4.11 -	Proporção de <i>Pixels</i> atribuídos às classes: “macrófita1” (colunas) com “macrófita2” (linhas), com mesmo grau de associação.....	102

## 1 INTRODUÇÃO

### 1.1 Contextualização do Problema

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).

Nos últimos anos as plantas aquáticas estão sendo estudadas como um efeito do desequilíbrio causado pela poluição e represamento dos rios. A quantidade excessiva de plantas, conseqüente desse desequilíbrio, dificulta tanto a navegação como a produção de energia elétrica. O Sensoriamento Remoto pode se constituir em uma ferramenta útil para monitorar a ocorrência dessas plantas, 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 métodos tradicionais de classificação de dados de Sensoriamento Remoto baseiam-se nas características espectrais do *pixel*, alocando-o a um único tipo de cobertura da terra desconsiderando a resposta gerada pela combinação de uma ou mais classes (GALO, 2000a). Assim, uma situação comum quando da utilização desses dados é a ocorrência de *pixels* misturados, geralmente decorrentes da pequena resolução das imagens orbitais e da ambigüidade entre as classes temáticas resultantes do processo de classificação.

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. Os modelos de mistura espectral consideram que, em muitas situações, a reflectância espectral observada pode ser modelada como uma combinação linear de componentes puros. Dessa forma, uma análise linear de mistura espectral pode ser usada para separar proporcionalmente os componentes de cada *pixel* da cena, estimar a proporção de cada componente dentro de cada elemento de resolução e gerar imagens frações correspondentes (GALO, 2000b).

No que se refere à classificação de dados de Sensoriamento Remoto a utilização de Redes Neurais Artificiais tem se apresentado como uma alternativa vantajosa em relação aos classificadores baseados em conceitos estatísticos (convencionais), uma vez que nenhuma hipótese prévia sobre a distribuição dos dados a serem classificados é exigida 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 Redes Neurais Artificiais 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), podendo assim resultar numa delimitação incorreta das classes. 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 neural.

## 1.2 Objetivos

O objetivo deste trabalho é aplicar uma Rede Neural Artificial na classificação de plantas aquáticas emersas (macrófitas) que ocorrem em alguns dos grandes reservatórios do rio Tietê-SP (Barra Bonita, Bariri, Ibitinga, Promissão e Nova Avanhandava). Para isso, foram utilizados dados multiespectrais de Sensoriamento Remoto e técnicas de processamento digital e análise de imagens, com o intuito de avaliar as questões relacionadas com a detecção das ocorrências de plantas aquáticas e de variações na água, presentes nesses reservatórios, bem como analisar a ambigüidade entre as classes de saída obtidas através da classificação pela Rede Neural Artificial.

Nesse sentido, inicialmente uma Rede Neural foi dimensionada, utilizando o Simulador de Redes Neurais Artificiais da Universidade de *Stuttgart* (SNNS), e treinada a partir de amostras representativas das áreas infestadas por plantas aquáticas presentes no Reservatório de Barra Bonita. Essa rede treinada foi então aplicada a outros reservatórios ao longo do rio Tietê, de modo a discriminar as classes de saída estabelecidas, ou seja, a reconhecer as mesmas ocorrências identificadas no primeiro reservatório. A possibilidade de

se desenvolver essa abordagem foi sustentada pelo fato de que, em estudos anteriores<sup>1</sup>, verificou-se que a presença das plantas aquáticas emersas nos demais reservatórios ao longo do rio Tietê, está associada ao seu deslocamento a partir de Barra Bonita.

A questão da ambigüidade entre as classes associadas à algumas classes de interesse foi verificada apenas para uma área teste (área de treinamento) previamente definida no reservatório de Barra Bonita, através da tabulação cruzada dos planos de informação gerados a partir dos valores de ativação fornecidos pela Rede Neural Artificial, para cada ocorrência de interesse.

### **1.3 Justificativa**

A ocorrência de plantas aquáticas em reservatórios para geração de energia elétrica no Brasil tem sido um problema de importância crescente, visto que algumas hidrelétricas já têm sua eficiência comprometida pela elevada infestação de plantas aquáticas emersas e imersas. Um dos problemas que essas plantas podem causar é o entupimento das grades de proteção das turbinas por grandes massas das plantas imersas. O desenvolvimento excessivo dessas plantas tem prejudicado a utilização da água para a navegação, a geração de energia em usinas hidrelétricas e a captação de água para irrigação e consumos humano e animal em diversos países.

O controle das macrófitas aquáticas tornou-se, então, alvo de estudos intensos nos últimos anos, devido aos prejuízos provocados por esse tipo de vegetação nos reservatórios e usinas hidrelétricas, exigindo constante manutenção de grades de tomada de água das turbinas de hidrelétricas, o que muitas vezes interrompe a geração de energia. Devido a esses problemas e ao alto custo do controle mecânico, vários estudos vêm sendo

---

<sup>1</sup> Resultados referentes a essa análise são descritos em Galo *et al.*, 2002a.

realizados com o intuito de otimizar o processo, ou mesmo encontrar alternativas para um possível manejo. A utilização de metodologias que incorporem uma representação da dispersão espacial dessas plantas aquáticas, e procedimentos de classificação podem se constituir em um primeiro passo no sentido de fornecer informações relacionadas ao grau de infestação dos reservatórios do rio Tietê e, com isso, contribuir para o estabelecimento de programas de manejo integrados para reservatórios de grande porte.

#### **1.4 Estrutura do trabalho**

Neste primeiro capítulo é feita a introdução do trabalho, contextualizando o problema abordado e especificando os objetivos e justificativa. No segundo capítulo faz-se uma revisão das bases conceituais dos temas relacionados com o desenvolvimento metodológico proposto. O terceiro capítulo refere-se a uma descrição do estudo de caso, dos materiais e equipamentos utilizados, assim como da metodologia desenvolvida para operacionalizar a pesquisa. A apresentação e análise dos resultados constam no quarto capítulo, enquanto que no quinto capítulo são apresentadas as conclusões do trabalho, face aos objetivos propostos.

## **2 FUNDAMENTAÇÃO TEÓRICA**

### **2.1 Aspectos básicos do Sensoriamento Remoto**

O Sensoriamento Remoto pode ser definido como sendo a utilização conjunta de modernos sensores, equipamentos para processamento de dados, equipamentos de transmissão de dados, aeronaves e espaçonaves, que têm por objetivo o estudo do ambiente terrestre, sem o contato físico direto com os alvos da superfície, através do registro e análise das interações entre a radiação eletromagnética e as substâncias componentes do planeta Terra em suas diversas manifestações (NOVO, 1989).

Os elementos da superfície terrestre podem ser investigados através de imagens que registrem suas condições, sendo analisadas através de técnicas e ferramentas específicas. Para aquisição de dados, 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 interage com os alvos da superfície terrestre podendo ser absorvida, refletida, transmitida e emitida por eles seletivamente. Com o desenvolvimento tecnológico atual, é possível medir com razoável precisão e à distância, as propriedades espectrais desses alvos. O uso de sistema 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. Dentre a grande variedade de equipamentos que apresentam essa capacidade podem ser citados os sistemas imageadores, os quais fornecem como produto uma imagem da cena observada.

Conforme descreve Novo (1989), os diferentes sistemas sensores ou sistemas imageadores são caracterizados pela sua resolução, definida como uma medida da

habilidade que o sensor possui de distinguir entre respostas espectralmente semelhantes e espacialmente próximas, sendo classificados quanto à resolução espacial, que mede a menor separação linear ou angular entre dois objetos da superfície terrestre; resolução espectral, que é uma medida da largura das faixas espectrais nas quais o sensor opera; resolução radiométrica, relacionada com a sensibilidade do sensor em distinguir entre dois níveis de intensidade do sinal de retorno; e resolução temporal, relativa ao intervalo de tempo entre a aquisição de duas imagens de uma mesma área.

A aquisição de dados de Sensoriamento Remoto com aplicação em recursos naturais pode ser feita através de sensores instalados em plataformas orbitais. Dentre os sistemas sensores atualmente em operação, pode ser destacado o sensor ETM+ – *Enhanced Thematic Mapper Plus* (instalado a bordo do satélite Landsat 7). O sistema Landsat é o sistema de coleta de dados orbitais mais conhecido e permite a aquisição repetitiva de dados multiespectrais da superfície terrestre. O sensor ETM+ do satélite Landsat 7, lançado em abril de 1999, é o mais recente satélite em operação da série e tem características técnicas semelhantes ao sensor TM (instalado a bordo do satélite 4 e 5), que possui sete bandas espectrais, sendo que seis destas bandas operam na região refletida do espectro óptico e apresentam uma resolução espacial de 30 metros no terreno. A outra banda espectral, designada como banda TM6, capta a radiação termal e tem uma resolução espacial de 120 metros. No sensor ETM+ do satélite Landsat 7 foi adicionado um detector que opera uma banda pancromática com resolução espacial de 15 metros, e a banda termal teve sua resolução melhorada de 120 para 60 metros.

Na Tabela 2.1 são apresentadas as principais bandas espectrais do sensor ETM+, assim como os intervalos de comprimento de onda que as define e suas principais aplicações.

Tabela 2.1 - Principais aplicações das bandas espectrais do sensor ETM+ do satélite Landsat.

<b>Banda</b>	<b>Intervalo Espectral (µm)</b>	<b>Região do Espectro Eletromagnético</b>	<b>Principais Características</b>
1	0,45 – 0,52	Azul – Visível	<ul style="list-style-type: none"> <li>- Penetração em corpos de água.</li> <li>- Sofre absorção pela clorofila e pigmentos fotossintéticos.</li> <li>- Sensibilidade à fumaça.</li> </ul>
2	0,52 – 0,60	Verde – Visível	<ul style="list-style-type: none"> <li>- Apresenta grande sensibilidade à presença de sedimentos em suspensão.</li> <li>- Boa penetração em corpos de água.</li> </ul>
3	0,63 – 0,69	Vermelho – Visível	<ul style="list-style-type: none"> <li>- A vegetação verde, densa e uniforme, apresenta absorção.</li> <li>- Apresenta bom contraste entre diferentes tipos de cobertura vegetal.</li> <li>- Permite análise da variação litológica em regiões com pouca cobertura vegetal.</li> <li>- Permite o mapeamento da drenagem.</li> <li>- Banda mais utilizada para delimitar a mancha urbana.</li> <li>- Permite a identificação de áreas agrícolas.</li> </ul>
4	0,76 - 0,90	Infravermelho Próximo	<ul style="list-style-type: none"> <li>- Os corpos de água absorvem energia.</li> <li>- A vegetação verde, densa e uniforme, reflete muita energia nesta banda.</li> <li>- Apresenta sensibilidade à rugosidade da copa das florestas (dossel florestal).</li> <li>- Apresenta sensibilidade à morfologia do terreno.</li> <li>- Serve para análise e mapeamento de feições geológicas e estruturais.</li> <li>- Serve para separar e mapear áreas ocupadas com pinus e eucalipto.</li> <li>- Serve para mapear áreas ocupadas com vegetação que foram queimadas.</li> <li>- Permite a visualização de áreas ocupadas com macrófitas aquáticas emersas.</li> <li>- Permite a identificação de áreas agrícolas.</li> </ul>
5	1,55– 1,75	Infravermelho Médio	<ul style="list-style-type: none"> <li>- Apresenta sensibilidade ao teor de umidade das plantas, servindo para observar estresse na vegetação, causado por desequilíbrio hídrico.</li> <li>- Esta banda sofre perturbações em caso de ocorrer excesso de chuva antes da obtenção da cena pelo satélite.</li> </ul>
6	10,4– 12,5	Infravermelho Termal	<ul style="list-style-type: none"> <li>- Apresenta sensibilidade aos fenômenos relativos aos contrastes térmicos, servindo para detectar propriedades termais de rochas, solos, vegetação e água.</li> </ul>
7	2,08 – 2,35	Infravermelho Médio	<ul style="list-style-type: none"> <li>- Apresenta sensibilidade à morfologia do terreno.</li> <li>- Identificação de minerais.</li> <li>- Potencialmente favorável à discriminação de produtos de alteração hidrotermal.</li> </ul>
8	0,52 – 0,9	Pancromático (Visível/Infravermelho Próximo)	<ul style="list-style-type: none"> <li>- Áreas Urbanas</li> </ul>

Fonte: Adaptado de Engesat, 2002.

Para que se possam extrair informações a partir de dados de Sensoriamento Remoto, é de suma importância o conhecimento do comportamento dos objetos da superfície terrestre e dos fatores que interferem nesse comportamento.

O conhecimento do comportamento espectral de alvos é imprescindível não somente para a extração de informações a partir das imagens obtidas pelos sensores, mas também na definição de novos sensores e do tipo de pré-processamento a que devem ser submetidos os dados brutos, ou mesmo na definição da forma de aquisição dos dados (geometria de coleta de dados, frequência, altura do imageamento, resolução limite, etc.) (NOVO, 1989).

As condições de coleta de dados envolvem o conhecimento não só dos instrumentos utilizados, como também das condições experimentais em que se realizaram as medidas. Portanto, para a interpretação dos dados espectrais é necessário um conhecimento adequado das condições experimentais em que os mesmos foram tomados. Essa é uma das grandes dificuldades encontradas quando as interpretações são baseadas em curvas espectrais adquiridas em literatura internacional, visto que raramente as condições experimentais são reportadas em sua totalidade (NOVO, 1989).

A seguir é tratado o comportamento espectral apenas dos componentes da superfície terrestre de interesse nesse trabalho: água e vegetação.

### **2.1.1 Comportamento Espectral da Água**

De acordo com Curran (1983), diferente da vegetação ou do solo, a maior parte do fluxo radiante incidente sobre água não é refletido, mas absorvido ou transmitido. Nos comprimentos de onda da radiação eletromagnética 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, o que resulta em um forte contraste entre a água e os limites de terra. Ainda segundo esse autor, 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.

A água apresenta-se na natureza sob diferentes estados físicos que influenciam de modo fundamental no seu comportamento espectral. No estado líquido a mesma apresenta baixa reflectância entre 0,38  $\mu\text{m}$  e 0,70  $\mu\text{m}$  ( $\rho < 0,1$ ), absorvendo toda a radiação acima de 0,7  $\mu\text{m}$ .

Novo e Shimabukuro (1994), argumentam que os componentes da água absorvem seletivamente a luz que chega ao volume d'água, sendo essa absorção máxima em alguns comprimentos de onda. Os pigmentos fotossinteticamente ativos são responsáveis pela absorção nas regiões espectrais do azul e do vermelho, de modo que um aumento na quantidade de fitoplâncton na água produz redução na quantidade dessa energia e a cor da água é percebida como verde. A matéria orgânica dissolvida é também responsável por mudanças no coeficiente de absorção da água, ocorrendo um máximo na região do azul e decrescendo com o comprimento de onda. Como consequência, a cor da água muda no azul (água limpa) e verde (água rica em fitoplâncton) para o amarelo, conforme o aumento da quantidade dos componentes orgânicos dissolvidos. Tem-se, dessa forma, que a água limpa reflete pouca energia na região do visível e praticamente nenhuma energia na região do infravermelho, enquanto que a água turbida (com sedimentos em suspensão) reflete mais energia, porém somente na região do visível (FLORENZANO, 2002).

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 através de Sensoriamento Remoto têm se limitado à detecção de particulados em suspensão e de vegetação aquática emersa (VELINI *et al*, 2002).

### 2.1.2 Comportamento Espectral da Vegetação

Segundo Moreira (2001), ao interagir com a cobertura vegetal, a radiação solar que chega na superfície da Terra se decompõe em três frações: uma parte 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).

Novo (1989) ressalta que através da análise da curva espectral média da vegetação fotossinteticamente ativa, ilustrada na Figura 2.1, pode-se identificar três regiões distintas ao longo do espectro eletromagnético, em função dos fatores que condicionam seu comportamento:




FIGURA 2.1 - Curva média da vegetação fotossinteticamente ativa.

Fonte: Novo, 1989.

- a. até 0,7  $\mu\text{m}$ , a reflectância é baixa ( $< 0,2$ ), dominando a absorção da radiação incidente pelos pigmentos da planta em 0,48  $\mu\text{m}$  (*carotenóides*) e em 0,62  $\mu\text{m}$  (*clorofila*). Em 0,56  $\mu\text{m}$ , há um pequeno aumento do coeficiente de reflectância, não atingindo, porém, níveis superiores a 0,1. É a reflectância responsável pela percepção da cor verde da vegetação;
- b. de 0,7  $\mu\text{m}$  a 1,3  $\mu\text{m}$ , tem-se a região dominada pela alta reflectância da vegetação ( $0,3 < \rho < 0,4$ ), devido estrutura celular da vegetação;
- c. entre 1,3  $\mu\text{m}$  e 2,5  $\mu\text{m}$ , a reflectância da vegetação é dominada pelo conteúdo da água das folhas. Nessa região, encontram-se dois máximos de absorção pela água: em 1,4  $\mu\text{m}$  e 1,95  $\mu\text{m}$ , correspondentes também às bandas de absorção atmosférica.

## 2.2 Processamento Digital e Análise de Imagens Multiespectrais

Nas últimas décadas, a utilização de computadores nos procedimentos de extração de informação a partir de dados de Sensoriamento Remoto tem sido realizada com relativo sucesso, possibilitando o desenvolvimento de análises direcionadas à caracterização dos processos ambientais (GALO, 2000a).

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. O autor acrescenta que, em conjunto com a área de abrangência da cena considerada e com o número de bandas espectrais disponíveis, as resoluções, espacial e radiométrica é que determinam o volume de dados que será analisado.

Uma imagem digital é numericamente formada por uma matriz bidimensional, onde linhas e colunas definem as coordenadas espaciais de um *pixel*, ao qual é atribuído um valor digital (nível de cinza) correspondente ao valor radiométrico registrado pelo sensor. No caso de imagens multiespectrais, cada *pixel* é radiometricamente representado por um vetor de atributos com tantas dimensões quantas forem as bandas espectrais consideradas (NOVO, 1989). Nesse sentido, o Processamento Digital de Imagens (PDI) envolve a manipulação e interpretação de dados de Sensoriamento Remoto com o auxílio de computadores, tendo por finalidade facilitar a identificação e extração das informações contidas nesses dados.

Novo (1989) classifica as técnicas de Processamento Digital de Imagens em três conjuntos: técnicas de pré-processamento, cuja aplicação permite transformar dados digitais brutos em dados corrigidos radiométrica e geometricamente; técnicas de realce, as quais visam melhorar efetivamente a visualização da cena para subsequente interpretação visual ou classificação digital; e técnicas de classificação que têm como finalidade o reconhecimento automático dos objetos da cena, a partir da análise quantitativa dos níveis de cinza. A decisão de quais técnicas aplicar em cada situação deve ser ditada pelos objetivos a serem alcançados e pelas especificidades da situação.

As técnicas de realce incluem grande variedade de procedimentos que podem implementar tanto modificações radiométricas e geométricas em uma única banda, como transformações orientadas, desenvolvidas a partir de dados multiespectrais. Uma modificação radiométrica bastante aplicada a imagens de Sensoriamento Remoto, de característica pontual e unidimensional, é a ampliação linear de contraste. Essa técnica consta do mapeamento dos valores de brilho de uma banda, cuja distribuição é representada em um histograma específico, para uma redefinição mais favorável, ou seja, expandindo adequadamente o intervalo de variação dos valores de brilho (RICHARDS, 1986).

Para muitos objetivos da classificação de imagens, o uso de dados espectrais transformados é, às vezes, mais conveniente do que se trabalhar com os originais. Dentre os métodos existentes para transformação de dados multiespectrais tem-se o modelo linear de mistura que separa as contribuições de cada material dentro do *pixel*.

### 2.3 Modelo Linear de Mistura Espectral

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 à 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 em três componentes, segundo o uso do solo (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:

$r_i$  : resposta espectral do *pixel* na banda  $i$ ;

$a, b, c$ : proporções de vegetação, solo e água, respectivamente;

$vege_i, solo_i$  e  $\acute{a}gua_i$ : respostas espectrais dos componentes vegetação, solo e água, respectivamente, e

$e_i$  : erro na banda  $i$ , e o subscrito  $i$  é a banda considerada.

O modelo linear de mistura espectral pode ser entendido como uma técnica que visa o realce das feições de interesse da imagem, com o intuito de otimizar o processo de extração de informações. Segundo Novo e Shimabukuro (1994), nesse modelo, o valor do *pixel* em cada banda espectral é considerado como a combinação linear da resposta de cada componente dentro do *pixel*. Assim, cada *pixel* contém informações sobre a proporção e a resposta espectral de cada componente. O resultado da decomposição linear é a geração de três novos componentes, sendo que cada um deles contém informações dos três constituintes “puros” do *pixel*, ou seja, vegetação, solo e água (MOREIRA, 2001).

Como ilustração, considerando a resolução espacial do sensor TM de 30 m, um *pixel* pode representar a resposta espectral de mais de um alvo. Essa mistura de constituintes no *pixel* pode afetar a análise dos dados do Sensoriamento Remoto, sendo que muitas técnicas de processamento de imagens supõem que os *pixels* sejam “puros” e representam áreas homogêneas na superfície terrestre. Conseqüentemente, feições de interesse podem ser mascaradas na análise, agregando num mesmo *pixel* diferentes alvos.

## **2.4 Classificação de dados de Sensoriamento Remoto**

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. Nesse processo, os sistemas computacionais auxiliam o usuário na extração de informações a partir das imagens orbitais (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 qualquer conhecimento prévio sobre as classes existentes na imagem e é definida, sem a interferência do analista, a estratificação da cena, atribuindo a cada *pixel* uma determinada classe espectral (VENTURIERI e SANTOS, 1998).

Por outro lado, o método de classificação é dito supervisionado quando implica na interação do intérprete humano e o sistema de análise e, além disso, esse intérprete tem um conhecimento prévio da cena, o que o habilita a fornecer informações específicas, possibilitando o treinamento do algoritmo de classificação. Normalmente, as abordagens de classificação supervisionada baseiam-se no uso de amostras para estimar os parâmetros estatísticos para cada classe. Essas amostras são chamadas de padrões de treinamento, sendo que a totalidade das amostras define o conjunto de treinamento. O processo pelo qual um conjunto de treinamento é usado para obter as funções de decisão é denominado aprendizagem ou treinamento (GONZALES e WOODS, 2000).

Dentro do contexto de classificação supervisionada, o uso de Redes Neurais Artificiais tem se apresentado como uma nova alternativa no processo de classificação de dados de Sensoriamento Remoto. Muitas vezes, as propriedades estatísticas de uma classe não podem ser estimadas, de modo que os problemas de teoria de decisão são melhor trabalhados pelos métodos de classificação que produzem diretamente as funções de decisão através dos dados de treinamento (GONZALEZ e WOODS, 2000). A utilização de modelos de Redes Neurais Artificiais em classificação, por sua vez possibilita a incorporação não apenas de dados multiespectrais, mas de dados adquiridos por outras fontes, que não apresentem natureza espectral. Nessas situações, as redes neurais parecem desempenhar a tarefa de classificação de imagens tão bem, ou melhor, que as técnicas estatísticas, uma vez que não

requerem que a natureza paramétrica dos dados a serem classificados seja explicitada (GALO, 2000a).

## 2.5 Redes Neurais Artificiais

Segundo Raia (2000), o primeiro estudo sobre Redes Neurais teria sido publicado em 1943, por McCulloch e Pitts, denominado *A Logical Calculus of the Ideas Immanent in Nervous Activity*, e que, ainda hoje, é considerado como referência básica para o desenvolvimento de Redes Neurais Artificiais. O estudo propunha uma modelagem do neurônio artificial, como uma unidade de processamento simples, onde a rede modelada utilizava um modelo bastante simples de neurônio, tendo cada um deles entradas excitatórias e inibitórias. Assim, quando a quantidade de entradas excitatórias fosse maior que as entradas inibitórias, o neurônio seria ativado e produzia saída igual a 1. O neurônio proposto pelos autores não apresentava limiar (*threshold*), ou seja, o valor que determina se o neurônio vai responder ou não a uma certa entrada. Assim, se a entrada for menor que o limiar, o neurônio permanecerá em estado inibitório; caso contrário, ele será ativado e propagará o estímulo recebido.

Alguns anos depois, Von Newmann mostrou que, quando redundâncias eram introduzidas nas redes McCulloch-Pitts, elas poderiam continuar funcionando normalmente apesar do mau funcionamento de elementos individuais. Em 1949, Hebb propôs uma forma de aprendizado para as Redes Neurais, à qual ele denominou aprendizado *hebbiano*. Por esta lei de aprendizado, se dois neurônios estão ativos simultaneamente, a conexão entre eles deve ser reforçada (HAYKIN, 1994).

Durante os anos 1950 e início dos anos 1960, uma classe das chamadas “máquinas que aprendem”, criadas por Rosenblatt, causou grande excitação no campo de

reconhecimento de padrões. Rosenblatt acrescentou um limiar (*thresholds*) aos neurônios e propôs uma metodologia pela qual a rede poderia passar por um processo de aprendizagem, ajustando de maneira sistemática os pesos de suas sinapses. Esta rede poderia, então, “aprender” simples problemas de classificação, passando a ser chamada de *perceptron*. Porém, ainda assim, esta modelagem era limitada (RAIA, 2000).

A razão para o grande interesse nessas máquinas (*perceptrons*) foi a comprovação matemática mostrando que, quando os *perceptrons* fossem treinados com conjuntos de treinamento linearmente separáveis, convergiriam para uma solução em um número finito de passos iterativos. A solução tomaria a forma de hiperplanos capazes de separar corretamente as classes representadas pelos padrões de conjunto de treinamento (GONZALES e WOODS, 2000).

Em 1969, Minsky e Papert mostraram que a rede *perceptron* não era capaz de resolver o problema do ou-exclusivo, ou seja, ela só poderia classificar padrões que eram linearmente separáveis. A partir disso, houve um desaquecimento no estudo sobre Redes Neurais, que só voltaram à tona nos anos 80, quando alguns problemas apresentados pelo *perceptron* passaram a serem resolvidos através do uso de novos modelos. Dentre os novos modelos, pode-se citar as redes de Hopfield, a máquina de Boltzmann e as redes com várias camadas (RAIA, 2000).

RUMELHART *et al* (1986), tratando do desenvolvimento de novos algoritmos de treinamento para *perceptrons* multicamadas (*feedforward*), mudou consideravelmente a situação. Esses autores descreveram o algoritmo de aprendizado chamado de “regra delta generalizada para aprendizado de retropropagação” ou *backpropagation* que fornece um método de treinamento efetivo para máquinas de múltiplas camadas, e demonstraram que Minsky e Pappert foram excessivamente pessimistas com

relação à rede *perceptron* e que as redes com várias camadas poderiam ser capazes de solucionar problemas considerados de difícil aprendizado.

Embora não se possa mostrar que esse algoritmo de treinamento convirja para uma solução no sentido da prova análoga para o *perceptron* de uma camada, a regra delta generalizada tem sido usada com sucesso em vários problemas de interesse prático. Esse sucesso estabeleceu as máquinas do tipo *perceptron* com múltiplas camadas (*feedforward*) como um dos principais modelos de redes neurais atualmente em uso (GONZALES e WOODS, 2000).

Apesar de desenvolvimentos tais como novas regras de treinamento para máquinas multicamadas, novos modelos de redes neurais, e alguns resultados encorajadores de aplicações terem dado interesse renovado nessa área do reconhecimento de padrões, a pesquisa nessa área ainda está no início, embora os anos 90 terem sido produtivos em novos estudos sobre Redes Neurais Artificiais nos mais diversos campos de conhecimento (RAIA, 2000).

A tentativa inicial de reproduzir o alto desempenho do cérebro humano em tarefas cognitivas extremamente complexas, motivou o desenvolvimento inicial dos modelos de Redes Neurais Artificiais (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 baseadas em modelos abstratos do funcionamento do cérebro humano e tentam reproduzir sistemas biologicamente realísticos.

Dentre os benefícios da computação neural, a autora relaciona:

- i. **habilidade de aprender com exemplos:** os sistemas têm a capacidade de aprender com a experiência, objetivando melhorar seu desempenho e se adaptar a ambientes novos e dinâmicos;
- ii. **robustez:** habilidade de lidar com ruídos. As Redes Neurais Artificiais são tolerantes a falhas e podem apresentar degradação gradual, ou seja, apesar de alguma falha no sistema, continuam a fornecer respostas adequadas por um bom tempo, o que as diferencia dos sistemas convencionais, onde uma falha pode causar prejuízo do sistema como um todo;
- iii. **velocidade do processamento:** como as redes neurais consistem de um grande número de unidades de processamento operando em paralelo, elas podem trabalhar em velocidades consideráveis em relação aos métodos computacionais comuns.

Schalkoff (1992) relata que as RNAs são caracterizadas por três entidades básicas:

1. a topologia da rede, ou a interconexão das unidades neurais.
2. as características individuais desses neurônios.
3. a estratégia para seu treinamento ou aprendizado.

De acordo com Venturieri e Santos (1998), as Redes Neurais Artificiais são organizadas em camadas que definem sua estrutura topológica. 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.

A arquitetura (topologia) de uma RNA refere-se a maneira como os elementos de processamento são organizados e afeta o desempenho da rede. Dentre as arquiteturas mais usadas pode-se citar a rede multicamadas “*Feedforward*”, que é formada de:

- **camada de Entrada:** onde os dados de entrada são apresentados a rede;
- **camadas Intermediárias ou Ocultas:** onde é feita a maior parte do processamento, através das conexões ponderadas; podem ser consideradas como extratoras de características;
- **camada de Saída:** onde o resultado final é concluído e apresentado.

Embora as redes de uma camada simples (*perceptron*) estejam disponíveis desde a década de 50, elas não tiveram aplicação devido a sua habilidade limitada de classificação e pela falta de um algoritmo de treinamento, que foram incorporados nas redes neurais multicamadas “*feedforward*” muito utilizadas atualmente (SCHALKOFF, 1992).

De maneira geral, na descrição da arquitetura básica de uma rede neural multicamadas “*feedforward*”, Gonzales e Woods (2000) apresentam um modelo que consiste de camadas de neurônios estruturalmente idênticos, arranjados de modo que a saída de cada neurônio em cada camada alimente a entrada de cada um dos neurônios da camada seguinte, como ilustra a Figura 2.2.

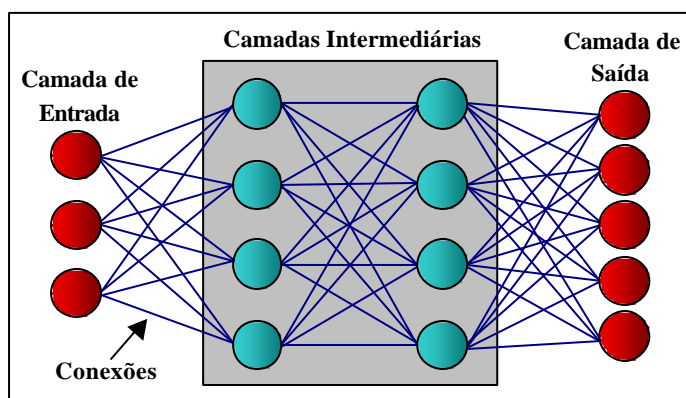


FIGURA 2.2 - Diagrama esquemático de uma RNA “*feedforward*” com duas camadas escondidas.

Gonzales e Woods (2000) esclarecem que o número de elementos de processamento (nós) da primeira camada corresponde a 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.

Em uma tentativa inicial de estabelecer ou definir o número de camadas escondidas e os números de nós que as compõem, alguns autores sugerem a utilização de regras pré-estabelecidas, como a regra ou teorema de *Kolmogorov*, que segundo Schalkoff (1992), dada uma função contínua  $\phi : I^d \rightarrow R^c$ ,  $\phi(x) = y$  onde  $I$  é o intervalo de fechamento  $[0,1]$ , e  $I^d$  é uma unidade  $d$ -dimensional,  $\phi$  pode ser representado por uma rede neural de três camadas, sendo  $d$  elementos de processamento na camada de entrada,  $(2d + 1)$  elementos de processamento na única camada escondida e  $c$  elementos de processamento na camada de saída.

Essas regras e teoremas não são muito utilizados pelos pesquisadores, mas podem ser consideradas como uma alternativa preliminar para definição do número de camadas e elementos de processamento das camadas escondidas.

De acordo com Lippmann (1987), os elementos de processamento são conectados através de pesos e cada nó produz um somatório das várias entradas, ponderadas pelos pesos de suas respectivas conexões, passando o resultado através de uma função de decisão, cujo limiar interno e o tipo da função é que caracterizam os nós. Para o autor, os modelos de redes neurais são especificados pela topologia da rede (arquitetura), as características dos nós (tipo e limiar interno da função decisão usada) e pelas regras de treinamento ou aprendizagem utilizadas.

Na descrição de uma rede neural multicamadas “*feedforward*” feita por Bocanegra (2002), o elemento fundamental de uma rede é o neurônio artificial, que consiste de uma unidade ou elemento de processamento que recebe uma ou mais entradas,

transformando-as em saída, onde cada entrada tem um peso associado, que determina sua intensidade. A Figura 2.3 mostra o esquema de um neurônio artificial.

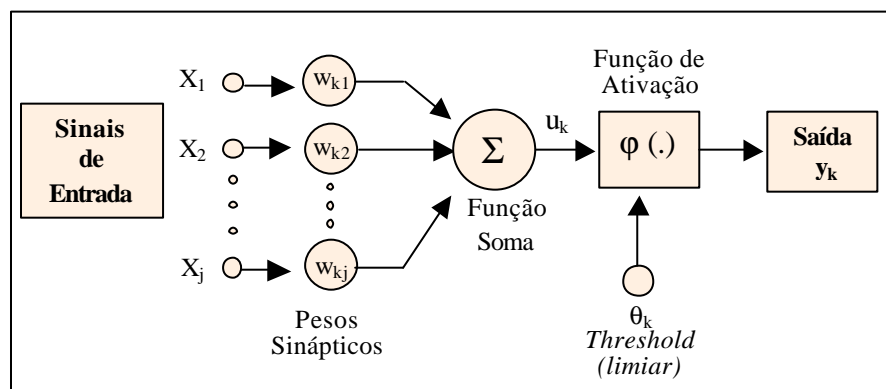


FIGURA 2.3 - Modelo de um neurônio não linear.

Fonte: Brondino, 1999.

Com base na Figura 2.3, Brondino (1999) distingui alguns elementos considerados importantes na estrutura de um neurônio artificial:

- **sinapses (conexões):** caracterizadas por um peso,  $w_{kj}$ , cujo papel é multiplicar o sinal  $x_j$  na entrada da sinapse  $j$ , conectada a um neurônio  $k$ . O peso  $w_{kj}$  é positivo se a sinapse associada é excitatória e negativo se a sinapse associada é inibitória;
- **somatório:** realiza a soma das entradas, ponderadas pelos seus respectivos pesos, ou seja, a saída  $u_k$  é definida por:

$$u_k = \sum_{i=1}^n w_{ij} x_j \quad (2)$$

- **limiar (threshold),  $q_k$ :** tem papel determinante na saída do neurônio, já que é usado para controlar a intensidade da função de ativação e obter o desempenho desejado da rede. Se o valor de  $u_k$  for menor que esse limiar  $q_k$ , então a saída do neurônio fica inibida, caso contrário, o neurônio fica ativo;

- **função de ativação:** funciona como um fator limitante à amplitude de saída do neurônio, ou seja, a entrada é normalizada dentro de um intervalo fechado, comumente  $[0,1]$  ou  $[-1,1]$ ;
- **saída do neurônio,  $y_k$ :** corresponde ao valor de saída, especificado por:

$$y_k = \varphi (u_k - \theta_k) \quad (3)$$

onde,  $\varphi$  é a função de ativação.

Segundo Raia (2000), a função de ativação define a saída do neurônio, em termos de nível de atividade do mesmo. Costa (2003) destaca que dentre as funções de ativação as mais comuns são as funções: Linear, Linear por Partes, *Threshold* ou limiar e Sigmóide Logística. Os gráficos referentes a essas funções são ilustrados na Figura 2.4. Para a construção de Redes Neurais Artificiais a função sigmóide é a função mais utilizada.

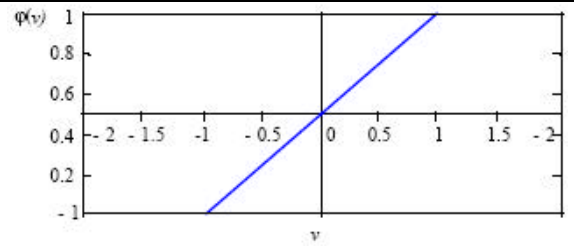
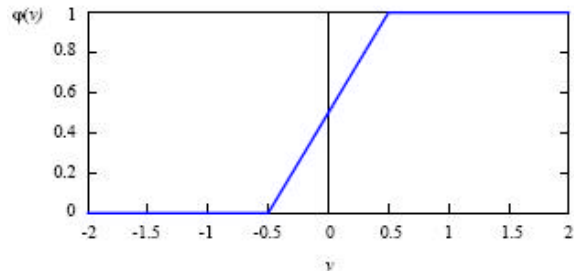
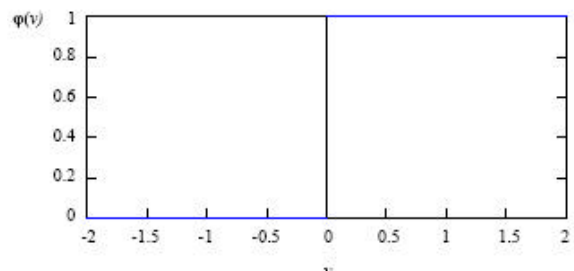
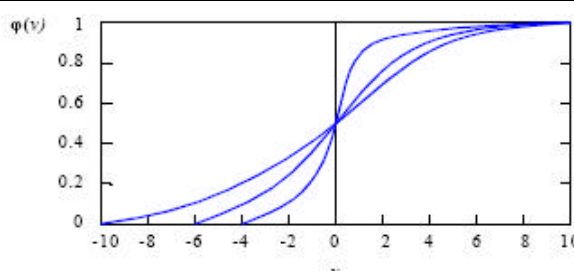
Nome da Função	Função	Intervalo	Gráfico
Linear	$\varphi(v) = v$	$[-\infty, +\infty]$	
Função Linear por partes (Rampa)	$\varphi(v) = \begin{cases} +1, & \text{se } v \geq 0,5 \\ v + 0,5, & \text{se }  v  < 0,5 \\ 0, & \text{se } v \leq -0,5 \end{cases}$	$\{-1, +1\}$	
Função Threshold ou limiar	$\varphi(v) = \begin{cases} 1, & \text{se } v > 0 \\ 0, & \text{se } v \leq 0 \end{cases}$	$\{-1, +1\}$ ou $\{0, +1\}$	
Sigmóide Logística	$\varphi(v) = 1/(1 + e^{-v})$	$\{0, +1\}$ ou $\{-1, +1\}$	

FIGURA 2.4 – Funções de ativações mais utilizadas nas RNAs.

Fonte: Adaptado de Costa, 2003.

As redes neurais multicamadas têm sido muito utilizadas para soluções de problemas envolvendo alto grau de não-linearidade, ou seja, dados muito similares. Tais redes usam um treinamento supervisionado, o qual utiliza um algoritmo muito popular chamado de retro-propagação de erro (*error backpropagation*), e é baseado na regra de aprendizagem que “corrige” o erro durante o treinamento (BOCANEGRA, 2002).?

A Figura 2.5 mostra parte da rede multicamadas “*feedforward*”, onde dois tipos de sinais podem ser identificados.




FIGURA 2.5 - Rede Multicamadas “*feedforward*” com retro-propagação do erro.

onde:

—► **Sinal funcional:** sinal de entrada (estímulo) que chega na entrada e é propagado positivamente (neurônio a neurônio) através da rede aparecendo no final como um sinal de saída.

--► **Sinal de erro:** originam-se nas saídas e são retro-propagados (neurônio a neurônio) através da rede.

Quando se trata de estruturas complexas, o algoritmo de treinamento ou aprendizagem “*backpropagation*” tem sido muito utilizado para treinar uma rede multicamadas “*feedforward*”. Esse algoritmo, derivado da Regra Delta Generalizada, permite um ajuste dos pesos em cada uma das camadas da rede e é projetado para minimizar a soma do quadrado do erro entre a saída calculada por uma arquitetura multicamadas e a saída desejada. O componente essencial desse algoritmo é o método iterativo que propaga regressivamente o erro requerido para adaptar os pesos, a partir dos neurônios da camada de saída para os nós das camadas precedentes (LIPPMANN, 1987).

Segundo Galo (2000a), 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 para computar 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 convenientemente 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.

De acordo com Raia (2000), quando um padrão é apresentado à rede pela primeira vez, esta produz uma saída aleatória. A diferença entre esta saída calculada e a desejada constitui o erro. A intenção do treinamento é buscar, cada vez mais, diminuir o valor deste erro, ajustando o valor dos pesos a cada nova iteração. A regra *backpropagation* faz com que os pesos da camada de saída sejam os primeiros a serem ajustados e, posteriormente, os pesos das demais camadas, de trás para frente.

Seja  $E_p$ , a função erro para o padrão  $p$ ,  $d_{pj}$  o valor da saída desejada (para o padrão  $p$  e o nó  $j$ ) e  $O_{pj}$ , o valor da saída obtida, então a função  $E_p$  pode ser dada por:

$$E_p = \frac{1}{2} \sum_j (d_{pj} - O_{pj})^2 \quad (4)$$

Portanto, o objetivo é minimizar essa função de erro. Se a função for simples, a rede tem garantia de encontrar solução. Caso contrário, a rede pode cair em um mínimo local e não produzir uma saída satisfatória.

A atualização dos pesos se dá pela adição de um termo de variação,  $\Delta w_{ij}$ . Ou seja, para um dado peso  $w_{ij}$  (do nó  $i$  para o nó  $j$ ), o peso atualizado na iteração  $(t+1)$ , é dado por:

$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij} \quad (5)$$

onde, de acordo com Bocanegra (2002), tem-se:

$$\Delta w_{ij} = \eta \delta_j o_i \quad (6)$$

sendo  $\eta$  a taxa de aprendizado e  $\delta_j$  a diferença (erro) entre o valor computado para o neurônio  $j$  e a saída desejada, dada por:

$$\delta_j = o_j (d_j - o_j) (1 - o_j) \quad (7)$$

onde:

$o_i$  : a saída do neurônio, e

$d_j$  : a saída desejada de  $n_j$ .

O valor da variável  $\eta$  vai determinar o quão suavemente se dará a atualização dos pesos. Se  $\eta$  for grande, o valor de  $\Delta w_{ij}$  será grande e, conseqüentemente, os pesos sofrerão uma alteração mais brusca.

A atualização dos pesos entre as camadas escondidas considerando que o peso  $w_{ki}$  liga neurônio  $n_i$  de uma camada escondida, a outro neurônio  $n_k$  na camada anterior, é feita de acordo com a equação:

$$\Delta w_{ki} = \eta \delta_i * o_k \quad (8)$$

onde:

$\delta_i$  é o erro relativo do neurônio  $n_i$ , dado pela equação:

$$\delta_i = o_i (1 - o_i) \sum w_{ij} \delta_j \quad (9)$$

sendo,  $o_k$  a saída do  $n_k$ , que estimula  $n_i$  via  $w_{ki}$ .

O algoritmo *backpropagation* apresenta alguns problemas, quanto às dificuldades de aprendizado. Em estruturas muito complexas, o treinamento é muito lento e existe o risco da rede cair num mínimo local. Além disso, pode ocorrer um “super-

treinamento”, fenômeno que surge depois de um algum tempo de treinamento, quando a rede memoriza os padrões que já foram apresentados e o processo de classificação piora sensivelmente. Possíveis soluções para estes problemas podem ser: diminuição da taxa de aprendizado, acréscimo de nós na camada intermediária ou uso de um termo de *momentum* e incorporação de ruídos (RAIA, 2000).

Os paradigmas de aprendizado, por sua vez, definem a maneira como a rede se relaciona com o ambiente, e se dividem em três principais grupos (BRONDINO, 1999):

- **supervisionado** - apresenta-se à rede, na fase de treinamento, um conjunto de entradas acompanhadas de suas respectivas saídas. O objetivo é minimizar o sinal de erro, que é função da diferença entre a saída desejada e aquela fornecida pela rede. Essa minimização se dá pelo ajuste dos pesos da rede. Um exemplo deste paradigma de aprendizado é o método *backpropagation*, discutido anteriormente;
- **não supervisionado** - a rede aprende sozinha, não havendo supervisão externa. É necessário que entradas parecidas sejam apresentadas a rede, para que essa possa extrair características estatisticamente relevantes e criar classes de maneira automática. Ou seja, a rede “analisa” os conjuntos de dados apresentados, determina algumas propriedades desse conjunto de dados e “aprende” a refletir essas 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 (MEDEIROS, 1999).
- **híbrido** - consiste de uma combinação dos aprendizados supervisionado e não supervisionado. Um exemplo é o aprendizado por reforço, onde a rede aprende de seu próprio ambiente, a partir dos dados de entrada. A única informação externa que a rede recebe é a indicação de que a resposta fornecida está correta ou não.

Resumindo, pode-se dizer que as RNAs podem ser categorizadas por sua topologia, isto é, pelo número de camadas, de elementos de processamento e de conexões; pelas características de seus elementos de processamento; e pelas leis de aprendizagem a que foram submetidas (MEDEIROS, 1999).

Segundo GALO (2000a) 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. 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.


## 2.6 Ambigüidade entre Classes

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*, 2002b).

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 (bordas) entre elas (CÂMARA *et al*, 2000).


De forma geral, uma maneira de caracterizar formalmente um conjunto, é através do conceito de *funções de pertinência* ( $F_P$  - grau de inclusão em um conjunto) onde, dado o valor de um atributo  $z$ , pode-se determinar se o elemento avaliado pertence ou não a um determinado conjunto em análise.

A Figura 2.6 mostra exemplos de funções de pertinência usadas em classificação, onde no eixo x, destaca-se a variação de um atributo (z) dos elementos, usado como parâmetro para classificação. O eixo y representa a faixa de valores possíveis para a função de pertinência ( $F_p$ ). Na Figura 2.6a, quando o valor do atributo z estiver entre o limiar inferior ( $L_i$ ) e o limiar superior ( $L_s$ ), a função retorna 1, caso contrário retorna zero, conforme mostra a Equação 10. Para a Figura 2.6b, a função retorna um valor entre 0 e 1, se o valor do atributo z estiver entre o limiar inferior ( $L_i$ ) e o limiar superior ( $L_s$ ), equação (11). Nessa última situação a região entre ( $L_{fi}$ ) e ( $L_s$ ) é denominada *zona de transição* (CÂMARA *et al*, 2000).



$$F_p^b(z) = 1 \quad \text{se } L_i \leq z \leq L_s$$

$$F_p^b(z) = 0 \quad \text{se } z < L_i \text{ ou } z > L_s$$
(10)



$$F_p^f(z) = \frac{1}{1 + \left( \frac{z - L_{fi} - d_I}{d_I} \right)^2}$$
(11)

FIGURA 2.6 - Exemplo de função de pertinência para conjunto (a) *booleano*; (b) *fuzzy*.

A Figura 2.6a possui uma função de pertinência similar ao conjunto *Booleano*, com limiares definidos de forma nítida, isto é, o resultado é expresso de forma

binária, “0” (hipótese não satisfeita) e “1” (hipótese satisfeita), não sendo possível à condição talvez. Embora esse método seja prático, normalmente não é o mais adequado, pois o ideal é que as evidências que apresentam uma importância relativa diferente recebam pesos de diferentes valores e não sejam tratadas igualmente como geralmente acontece (CÂMARA *et al.*, 2000).

Um conjunto que tem uma função de pertinência como mostra a Figura 2.6b, é denominado de *conjunto Fuzzy*, o qual tem como característica a indefinição de fronteiras ou limiares entre as classes.

De acordo com Wang (1990) uma partição *Fuzzy* do espaço espectral multidimensional é definida, formalmente, como conjuntos *Fuzzy*  $F_1, F_2, \dots, F_m$ , de um universo  $X$ , de modo que:

$$\begin{aligned} \forall x \in X \\ 0 \leq f_{F_i(x)} \leq 1 \\ \sum_{x \in X} f_{F_i(x)} > 0 \\ \sum_{i=1}^m f_{F_i(x)} = 1 \end{aligned} \quad (12)$$

onde:

$F_1, F_2, \dots, F_m$  representam as classes de referência;

$X$  é o total de *pixels* da imagem;

$m$  é o número de classes estabelecidas;

$x$  é o vetor de atributos do *pixel* analisado e,

$f_{F_i}$  é a função de pertinência do conjunto *Fuzzy*  $F_i$  ( $1 \leq i \leq m$ ).

Para o referido autor, o resultado de uma classificação *Fuzzy* pode ser expresso na forma de uma matriz:

$$\begin{bmatrix} f_{F_1(x_1)} & f_{F_1(x_2)} & \cdots & f_{F_1(x_n)} \\ f_{F_2(x_1)} & f_{F_2(x_2)} & \cdots & f_{F_2(x_n)} \\ \vdots & \vdots & & \vdots \\ f_{F_m(x_1)} & f_{F_m(x_2)} & \cdots & f_{F_m(x_n)} \end{bmatrix} \quad (13)$$

onde  $n$  é o número de *pixels*.

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).

Classes discretas convencionais podem ser obtidas através da matriz mostrada na Equação (13), simplesmente pela substituição do valor máximo de cada coluna por “1” e os demais por “0”, enquanto que para classes contínuas essa condição é alterada para permitir que os valores parciais de pertinência sejam considerados.

Dentro do contexto de classificação Zhang e Foody (1998) ressaltam que um *pixel* pode estar parcialmente associado a múltiplas classes e o grau dessa associação é definido por um valor de pertinência *fuzzy*. Existem várias maneiras de derivar os valores de pertinência e essa tarefa depende, essencialmente, da técnica de classificação adotada. No caso da classificação de máxima verossimilhança, a definição do nível de pertinência de um *pixel* para as classes de referência se baseia na estimativa da função densidade de probabilidade de cada uma das classes. Por outro lado, quando uma rede neural é usada para a classificação de dados multiespectrais e temáticos, o grau de pertinência associado a cada classe pode ser medido pelos valores de ativação de saída, calculados para cada elemento do processo de saída da rede.

### **3 MATERIAIS E MÉTODOS**

#### **3.1 Estudo de Caso**

O estudo de caso considerado neste trabalho é constituído por reservatórios administrados pela AES Tietê S.A, localizados ao longo do Rio Tietê. A AES Tietê S.A. é uma empresa do Grupo AES composta de dez Usinas Hidrelétricas, localizadas nas regiões central e noroeste do Estado de São Paulo. A operação comercial dessa Companhia foi iniciada em abril de 1999, após a reestruturação societária e patrimonial das empresas do setor energético do Estado de São Paulo, em razão do Programa Estadual de Desestatização. Cinco desses reservatórios - Barra Bonita, Bariri, Ibitinga, Promissão e Nova Avanhandava - ficam no Rio Tietê, que corta o Estado no sentido leste-oeste, com 1.100 quilômetros de extensão. Essas usinas foram projetadas e construídas com vistas ao múltiplo aproveitamento da água. Além da geração de energia, permitem controle de cheias, navegação hidroviária, desenvolvimento da piscicultura e atividades de recreação, entre outros usos (MACRÓFITAS, 2003).

Dentre os reservatórios administrados pela AES, os cinco reservatórios estudados estão localizados na Bacia do Rio Tietê (Barra Bonita, Bariri, Ibitinga, Promissão e Nova Avanhandava) e foram selecionados por apresentarem macrófitas aquáticas emersas em seus leitos. A Figura 3.1 ilustra a localização desses reservatórios.

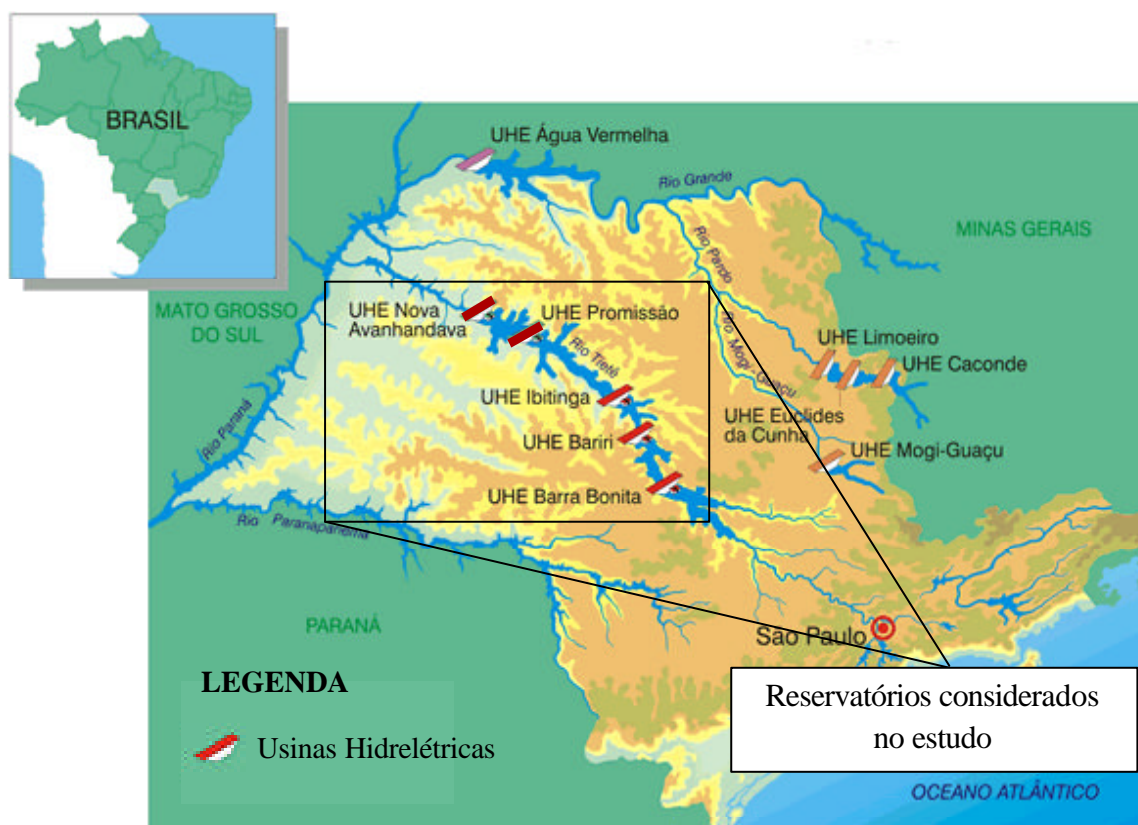


FIGURA 3.1 – Ilustração destacando os reservatórios em estudo ao longo do Rio Tietê.

Fonte: Adaptado de Cavenaghi, 2003.

## 3.2 - Material e Equipamentos

### 3.2.1 Dados Multiespectrais de Sensoriamento Remoto

Os dados multiespectrais utilizados no projeto, correspondem a imagens orbitais ETM+/Landsat7, abrangendo os cinco reservatórios de interesse. Essas imagens e os dados descritivos da área de estudo foram 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” (VELINI *et al*, 2002). As imagens são mostradas na Figura 3.2, que define também as órbitas/ponto correspondentes a cada reservatório.

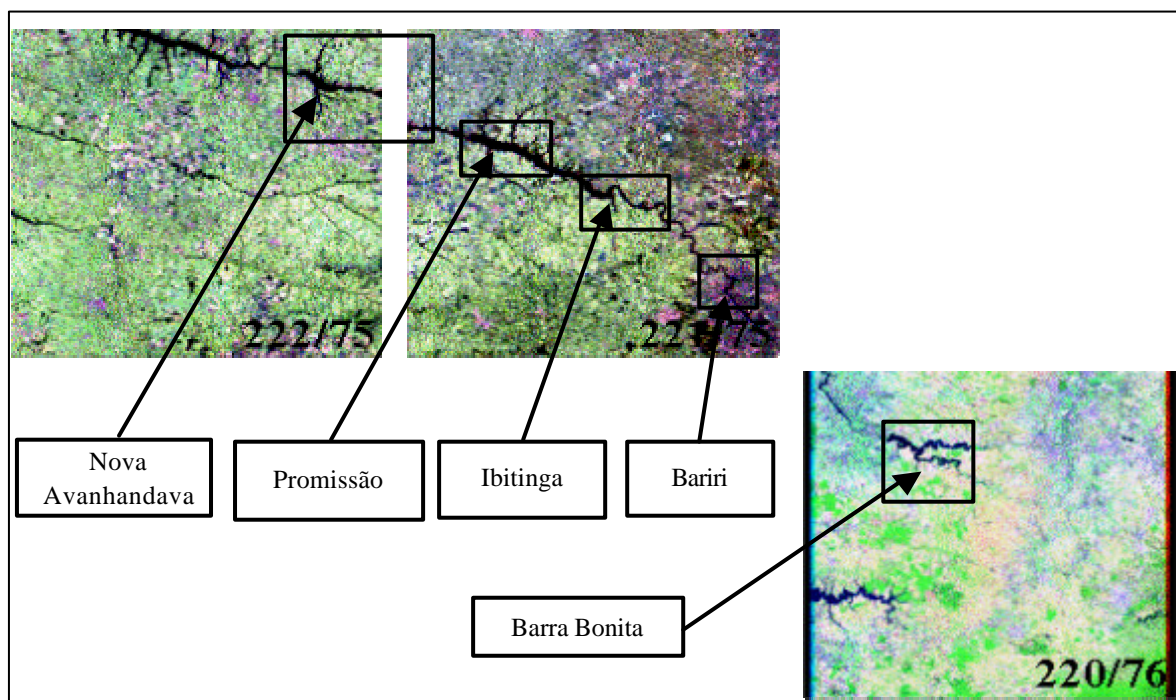


FIGURA 3.2 - Distribuição das imagens orbitais ETM+/Landsat, pelas respectivas órbitas/ponto, indicando os reservatórios de interesse.

Fonte: Velini *et al*, 2002.

No caso do reservatório de Nova Avanhandava foi realizada uma normalização radiométrica nas imagens, seguido da construção de um mosaico das mesmas, pois esse reservatório estava parcialmente inserido em duas imagens, como pode ser verificado na Figura 3.2.

A Tabela 3.1 indica a data de obtenção das imagens de cada reservatório e respectiva órbita/ponto referente ao satélite Landsat7.

Tabela 3.1 - Datas de tomada das imagens selecionadas para a realização do monitoramento a partir de dados ETM+/Landsat.

Órbita/Ponto	Datas de passagem	Reservatórios incluídos na cena
220/76	27/06/2001	Barra Bonita
221/75	20/07/2001	Bariri, Ibitinga, Promissão e Nova Avanhandava (final do reservatório)
222/75	12/08/2001	Início de Nova Avanhandava (Usina)

Fonte: Adaptado de Velini *et al*, 2002.

### 3.2.2 Ferramentas Computacionais utilizadas no processamento e análise dos dados

Para o processamento e análise digital dos dados multiespectrais foram usados *softwares* instalados em um microcomputador Pentium/166 com 32 MB de memória RAM contendo os sistemas operacionais Windows e Linux, para a aplicação da Rede Neural Artificial, e um microcomputador AMD/Athlon(tm) Processor 1.2 GHz, com 128 MB de memória RAM, para processamentos de manipulação e análise de imagens.

O sistema Linux foi necessário para viabilizar o uso do simulador de Redes Neurais Artificiais na classificação de dados, o que implicou, ainda, na utilização de programas computacionais de conversão dos dados a serem classificados, em um arquivo padrão compreendido pelo simulador, assim como, para a conversão dos valores de saída da Rede Neural Artificial para o formato de uma imagem classificada.

No desenvolvimento desse projeto foram utilizados os seguintes aplicativos: *software* SPRING, para a manipulação das imagens, geração das imagens-fração através do modelo linear de mistura espectral e tratamento da imagem; o *software* IDRISI para a exclusão da área de entorno, a elaboração da tabulação cruzada entre os planos de informação e para a análise da ambigüidade, dentre outros processamentos específicos, e o simulador de redes neurais “*Stuttgart Neural Network Simulator*” - SNNS, para o processo de classificação dos dados através de Redes Neurais Artificiais.

#### ▪ SPRING

O SPRING (Sistema de Processamento de Informações Georreferenciadas) é um banco de dados geográfico de segunda geração desenvolvido para ambientes UNIX e Windows. Tem se mostrado uma opção altamente atrativa na área de geoprocessamento, pois pode ser considerado um *software* de domínio público e constitui um produto desenvolvido

com tecnologia totalmente nacional, pelo Instituto Nacional de Pesquisas Espaciais – INPE, em São José dos Campos/SP, cidade que se destaca no cenário nacional pelas empresas e institutos ligados a área de tecnologia principalmente no setor aeroespacial.

A estrutura do sistema garante uma organização que permite o armazenamento e recuperação eficiente dos dados, graças a natureza de seu Banco de Dados Geográfico. Um Banco de Dados no SPRING corresponde, fisicamente, a um diretório onde serão armazenados tanto o Modelo de Dados com suas definições de Categorias e Classes, quanto aos projetos pertencentes ao banco. Os projetos são armazenados em subdiretórios juntamente com seus arquivos de dados: pontos, linhas, imagens orbitais e aéreas, imagens temáticas, textos, grades e objetos. Inicialmente, deve-se criar um banco para, então, ativá-lo e inserir dados no mesmo (SPRING, 2003).

O sistema SPRING constitui-se de quatro aplicativos ou programas executáveis, o Impima – utilizado para leitura de imagens e conversão para o formato GRIB, o SPRING – programa principal do sistema onde serão modelados os dados, o Scarta, programa que permite a elaboração de cartas a partir de dados previamente tratados no programa SPRING e o programa Iplot utilizado para abrir um arquivo IPL, criado pelo Scarta (SPRING, 2003).

#### ▪ IDRISI

O *software* IDRISI versão 3.2 é também um Sistema de Informações Geográficas e de processamento de imagens desenvolvido pelo “*Graduate School of Geography*” da “*Clark University*” e projetado para a análise de dados geográficos em formato matricial (EASTMAN, 1998). Consiste de um programa principal de interface e mais de 150 módulos de programas que fornece facilidades na entrada, na visualização e na análise

de dados geográficos, também possui um módulo de conversão vetor-matriz, pois ele trabalha com imagens e operações que permitem a tabulação cruzada entre planos de informações.

O IDRISI trabalha de forma analítica *raster* (imagem), cobrindo o espectro de necessidades de SIG e de Sensoriamento Remoto, desde consulta a banco de dados e modelagem espacial, até realce e classificação de imagens. Facilidades especiais estão incluídas para monitoramento ambiental e gerenciamento de recursos naturais, destacando análise de séries temporais/mudanças, apoio a decisão por critérios múltiplos e por objetivos múltiplos; análise de incerteza e modelagem de simulação (EASTMAN, 1998).

- **Simulador SNNS**

O SNNS (*Stuttgart Neural Network Simulator*) é um programa de domínio público, desenvolvido pelo “*Institute for Parallel and Distributed High Performance System*” da “*University of Stuttgart*”, a partir de 1989, e é um dos simuladores de redes neurais mais empregados pela comunidade científica, podendo rodar em uma série de plataformas. Engloba uma vasta quantidade dos modelos de redes neurais mais conhecidos e utilizados atualmente, e proporciona um ambiente eficiente e flexível para auxiliar na criação e no treinamento de redes neurais artificiais.

No simulador SNNS, o processamento da informação real é modelado pela função de ativação e pela função de saída da rede. A função de ativação calcula primeiro a entrada para uma unidade de processamento, a partir dos valores ponderados de saída de unidades prévias, sendo então calculado um novo valor de ativação para essa unidade (a partir da unidade prévia). Possibilita também, executar um ciclo de validação a cada  $n$  ciclos de treinamento (ZELL *et al*, 1995).

A criação e edição das arquiteturas das redes são tarefas simples e rápidas no simulador. Também é possível acompanhar a evolução, tanto do erro de aprendizagem quanto de validação, através de interfaces gráficas que o mesmo fornece.

Segundo Zell *et al* (1995), uma das maiores vantagens das redes neurais é sua capacidade de generalização. Isto significa que uma rede treinada pode classificar dados de treinamento, sem conhecimento prévio de todo o conjunto. Em aplicações do mundo real, normalmente se dispõe de uma pequena parte dos padrões possíveis para a generalização da rede. Para obter melhor generalização os autores recomendam que a base de dados seja dividida em três partes:

- conjunto de treinamento – usado para o aprendizado da rede neural. O erro da base de dados é minimizado durante o treinamento;
- conjunto de validação - usado para estimar o desempenho da rede neural sobre o conjunto de padrões que não foram treinados durante a aprendizagem;
- conjunto de teste – para checar o desempenho global da rede. Refere-se ao conjunto de dados a ser classificado.

A aprendizagem deve ser finalizada quando o erro, para o conjunto de validação, for mínimo, pois nesse ponto a rede generaliza melhor. Quando a aprendizagem da rede não é adequadamente finalizada ocorre um “super-treinamento” e o desempenho da rede para o conjunto total de dados decresce, apesar de que o erro para os dados de treinamento ainda pode diminuir. Concluída a fase de treinamento, a rede deve ser testada para o terceiro conjunto de dados, o conjunto teste, que se constitui no conjunto total de dados a ser classificado. É a partir da aplicação da rede a esse conjunto que é possível verificar se a rede treinada está generalizando corretamente (ZELL *et al*, 1995).

A medida do desempenho da rede depende do problema que é apresentado a mesma. Se a tarefa da rede é uma classificação, o desempenho depende da complexidade do problema.

### **3.3 Procedimento Metodológico**

Como a tarefa de classificação foi realizada mediante a aplicação de uma Rede Neural Artificial (RNA), inicialmente, foi necessário um treinamento no sistema operacional LINUX (que serve como base para o simulador de redes neurais - SNNS), um estudo sobre quais algoritmos de treinamento eram adequados para treinar o modelo a ser aplicado, e sobre os recursos e operações disponíveis no simulador, assim como, uma pesquisa prévia sobre os métodos e *softwares* (aplicativos ou programas computacionais) mais adequados para utilização no projeto, e um planejamento inicial.

A partir dessa atividade preliminar, o desenvolvimento do projeto foi realizado em três etapas: a primeira consistiu no treinamento de uma Rede Neural Artificial dimensionada a partir de amostras representativas das classes de interesse (água e áreas infestadas por plantas aquáticas), as quais foram coletadas no reservatório de Barra Bonita nas áreas de treinamento e validação, e na aplicação dessa rede treinada à imagem abrangendo todo esse reservatório. Na segunda etapa, a rede treinada para o reservatório de Barra Bonita foi aplicada aos outros quatro reservatórios (Bariri, Ibitinga, Promissão e Nova Avanhandava) localizados ao longo do rio Tietê, gerenciados pela AES, e assim verificado seu potencial em discriminar as mesmas classes de saída estabelecidas para Barra Bonita. A terceira etapa consistiu na análise da ambigüidade das classes de saída da rede neural associadas às diferentes ocorrências de plantas aquáticas e variações espectrais na água, apenas para a área de treinamento do reservatório de Barra Bonita, através da tabulação cruzada dos planos de informações individuais gerados pelos valores de ativação, resultantes da aplicação da RNA.

O fluxograma mostrado na Figura 3.3 ilustra as atividades desenvolvidas neste projeto.

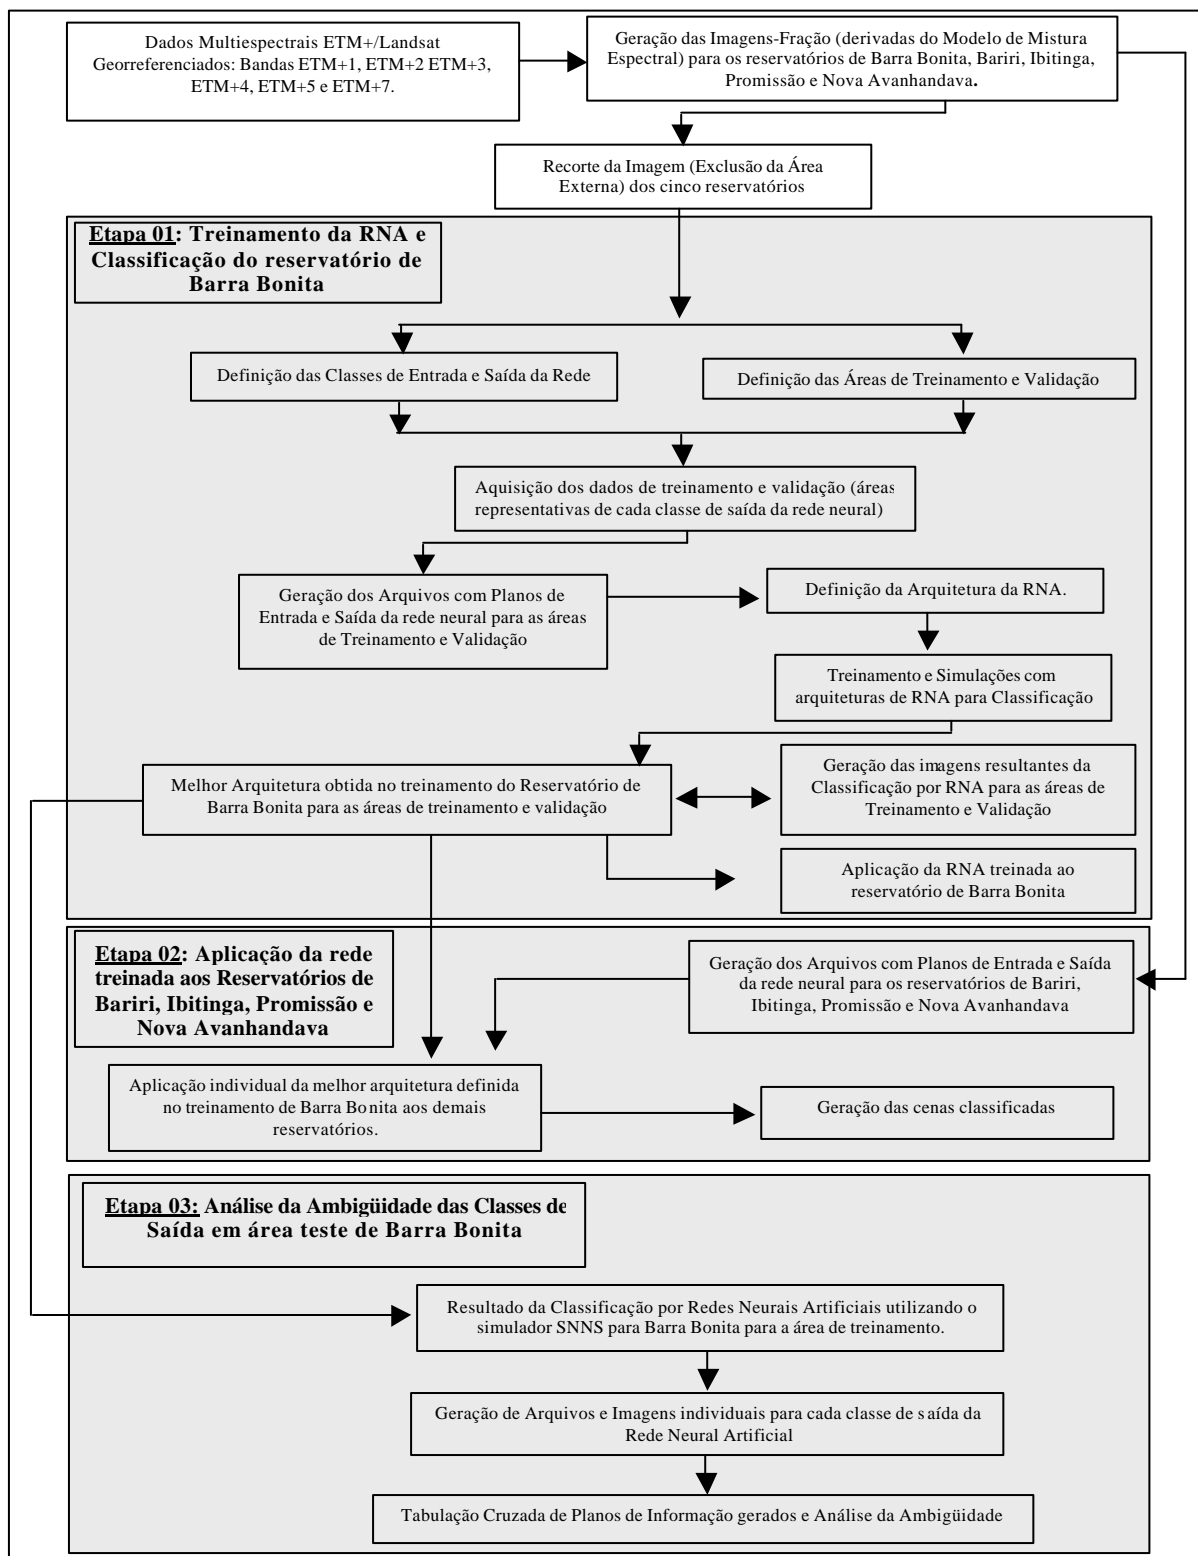


FIGURA 3.3 – Fluxograma ilustrando as atividades desenvolvidas.

Para a realização desse projeto foi utilizada uma imagem que engloba o reservatório de Barra Bonita, tomada em junho de 2001, por apresentar maior quantidade de macrófitas emersas em seu leito, assim como uma maior diversidade de plantas aquáticas desse tipo. As imagens dos reservatórios de Bariri, Ibitinga, Promissão foram adquiridas em julho de 2001 e a de Nova Avanhandava em Agosto de 2001, conforme indicado na Tabela 3.1.

Essas imagens foram pré-processadas no *software* SPRING, para que as características mais importantes dos dados a serem classificados fossem realçadas, dentre outros processamentos. Foi aplicada uma operação de ampliação linear de contraste para a redefinição dos valores de brilho, de modo a expandir ao máximo o intervalo de variação dos valores de brilho na cena. As imagens multiespectrais ETM+/Landsat7 cedidas pelo projeto AES Tietê SA apresentavam-se georreferenciadas no sistema de projeção UTM (*Universal Transversa de Mercator*) e datum WGS84.

Em seguida, aos dados multiespectrais ETM+/Landsat dos cinco reservatórios do rio Tietê, foi aplicado um modelo de mistura linear para separar as contribuições de cada material dentro do *pixel*, decompondo a imagem em três componentes “puros” de água, solo e vegetação.

**- Geração das Imagens-fração derivadas do Modelo de Mistura Espectral: Dados de entrada da RNA**

As respostas espectrais dos componentes dos *pixels*, representados pela vegetação, solo e água, foram obtidas diretamente das bandas espectrais ETM+1, ETM+2 e ETM+3, ETM+4, ETM+5 e ETM+7, que compõem a imagem do reservatório de Barra Bonita e dos demais reservatórios ao longo do rio Tietê.

Para a realização desse procedimento foi utilizada a ferramenta disponível no *software* SPRING denominada de “Modelo de Mistura” que permite criar um modelo a partir das assinaturas espectrais dos componentes da mistura e, em seguida, aplicá-lo aos dados de interesse. No processo de criação desse modelo, deve-se definir primeiramente as bandas de interesse, especificar as componentes da mistura espectral e gerar, dessa forma, as respectivas assinaturas espectrais de vegetação, solo e água.

A aplicação do modelo de mistura teve como objetivo auxiliar na discriminação dos tipos de água e macrófitas que ocorrem em Barra Bonita e nos demais reservatórios de interesse.

O modelo foi aplicado às seis bandas espectrais anteriormente especificadas e as proporções dos componentes (vegetação, solo e água) foram estimadas utilizando o Método dos Mínimos Quadrados Ponderado, o qual busca iterativamente a solução do 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 cada um dos cinco reservatórios do rio Tietê.

#### - **Recorte da Imagem (Exclusão da Área Externa dos Reservatórios)**

As imagens utilizadas contendo somente o contorno dos reservatórios foram extraídas de uma cena que possuía apenas a classificação do corpo d’água, disponibilizada pelo projeto AES-ANEEL: “Monitoramento dos Problemas com Macrófitas nos Reservatórios da AES - Desenvolvimento de Programas de Manejo Integrado das Principais Espécies

presentes”. Uma das imagens utilizadas, referente ao reservatório de Barra Bonita, é mostrada na Figura 3.4 (a), enquanto que na Figura 3.4 (b) é mostrada a mesma imagem após alguns processamentos com o *software* IDRISI, de forma a atribuir todos os *pixels* contidos no reservatório a um único identificador (área interna), e a parte externa ao reservatório foi considerada como fundo, com identificador zero.

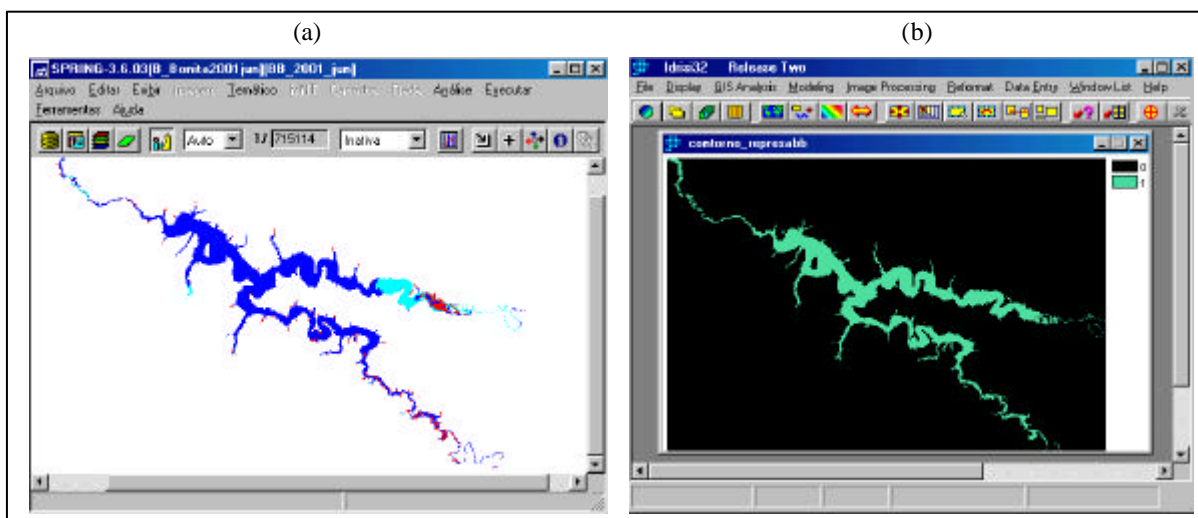


FIGURA 3.4 - (a) Contorno do rio - AES; (b) Delimitação da área de estudo, contendo o reservatório de Barra Bonita (identificador igual a 1) e o fundo (com identificador igual a zero).

A imagem da Figura 3.4 (b), contendo apenas o reservatório de Barra Bonita (polígono) foi usada como máscara e multiplicada por todas as Imagens-Fração, individualmente, a fim de delimitar sua abrangência do espelho d'água nesse reservatório. A Figura 3.5 ilustra o resultado desse processamento para as imagens-fração geradas.

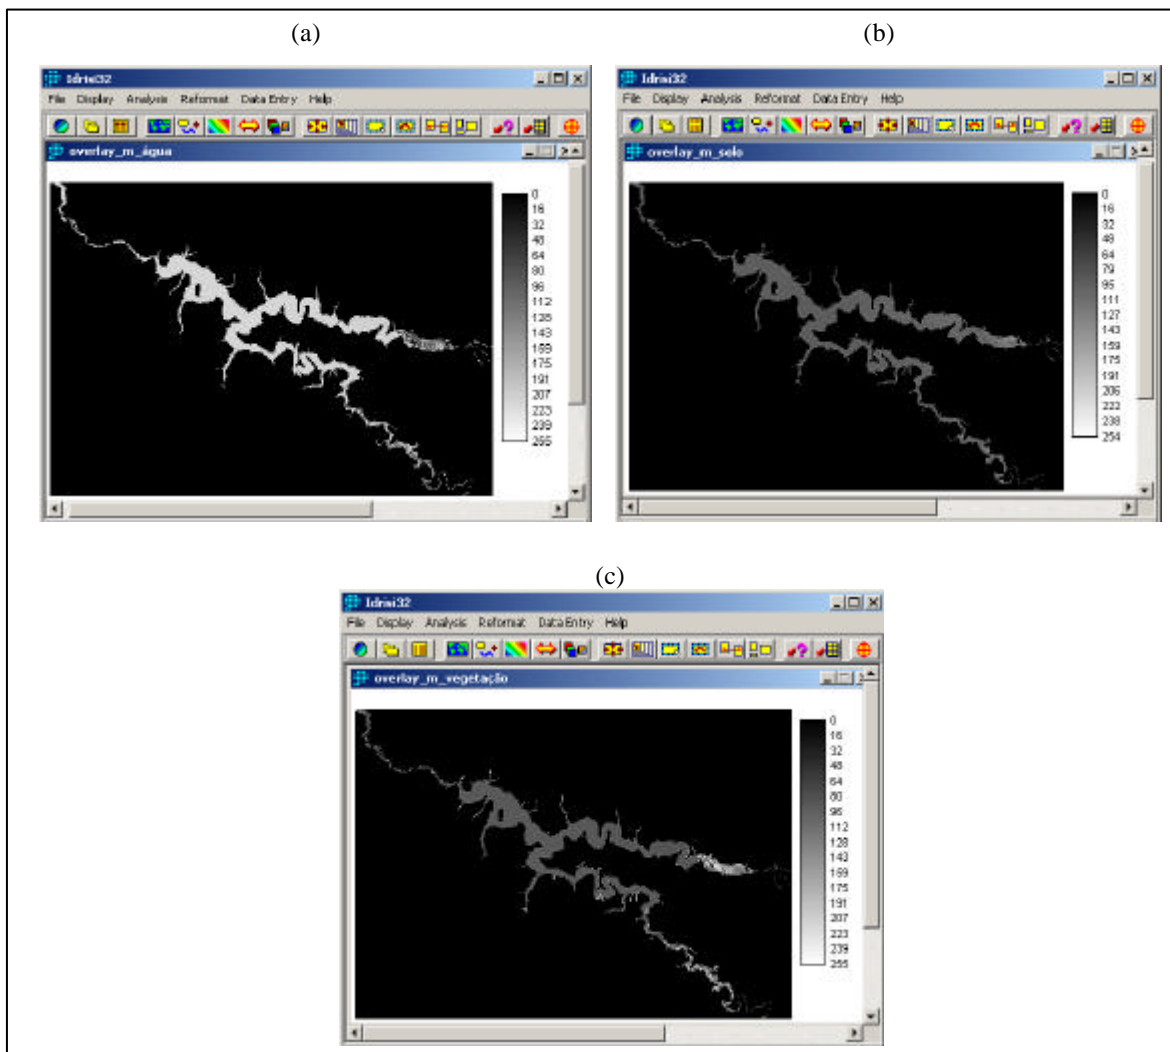


FIGURA 3.5 - (a) Imagem ilustrando a delimitação do espelho d'água nas imagens-fração água; (b) solo; (c) vegetação; com intervalo de valores de brilho entre 0-255.

Todos os processos citados anteriormente foram realizados de maneira similar aos outros quatro reservatórios em estudo.

### 3.3.1 ETAPA 1 – Treinamento e Aplicação da RNA ao Reservatório de Barra Bonita

Para realização da classificação usando o simulador de redes neurais, SNNS, foi necessário realizar uma série de atividades:

- definição dos dados de entrada e as classes de saída da classificação;
- aquisição das amostras de treinamento e validação;
- geração dos arquivos de treinamento e validação no formato do SNNS;

- d) definição das arquiteturas da rede;
- e) treinamento e Simulações com arquiteturas de Redes Neurais Artificiais;
- f) aplicação da Rede Neural Artificial treinada na classificação da área de estudos, e
- g) geração da imagem resultante da classificação.

- **Definição dos dados de entrada e classes de saída da classificação**

Na classificação usando o simulador SNNS, é necessário a obtenção das áreas de treinamento e validação, o que foi feito através da aquisição de amostras, identificando as categorias ou classes de interesse na imagem.

Os dados de entrada utilizados foram as imagens-fração derivadas do Modelo de Mistura Espectral. As classes de saída foram estabelecidas através da análise visual das imagens ETM+ (bandas 3, 4 e 5), com o auxílio da imagem classificada para o projeto AES e dados descritivos (identificação dos tipos de água). Assim, a identificação das diferentes variações de água e tipos de macrófitas presentes foi feita visualmente nas imagens, porém essas ocorrências não foram relacionadas aos seus respectivos nomes (conforme indicado no relatório AES) devido à dificuldade de se fazer essa caracterização nas imagens multiespectrais. Isto decorre da resolução espacial das imagens serem de 30 metros, que não permite a identificação direta dos tipos, mas indica a ocorrência de vários tipos de macrófitas.

As classes definidas para saída da rede neural constituíram-se de dois tipos de água (água1 e 2) diferenciados em função da maior ou menor presença de sedimentos definindo uma coloração diferente para a água; duas variações no padrão de ocorrência de plantas aquáticas (macrófita 1 e 2) percebidas devido a sua variabilidade espectral e textura; e fundo, referente à área externa do espelho d'água.

## - **Aquisição das Amostras para Treinamento e Validação**

O treinamento e a validação de redes neurais foi realizado a partir da apresentação de padrões de entrada/saída espacialmente correspondentes, definidos em um ou mais conjuntos de amostras. A aquisição das amostras das classes foi feita a partir dos dados de áreas representativas da região de estudo (reservatório).

A aquisição dos dados amostrais para as áreas de treinamento e validação implicou na extração de áreas ou segmentos da imagem, em cada um dos planos de entrada da rede (imagens-fração água, solo e vegetação), e pela definição de um plano de saída associado à ocorrência de cada classe de interesse sobre um fundo preto (que caracteriza ausência de informação, pelo fato de estar fora da região delimitada para a amostra).

Nesse processo, foi selecionada uma área de treinamento e uma de validação, nas quais se procurou englobar todas as possíveis classes de saída definidas na imagem a ser classificada. A obtenção desses arquivos resultou da digitalização de polígonos associados aos locais de ocorrência de uma dada classe e na geração de arquivos individuais para cada classe de saída. Para facilitar sua discriminação pela rede, cada classe recebeu um atributo (valor numérico) diferente.

Utilizando recursos do IDRISI, os arquivos contendo as amostras (polígonos) foram convertidos em imagens, com as mesmas dimensões das áreas de treinamento e validação, sendo que cada imagem continha apenas as amostras representando a classe em questão (associada a um atributo identificador diferente de zero) e fundo (identificador igual a zero). Ainda no *software* IDRISI, os identificadores das classes foram substituídos de seus valores iniciais adotados na digitalização, para valores definidos em intervalos maiores referentes a 1, 63, 156, 189, e 252, correspondendo às classes de saída: “fundo”, “água1”, “água2”, “macrófita1” e “macrófita2”, respectivamente. Essa estratégia foi

adotada a fim de evitar números muito próximos quando da sua normalização para o intervalo [0, 1] na saída da rede neural.

Desta maneira, as áreas de treinamento e validação contêm os planos de saída da rede constituídos por sub-imagens de mesmas dimensões e nas mesmas posições definidas para os dados de entrada constituídos pelas imagens-fração geradas: água, solo e vegetação.

#### - **Geração dos arquivos de treinamento e validação no formato do SNNS**

Para treinar, validar, ou mesmo classificar qualquer tipo de dados usando o simulador SNNS é necessário convertê-los em um formato apropriado ou compatível com a configuração do simulador. Esse formato define um arquivo de padrões, composto por um cabeçalho e um componente de dados. O cabeçalho estabelece tanto o número de padrões do arquivo quanto a dimensionalidade dos vetores de entrada e classes de saída. O componente de dados é simplesmente uma lista de números que representam os atributos de entrada e de saída, normalizados no intervalo entre 0 e 1. Para cada padrão, o número de valores listados deve corresponder ao número de elementos de processamento da primeira camada da rede, acrescido do número de unidades de saída, conforme definido no cabeçalho (ZELL *et al.*, 1995).

Após a aquisição das áreas de treinamento e validação foi necessário transferir os arquivos de dados (imagens no formato PBM) para o sistema operacional LINUX e gerar os arquivos de padrões no formato reconhecido pelo SNNS (extensão .pat), e importá-los para o ambiente do simulador.

A conversão desses dados foi realizada através do programa que transforma dados no formato imagem (.pbm) para o formato SNNS (.pat), reconhecido pelo simulador. O

programa *pbm-snns*<sup>2</sup> permite montar ou gerar os arquivos de padrões, a partir dos planos que compõem cada amostra definida na imagem. Esse programa é flexível o suficiente para permitir que sejam definidos vários padrões em um único arquivo.

O arquivo de treinamento gerado para o presente projeto, a partir do programa *pbm-snns*, citado anteriormente, é composto por uma área ou amostra de treinamento e uma de validação.

Para criar os arquivos do simulador (.pat), são informados sequencialmente os planos de entrada e, em seguida as imagens correspondentes a cada uma das classes de saída, para arquivo de padrões ou amostra de treinamento. Os arquivos de treinamento e de validação são compostos por um único padrão, já que constituíram uma única área amostral.

#### - Definição da Arquitetura da Rede

Para definir o número de camadas escondidas e o número de nós que compõem cada camada intermediária foram realizadas simulações com diferentes arquiteturas de rede, durante a etapa de treinamento, e posterior análise do desempenho da rede treinada sobre uma amostra de validação, com a finalidade de encontrar uma arquitetura de rede que represente melhor as classes de saída pré-definidas.

Para a realização da classificação supervisionada foi utilizado o modelo de Redes Neurais Artificiais com estrutura de múltiplas camadas e alimentação progressiva (*feedforward*), e o algoritmo de treinamento *backpropagation*, ambos disponíveis no SNNS.

Como a especificação dos dados a serem classificados (dados de entrada) e das classes de interesse (saída) foram estabelecidas, o número de nós da camada de entrada (3) e de camada de saída (5) já ficaram definidos, faltando determinar o número de camadas

---

<sup>2</sup> Programa implementado e disponibilizado pelo Prof. Mauricio Galo do Departamento de Cartografia da FCT/Unesp

escondidas e o número de nós dessa (s) camada (s), para estabelecer as diferentes arquiteturas de rede a serem treinadas.

A definição do número de camadas escondidas e o número de nós que as constituem foram determinadas por tentativa e erro. Foram realizadas várias simulações com diferentes arquiteturas de redes neurais, com a finalidade de selecionar aquela que melhor representasse os dados, com base na análise do desempenho da rede treinada sobre uma amostra de validação, para cada arquitetura testada.

#### - **Treinamento e Simulações com Arquiteturas de Redes Neurais Artificiais**

Segundo Zell *et al.* (1995), uma questão importante da aplicação de Redes Neurais Artificiais está relacionada ao modo pelo qual os pesos das conexões entre os elementos de processamentos (nós) são ajustados, para garantir o comportamento desejado para o sistema. Essa questão define a maneira como a rede aprende que uma entrada específica corresponde a uma dada classe de saída, ou seja, está relacionada com o treinamento da rede.

A partir da análise do comportamento de uma rede neural durante a fase de treinamento é possível avaliar sua adequação na classificação dos dados disponíveis. Isto significa que, além da arquitetura da rede (definida pelo número de camadas escondidas e número de nós em cada camada), devem ser estabelecidos os parâmetros relacionados com as funções de aprendizagem e ativação e com as regras estabelecidas para a atualização de pesos e inicialização da rede, além do critério de término das iterações ou ciclos.

O treinamento das arquiteturas de redes foi iniciado no simulador SNNS com a criação das configurações da rede, estabelecendo o número de elementos de processamento para cada camada (entrada, escondidas e validação) e introduzindo os arquivos padrões usados para o treinamento e validação.

O processo de treinamento utilizando o algoritmo padrão *backpropagation* implica na definição prévia da taxa de aprendizagem, que neste trabalho foi  $\eta=0,01$ , e é normalmente correspondente a quanto de erro é repassado aos nós a cada iteração. A definição dos parâmetros e especificação das funções de ativação e inicialização, partiu da recomendação da literatura especializada e de resultados de testes preliminares de convergência realizados por Galo (1997). A função sigmóide associada a cada nó foi utilizada para verificar se um elemento de processamento era ou não ativado por uma entrada específica, ou seja, a função era usada para calcular o valor de ativação em cada nó. O modo de atualização escolhido foi o *topological-order*, ou estrutura topológica, que leva em conta a organização das camadas na rede, ou seja, a primeira camada a ser processada é a camada de entrada, seguida pela primeira camada escondida e assim sucessivamente, até a última camada de saída. Os pesos aleatórios iniciais para as unidades de entrada foram definidos no intervalo entre 0,1 e -0,1, visando perceber melhor as variações que ocorrem nos dados durante o processo de treinamento.

A validação dos dados é feita a cada  $n$  ciclos de treinamento estabelecidos pelo usuário. No presente caso, a cada 20 iterações, o treinamento era interrompido para calcular o erro médio quadrático sobre o conjunto de padrões de validação e esse erro foi monitorado, tanto para padrões de treinamento quanto para validação, para verificar se o mesmo atingia o valor mínimo pré-estabelecido (usualmente de 0,05). Desse modo, durante essa fase, o conjunto de validação é utilizado para determinar o desempenho da rede com dados que não foram previamente utilizados no treinamento.

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. Os elementos de processamento (nós) e o número de camadas escondidas foram definidos por tentativa e erro.

Como o simulador permite operar simultaneamente com dois conjuntos de padrões (treinamento e validação), a maneira mais adequada para verificar a capacidade de generalização da rede é monitorar o erro quadrático médio (EQM) para o conjunto de validação, o que pode ser visualizado através do gráfico do erro ou pode ser monitorado na janela que mostra os comandos que estão sendo utilizados. Quando esse erro atingir um mínimo pré-estipulado, o treinamento pode ser finalizado.

Concluído o treinamento de cada arquitetura da rede, foi necessário salvá-la no formato .net para sua utilização posterior na classificação de toda a cena (fase de teste), o que é feito através da função VALID, que produz as ativações de saída para cada *pixel* da cena, em relação a cada classe de interesse.

Como já especificado, as simulações foram realizadas com a finalidade de identificar a configuração de rede mais adequada para representar as classes de interesse.

A finalização dessa primeira etapa consistiu da aplicação da rede neural treinada a partir de amostras coletadas na imagem do reservatório de Barra Bonita, com a finalidade de selecionar a arquitetura que melhor representasse as classes de interesse. Escolhida essa arquitetura, obtida através do treinamento, foram geradas as imagens resultantes da classificação para as áreas de treinamento e validação.

#### **- Geração da Imagem resultante da Classificação**

Para produzir uma imagem da cena classificada a partir dos valores de saída da rede, foi utilizado o programa *snns-pbm*<sup>3</sup>. Através desse programa as ativações de saída (arquivo com extensão .res) foram convertidas para o formato PBM (formato imagem), gerando a imagem da cena classificada. Esse programa também fornece o resultado da

---

<sup>3</sup> Programa implementado e disponibilizado pelo prof. Maurício Galo do Departamento de Cartografia – FCT/UNESP

classificação na forma descritiva, para que uma futura análise possa ser realizada. Tem como finalidade identificar a unidade de processamento de saída, para um dado vetor, que fornece o maior valor de ativação (associado à classe correspondente) e, então estabelece a posição desse *pixel* na matriz bidimensional que representa a imagem.

A partir da definição da arquitetura mais adequada, foi realizada tanto a classificação das áreas de treinamento e validação, quanto da cena inteira (imagem) do reservatório de Barra Bonita. Como a imagem abrangendo todo o reservatório era muito grande houve necessidade de reamostrar o tamanho de seus *pixels*, degradando sua resolução espacial. Para isso foi utilizado um recurso do IDRISI (CONTRACT) que reduz o número de linhas e colunas dessa imagem, diminuindo a resolução espacial do *pixel*. O fator de redução foi fixado em 2 (X e Y), de modo que a imagem gerada passou a ter resolução espacial de 60 metros e não mais de 30 metros. Nesse fator de redução, todo segundo *pixel* da imagem foi retido e o restante descartado, e esse novo *pixel* de saída representa a média dos *n pixels* especificados pelo fator escolhido (2), sendo assim o novo *pixel* representa a média de 4 *pixels* de entrada (EASTMAN, 1998). Este processo foi necessário devido as limitações de *hardware* do computador utilizado para o processo de classificação, otimizando o tempo de processamento digital e minimizando o espaço em disco.

### **3.3.2 ETAPA 2 – Aplicação da rede treinada na classificação dos reservatórios de Bariri, Ibitinga, Promissão e Nova Avanhandava**

Selecionada a melhor arquitetura de RNA (aquela que melhor discriminou as classes de saída da rede), essa arquitetura treinada foi aplicada aos demais reservatórios ao longo do rio Tietê, a fim de obter as mesmas classes definidas para Barra Bonita e assim verificar seu potencial na discriminação dessas classes.

Sendo assim, a segunda etapa do projeto consistiu na aplicação da arquitetura selecionada para o reservatório de Barra Bonita aos demais reservatórios do rio Tietê (Bariri, Ibitinga, Nova Avanhandava e Promissão). Para a realização da classificação desses reservatórios foram necessários gerar arquivos contendo os planos de entrada e saída da RNA para cada reservatório, individualmente. Assim, a partir dos planos de entrada da rede constituídos pelas imagens-fração geradas para cada reservatório, foi aplicada a rede treinada com o objetivo de mapear as classes de saída (“água1”, “água2”, “macrófita1”, “macrófita2” e “fundo”) obtidas no treinamento.

Para os reservatórios de Promissão e Nova Avanhandava, foi necessário reamostrar os *pixels* da imagem, utilizando os fatores de redução de 2 e 3, respectivamente. Em função disso, a resolução espacial passou a ter 60 metros para Promissão e 120 metros para Nova Avanhandava.

A cada um dos reservatórios foi aplicada a rede neural, e foram geradas as imagens resultantes para cada um deles, individualmente, através do programa de conversão *snns-pbm*, que fornece a imagem resultante no formato PBM.

### **3.3.3 ETAPA 3 – Análise da Ambigüidade das Classes de Saída na área de treinamento de Barra Bonita**

Um aspecto importante da abordagem desenvolvida com a utilização do simulador SNNS no mapeamento da ocorrência de plantas aquáticas emersas foi a possibilidade de se verificar a ambigüidade entre os tipos de água e macrófitas mapeados. A análise da ambigüidade, nesse caso, pode ser considerada como uma alternativa para avaliar classes misturadas ou que ocorrem nos locais de transições entre classes, nos quais podem ser percebidos dois ou mais tipos consorciados ou identificadas características de classes vizinhas.

A partir do arquivo de saída do simulador SNNS, referente à área de treinamento de Barra Bonita, foram criados arquivos individuais contendo os valores de ativação resultantes do processo de classificação associados a cada classe de saída, produzindo cinco planos de informações individuais (“água1”, “água2”, “macrófita1”, “macrófita2” e “fundo”). A geração desses arquivos foi feita através do programa de conversão *snns-pbm* modificado que, nesse caso, gera essas imagens individuais para cada uma das classes de saída, a partir dos valores de ativação para cada *pixel* da imagem. Com a aplicação desse programa, os valores de ativação que variavam entre 0 e 1 foram normalizados para o intervalo de 0 a 255, possibilitando a visualização das imagens em tons de cinza (ND). Posteriormente, para cada *pixel* da cena, esses valores foram generalizados em categorias designadas por “Muito Baixo” (MB), “Baixo” (B), Médio (M), “Alto” (A) e “Muito Alto” (MA), de acordo com seu grau de associação com a classe em questão.

A definição dos intervalos das classes (MB, B, M, A, MA) foi realizada a partir de uma verificação prévia das imagens que continham os valores de ativação fornecidos pela rede neural para cada classe de saída. Esses valores de ativação foram então associados, de acordo com sua distribuição a intervalos iguais, gerando uma nova representação fatiada para cada classe.

Dessa forma, foram definidos os novos intervalos de atributos representados por uma imagem fatiada, na qual foram definidas cores de forma a melhor representar o grau de associação entre as classes.

Uma análise das imagens individuais geradas para cada classe foi realizada e, a partir disso, foram verificadas as ambigüidades entre as classes de água e de macrófitas através do processo de tabulação cruzada e do índice de concordância *Kappa*.

As tabulações cruzadas realizadas possibilitaram a comparação entre os planos de informação “água1” e “água2”, e os planos “macrófita1” e “macrófita2”, resultando

em duas novas imagens mostrando o grau de associação de cada *pixel* da imagem para as classes de saída analisadas. Essa última verificação foi realizada a partir das imagens resultantes da tabulação cruzada e pelo índice de concordância entre os graus de associação medido nos dois planos de informação.

Apesar de estar prevista inicialmente, a utilização de uma abordagem *fuzzy* na análise da ambigüidade entre as classes de saída da rede neural, ela não foi adotada, pois os valores de ativação obtidos pelo processo de classificação não atenderam as propriedades fundamentais necessárias para aplicação de operações *fuzzy*. Essas propriedades consideram que o somatório dos valores de ativação (calculados para cada elemento do processo de saída da rede) deve ser igual a 1 (Equação 12), o que não foi verificado nos valores de ativação fornecidos pela rede neural.

## 4 RESULTADOS E ANÁLISES

### 4.1 Imagens-Fração derivadas do Modelo de Mistura Espectral: Dados de entrada da RNA

As proporções de mistura espectral 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, com base no comportamento espectral desses alvos. A Tabela 4.1 mostra os coeficientes do modelo linear usado para a transformação nos componentes: solo, vegetação e água, ou seja, para gerar as imagens-fração correspondentes para o reservatório de Barra Bonita.

Tabela 4.1 - Valores obtidos a partir da amostragem dos *pixels* “puros” identificados na imagem de Barra Bonita.

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

A Tabela 4.1 indica a contribuição de cada banda na definição de cada componente de mistura. Na componente solo pode-se verificar que há uma maior participação da banda ETM+5 (0,310) na sua formação, enquanto que a banda ETM+4 contribui mais para a formação da componente vegetação (0,337). A componente água tem maior proporção da banda ETM+1 (0,180), ou seja, possui maior participação da componente nos menores comprimentos de onda. Resultados análogos a esse ocorreram nos demais reservatórios em estudo, podendo ser analisados da mesma forma.

A aplicação do modelo de mistura espectral em todos os reservatórios ao longo do rio Tietê (Barra Bonita, Bariri, Ibitinga, Promissão e Nova Avanhandava) foi também realizada no *software* SPRING, usando um estimador pelo Método dos Mínimos

Quadrados Ponderado. Esse estimador busca iterativamente a solução do sistema de equações lineares produzindo um indicador de erro de estimação para cada banda espectral, minimizando assim a soma dos quadrados dos erros. O cálculo desses erros no processo de estimação de proporções e a geração de imagens de erro são indicadores da adequação dos componentes selecionados, e auxiliam na análise do modelo de mistura de uma determinada cena.

Os erros nas bandas ETM+1, ETM+2, ETM+3, ETM+4, ETM+5 e ETM+7 e o erro médio total de estimação obtido para todos os reservatórios podem ser verificados na Tabela 4.2.

Tabela 4.2 – Erro por banda e erro total de estimação dos reservatórios ao longo do rio Tiete.

<b>Erro/banda</b>	<b>Barra Bonita</b>	<b>Bariri</b>	<b>Ibitinga</b>	<b>Promissão</b>	<b>Nova Avanhandava</b>
<b>ETM+1</b>	1,670	4,400	2,783	1,867	1,718
<b>ETM+2</b>	3,824	4,568	2,958	3,053	2,556
<b>ETM+3</b>	4,132	4,127	3,197	2,932	3,066
<b>ETM+4</b>	0,557	1,429	1,991	1,963	2,299
<b>ETM+5</b>	2,369	2,805	3,097	5,478	5,288
<b>ETM+7</b>	1,728	3,548	2,653	5,619	4,248
<b>Erro Total</b>	2,380	3,480	2,780	3,486	3,196

Os valores de erro estimados resultantes dessa aplicação referem-se ao ajustamento do modelo de transformação dos dados em frações de imagem, indicando a adequação dos componentes selecionados (amostras) e de suas assinaturas espectrais. De acordo com a Tabela 4.2, esses erros dependem da imagem considerada, e em termos relativos indicam menores valores associados à banda ETM+4 (exceto para Nova Avanhandava e Promissão).

As imagens-fração geradas, correspondentes à água, solo e vegetação, para o reservatório de Barra Bonita são mostradas na Figura 4.1.

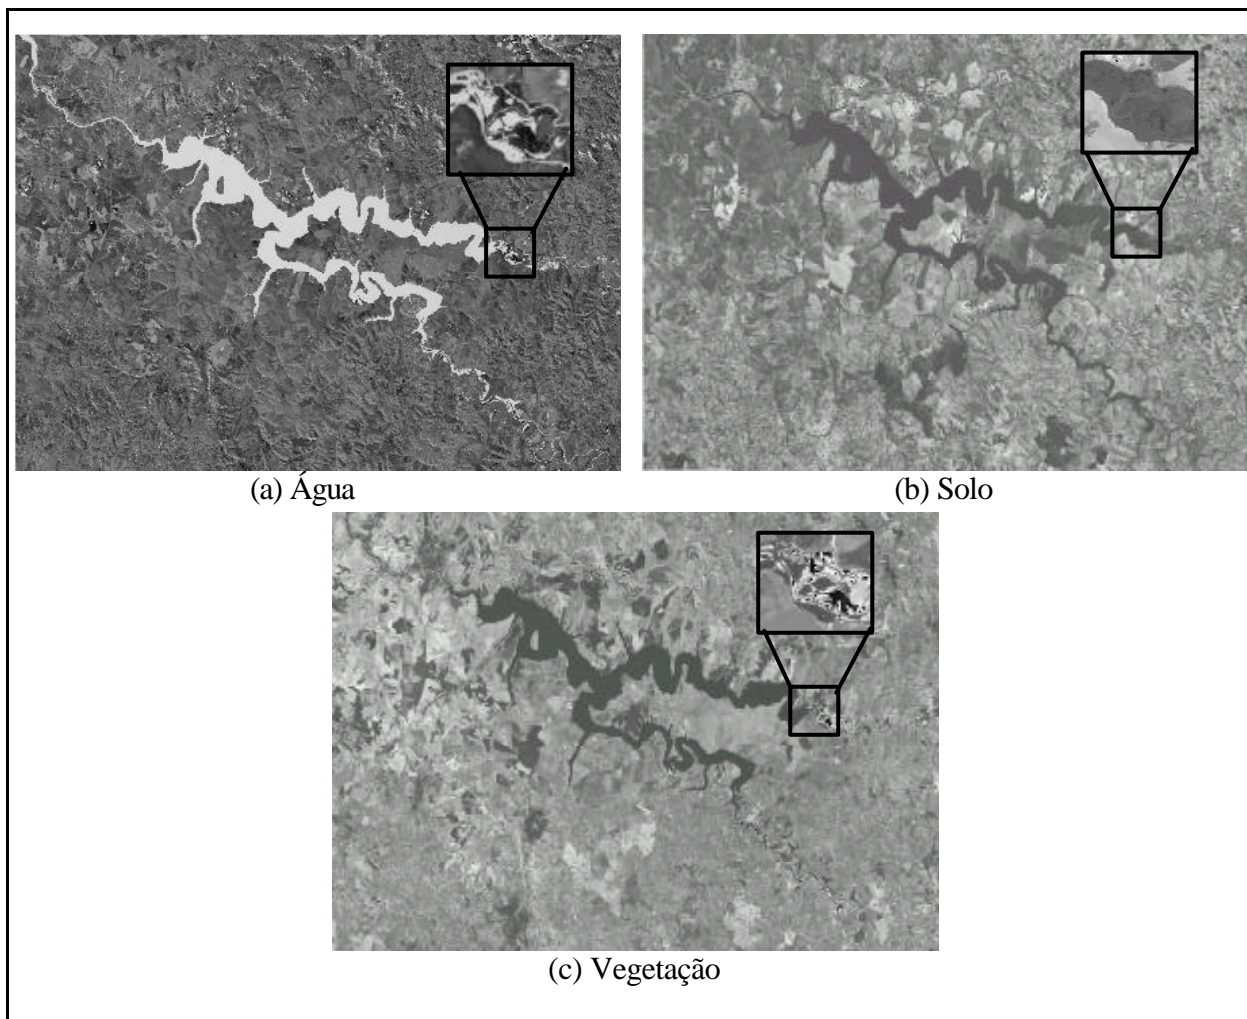


FIGURA 4.1 - Imagens-fração correspondentes as componentes “puras” água (a); solo (b) e vegetação (c), resultantes da aplicação do modelo linear de mistura espectral.

Observando individualmente as imagens-fração pode-se verificar que na componente água, apresentada na Figura 4.1 (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. As variações nos tipos de vegetação aparecem em tons mais escuros, o que pode ser verificado em destaque nas áreas onde existem macrófitas aquáticas emersas.

A componente solo, representada na Figura 4.1 (b), mostra que a vegetação e a água estão associadas a um tom de cinza escuro, enquanto que o solo exposto aparece em tons de cinza mais claros na cena. Na componente vegetação (Figura 4.1 (c)) pode-se verificar que as áreas de ocorrência de plantas aquáticas em Barra Bonita aparecem em tons muito

claros, enquanto os corpos d'água e solo exposto (bem definidos) aparecem numa tonalidade escura.

A diferenciação das imagens contendo as áreas consideradas de interesse indica a importância desses componentes “puros” na discriminação das classes de saída da rede, no caso das macrófitas aquáticas emersas existentes no reservatório de Barra Bonita.

As imagens-fração geradas, correspondentes à água, solo e vegetação, para os demais reservatórios ao longo do rio Tietê, são mostradas na Figura 4.2.

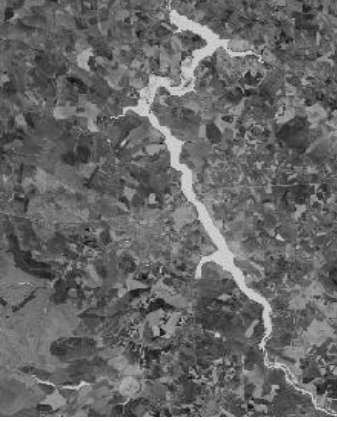
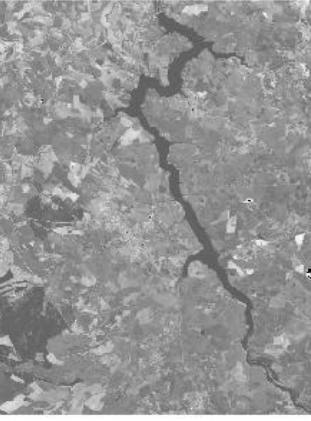
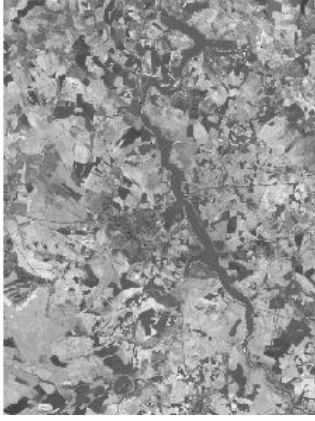
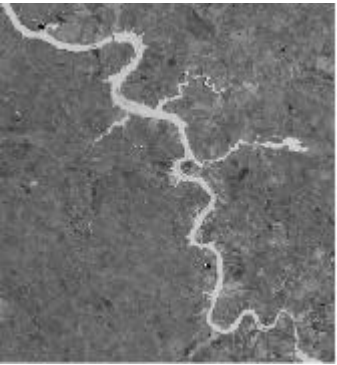
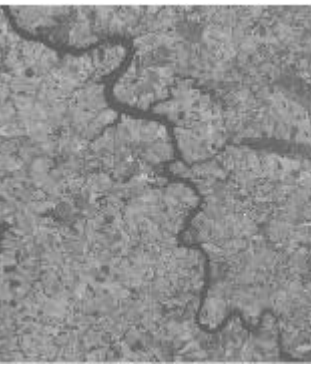

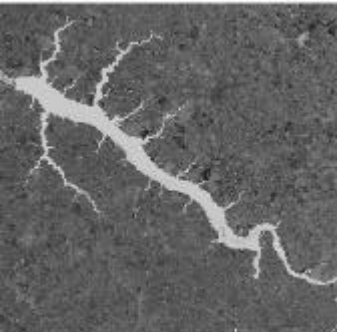


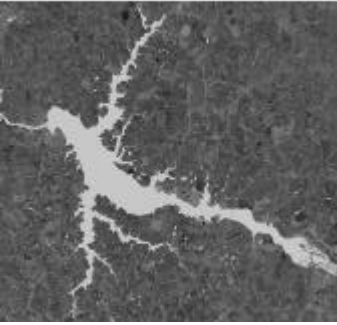

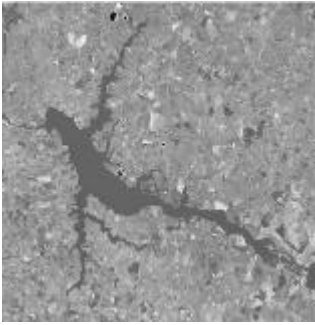
Imagens-fração/ Reservatórios	ÁGUA	SOLO	VEGETAÇÃO
<b>Bariri</b>			
<b>Ibitinga</b>			
<b>Promissão</b>			
<b>Nova Avanhandava</b>			

FIGURA 4.2 - Imagens-fração correspondentes as componentes água, solo e vegetação, resultantes da aplicação do modelo linear de mistura espectral dos reservatórios de Bariri, Ibitinga, Promissão e Nova Avanhandava.

As análises referentes aos componentes individuais (água, solo e vegetação) das imagens-fração dos demais reservatórios do rio Tietê (Figura 4.2) ocorreram de maneira análoga àquela realizada para reservatório de Barra Bonita (Figura 4.1).

Para a definição dos dados de entrada da rede neural, foi também considerada a correlação entre todas as imagens multiespectrais e aquelas derivadas do modelo de mistura. A Tabela 4.3 mostra a matriz de correlação entre as imagens ETM+ e as imagens-fração para Barra Bonita.

Tabela 4.3 - Matriz de Correlação entre as bandas multiespectrais ETM+/Landsat e as imagens-fração água, solo e vegetação.

	<b>ETM+ 1</b>	<b>ETM+ 2</b>	<b>ETM+ 3</b>	<b>ETM+ 4</b>	<b>ETM+ 5</b>	<b>ETM+ 7</b>	<b>Solo</b>	<b>Vegetação</b>	<b>Água</b>
<b>ETM+1</b>	1	0,875	0,844	0,199	0,636	0,721	0,653	-0,194	-0,397
<b>ETM+2</b>	0,875	1	0,886	0,425	0,762	0,767	0,722	0,003	-0,629
<b>ETM+3</b>	0,844	0,886	1	0,173	0,772	0,879	0,864	-0,291	-0,486
<b>ETM+4</b>	0,199	0,425	0,173	1	0,52	0,255	0,151	0,856	-0,897
<b>ETM+5</b>	0,636	0,762	0,772	0,52	1	0,924	0,893	0,053	-0,813
<b>ETM+7</b>	0,721	0,767	0,879	0,255	0,924	1	0,953	-0,24	-0,606
<b>Solo</b>	0,653	0,722	0,864	0,151	0,893	0,953	1	-0,327	-0,551
<b>Vegetação</b>	-0,194	0,003	-0,291	0,856	0,053	-0,24	-0,327	1	-0,582
<b>Água</b>	-0,397	-0,629	-0,486	-0,897	-0,813	-0,606	-0,551	-0,582	1

A Tabela 4.3 mostra que ocorre uma correlação entre as bandas, isto pode ser verificado nas bandas ETM+1 (0,875) e ETM+2 (0,844), as quais são bastante correlacionadas com a banda ETM+3. A banda ETM+7 é altamente correlacionada com ETM+3 (0,879) e ETM+5 (0,924) e, ainda com a imagem-fração solo (0,953). Observa-se também que a imagem-fração solo apresenta correlação com as bandas ETM+3 (0,864) e ETM+5 (0,893); a imagem-fração vegetação é correlacionada com a banda ETM+4, e a imagem-fração água apresenta correlação com as bandas ETM+4 e ETM+5. Como ocorrem correlações entre as bandas espectrais e as imagens-fração, considerou-se adequado o uso das imagens-fração solo, vegetação e água nos processamentos posteriores, uma vez que essas imagens derivadas do modelo de mistura evidenciam as feições de interesse. Assim, a escolha dessas imagens deveu-se ao fato delas representarem os componentes “puros” da cena, e

apresentarem correlação com as bandas espectrais ETM+/Landsat originais, apresentando informações redundantes (correlacionadas).

Dessa forma, definiu-se o uso das imagens-fração água, solo e vegetação, derivadas do modelo de mistura espectral ao invés das bandas originais, como dados de entrada para a classificação pela rede neural artificial, constituindo assim três planos de entrada da rede.

#### **4.2 Características das Amostras de Treinamento e Validação da RNA para Barra Bonita**

Na definição das áreas utilizadas no treinamento e validação para o processo de classificação pela rede neural artificial para o reservatório de Barra Bonita, teve-se o cuidado de verificar se todas as classes de saída estavam contidas nas áreas selecionadas (tanto para treinamento como para validação), a fim de garantir que fossem reconhecidas na classificação. Nesse sentido, foi escolhida uma área de treinamento e uma de validação ao longo dos rios Tietê e Piracicaba.

A Figura 4.3 mostra a localização da área de treinamento selecionada, assim como da amostra de validação, delimitadas em uma composição colorida das bandas ETM + 3 4 e 5 associadas às cores azul (B), verde (G) e vermelho (R) respectivamente, e indicadas no contexto da área a ser classificada para Barra Bonita.

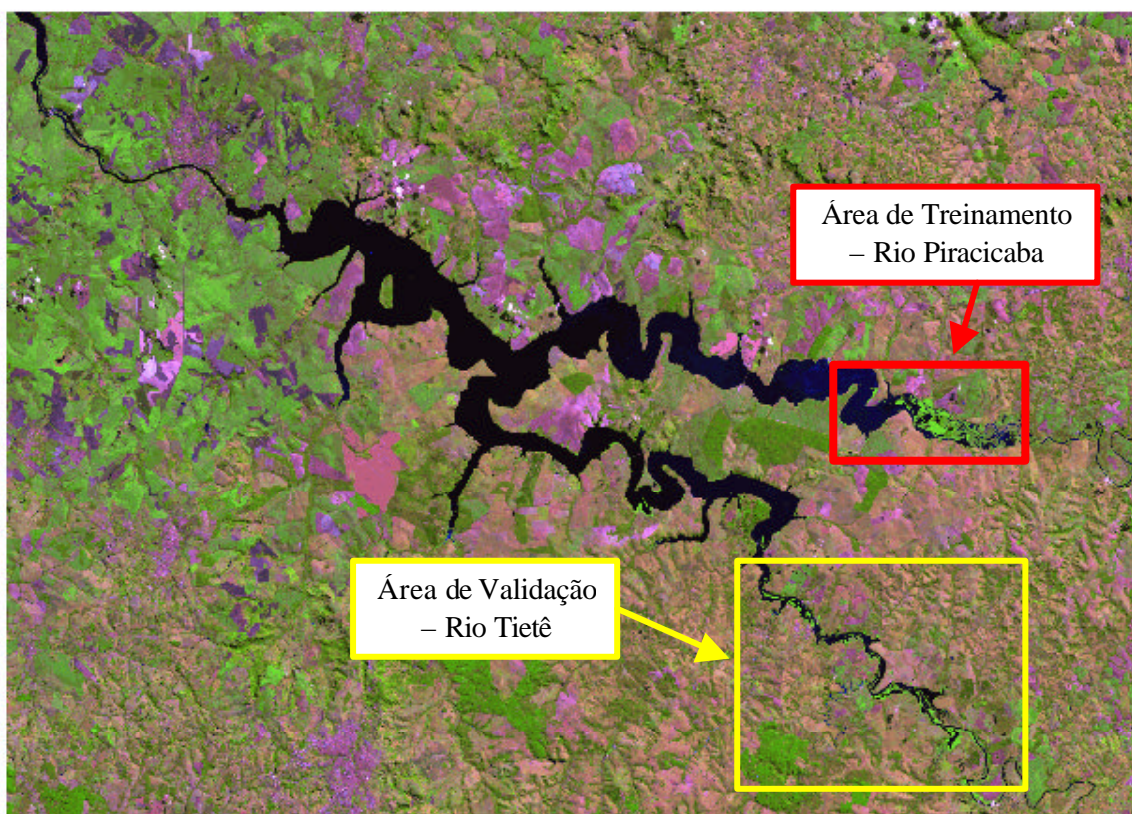


FIGURA 4.3 - Localização das amostras de treinamento e validação na área de estudo contendo o reservatório de Barra Bonita.

Pela Figura 4.3 pode-se verificar que as áreas selecionadas para treinamento e validação foram aquelas que apresentaram maior concentração e dispersão espacial das macrófitas aquáticas emersas nesse reservatório, o que justifica a escolha dessas duas áreas, para o processo de classificação por Redes Neurais Artificiais.

A partir da aquisição das áreas de treinamento e validação e da definição dos dados de entrada e saída da rede, foi realizada uma análise da variabilidade das amostras de treinamento e validação para cada uma das cinco classes de saída da rede. Nesse sentido, foram avaliados a média e desvio padrão dos números digitais (NDs) dos *pixels* amostrados por classe, para cada um dos planos de entrada (imagens-fração água, solo e vegetação). Para uma melhor visualização do comportamento médio das classes, foram elaborados gráficos que mostram os valores obtidos para cada classe (água1, água2, macrófita1 e macrófita2). Os

parâmetros estatísticos extraídos da área de treinamento e da amostra de validação são apresentados nas Tabelas 4.4 e 4.5 e nas Figuras 4.4 e 4.5, respectivamente.

Tabela 4.4 - Média e desvio padrão dos NDs (Número Digitais) das classes extraídos a partir de cada plano de entrada para a amostra de Treinamento.

Planos	Imagem Fração Água		Imagem Fração Solo		Imagem-fração Vegetação	
	Médias	DP	Média	DP	Média	DP
água1	205,77	24,68	97,168	11,73	90,052	11,32
água2	207,106	4,621	104,133	2,34	87,25	3,246
Macrófita1	40,95	16,41	93,159	17,76	112,11	111,181
Macrófita2	65,53	36,14	89,579	45,960	161,36	83,64

Analisando a Tabela 4.4, pode-se observar que os valores de média obtidos na classe “água1”, para o plano da imagem-fração solo e vegetação (97,168 e 90,052, respectivamente) apresentaram valores de média próximos, podendo dessa forma ocasionar alguma confusão na definição dessa classe nessas imagens. As classes “água1” e “água2” (205,77 e 207,106), para os planos imagem-fração água e vegetação (90,52 e 87,25), assim como as classes “macrófita1” e “macrófita2” (93,159 e 89,579), para o plano de imagem-fração solo, apresentam médias muito próximas, podendo indicar confusão na discriminação dos dados no processo de treinamento da rede. Também as classes “água1” (97,168) e “macrófita1” (93,159), e as classes “água2” (87,25) e “macrófita2” (89,579), para as imagens-fração solo e vegetação, podem ocasionar alguma confusão na definição das classes nessas bandas. Isto também pode ser verificado pela Figura 4.4 que mostra o gráfico do comportamento médio dos números digitais referentes a cada classe, para as imagens-fração geradas.

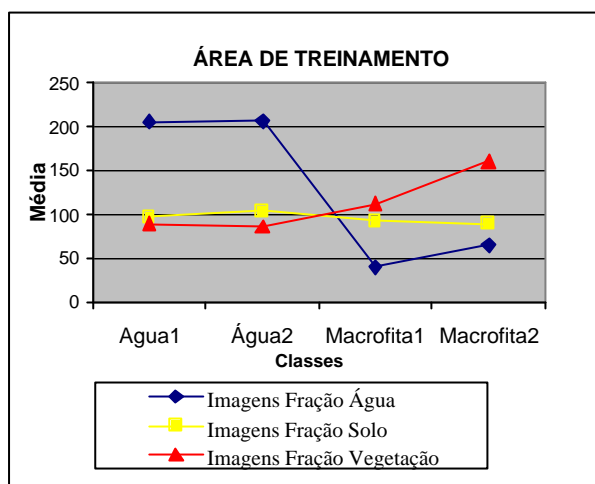


FIGURA 4.4 – Média e desvio padrão dos NDs das classes extraídas a partir de cada plano de entrada para a amostra de Treinamento.

Na análise da Figura 4.4, referente a área de treinamento, as médias das proporções de mistura obtidas nas imagens-fração vegetação e solo, referentes às classes “água1” e “água2”, são bastante próximas, confirmando que pode ocorrer dificuldade na diferenciação dessas classes com base nos dados de treinamento adquiridos. Uma observação a ser feita para a imagem-fração solo é que todas as classes apresentam valores muito próximos neste plano. As classes para a imagem-fração água apresentam-se bem diferenciadas, podendo melhor representar as diferentes classes nessa imagem. A classe “macrófita2” apresenta valores bem diferenciados nas três imagens-fração geradas, indicando sua melhor separabilidade das demais classes de saída.

A Tabela 4.5 mostra os parâmetros obtidos nas mesmas condições, para a amostra de Validação.

Tabela 4.5 - Média e desvio padrão dos NDs das classes extraídos a partir de cada plano de entrada para a amostra de Validação.

Planos	Imagem Fração Água		Imagem Fração Solo		Imagem-fração Vegetação	
	Média	DP	Média	DP	Média	DP
Água1	209,88	1,860	96,293	1,772	92,326	2,158
Água2	182,027	63,859	90,535	31,699	82,965	29,48
Macrófita1	50,207	14,085	95,894	8,253	129,70	115,33
Macrófita2	55,856	45,333	72,774	51,815	126,43	99,71

A partir dos dados dessa Tabela, foi elaborado o gráfico representando a média das classes de saída, juntamente com os seus respectivos planos de entrada para a validação. A Figura 4.5 ilustra esse gráfico.




FIGURA 4.5 – Média e desvio padrão dos NDs das classes extraídos a partir de cada plano de entrada para a amostra de Validação.

Conforme pode ser observado na Tabela 4.5 e na Figura 4.5, as médias extraídas para a área de validação das imagens-fração solo e vegetação, classes “água1” e “água2”, apresentam-se similares. Para a componente solo as médias para as quatro classes estão muito próximas dificultando sua separação. Na componente água percebe-se uma variabilidade maior nas médias calculadas para as diferentes classes representando melhor essas classes, nessa componente. De acordo com as médias apresentadas para a área de validação, as classes “macrófita1” e “macrófita2” serão as classes melhor discriminadas.

Dessa forma, pela análise das médias obtidas para as áreas de treinamento e validação pode-se inferir que, nas imagens-fração solo e vegetação, as classes “água1” e “água2”, devem apresentar maior confusão no processo de classificação pela rede neural.

### 4.3 Arquiteturas de Redes Neurais Artificiais testadas

Definidos os dados de entrada e saída da rede, assim como as áreas de treinamento e validação, uma arquitetura parcial para a Rede Neural Artificial foi determinada, considerando o número de elementos de processamento da camada de entrada (3 nós) e o número de unidades de processamento de saída (5 nós, um para cada classe). A partir disso, foi necessário estabelecer o número de camadas escondidas para que o processo de treinamento da rede fosse iniciado. Nessa etapa várias simulações foram realizadas utilizando diferentes arquiteturas de rede, visando encontrar a configuração de rede mais adequada para representar as classes de interesse.

Testes anteriores foram realizados com uma outra arquitetura inicial (camada de entrada e saída) composta de seis elementos na camada de entrada (ETM+3, ETM+4, ETM+5, imagens-fração água, solo e vegetação) e oito elementos na camada de saída (água1, água2, macrófita1, macrófita2, macrófita3, macrófita4, indefinido e fundo). Os resultados apresentados pelo treinamento dessa rede considerando essa arquitetura inicial não foram considerados satisfatórios, devido aos dados de entrada da rede apresentarem correlação (bandas espectrais e as imagens-fração) e algumas classes de saída terem valores similares e outras classes não serem discriminadas. Um outro fator importante a ser considerado é o tempo computacional gasto, pois essa rede apresentava-se muito complexa (muitos elementos a serem processados) tornando o treinamento muito demorado.

Assim, houve a necessidade de definir novos dados de entrada e novas classes de saída. Os novos testes foram realizados utilizando arquiteturas de três camadas de entrada, cinco classes de saída e, com duas camadas escondidas, normalmente suficientes para separar classes com características espectralmente similares, já que produzem superfícies de decisão mais complexas. Dessa forma, a arquitetura contendo duas camadas escondidas

teoricamente, podem melhor representar as classes que apresentam características muito homogêneas na cena. A configuração final da Rede Neural Artificial pode ser visualizada na Figura 4.6.




FIGURA 4.6 – Configuração final da Rede Neural Artificial.

As simulações e o número de classes de saída definidas pela rede na amostra de validação são mostradas na Tabela 4.6, na qual estão indicados: a arquitetura de rede, o número de ciclos usados para treinar cada arquitetura de rede, o erro médio quadrático (EMQ) da validação, o número de classes discriminadas no treinamento e o critério de definição do número de nós das camadas escondidas usadas no treinamento da Rede Neural Artificial. Para especificar cada arquitetura de rede treinada, adotou-se o seguinte padrão: [número de nós na camada de entrada – número de nós da camada escondida (podendo variar de uma, duas ou três) – número de nós na camada de saída].

Tabela 4.6 - Resumo das simulações realizadas para o treinamento da rede.

Arquitetura da Rede	Número de ciclos de Treinamento	EMQ Validação	Número de classes discriminadas	Critério para definir o número de nós escondidos
[3-13-7-5]	5000	0,01014	05	Tentativa e Erro
[3-21-11-5]	5500	0,01015	05	Tentativa e Erro
[3-37-29-5]	1000	0,03184	04	Tentativa e Erro
[3-25-16-5]	4000	0,00997	04	Tentativa e Erro
[3-49-41-5]	1500	0,02980	04	Tentativa e Erro

Pela Tabela 4.6 percebe-se que o EMQ obtido para os dados de validação é bastante reduzido, porém algumas arquiteturas não apresentaram resultados satisfatórios na definição do número de classes de saída. Embora a arquitetura [3-25-16-5] tenha apresentado um EMQ menor em relação às outras arquiteturas, a mesma não conseguiu discriminar todas as classes de saída estipuladas, e dessa forma não foi utilizada na classificação dos reservatórios em estudo.

Assim, as arquiteturas que apresentaram melhores resultados na classificação das classes de saída foram: [3-13-7-5] e [3-21-11-5], pois conseguiram classificar todas as classes de saída pré-estabelecidas. Embora essas duas arquiteturas fossem consideradas satisfatórias, a arquitetura [3-21-11-5] classificou as classes de saída de forma mais adequada, isso foi verificado visualmente na imagem de saída gerada pela rede.

Uma forma de apresentação do resultado obtido é mostrada na Figura 4.7, na qual a classificação gerada é indicada em arquivo texto, que informa a quantidade de *pixels* e porcentagem atribuída a de cada classe de saída.

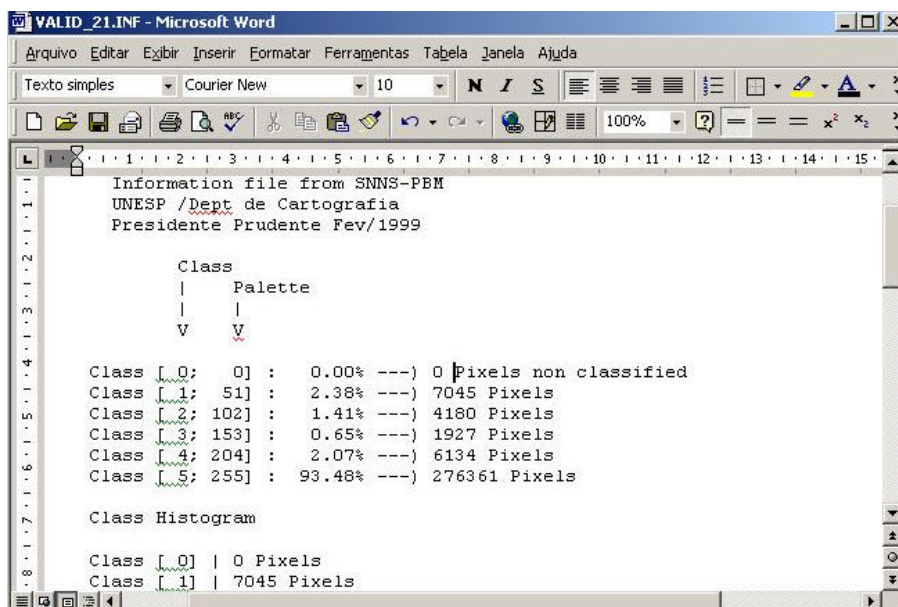


FIGURA 4.7 – Arquivo das classes de saída, na forma descritiva, gerado a partir da classificação pelo programa de conversão snns-pbm.

Na Tabela 4.7 é apresentada a proporção de *pixels* associados a cada uma das cinco classes de saída para a área de validação, obtida através do programa de conversão *snns-pbm*.

Tabela 4.7 - Proporção de *pixels* associados a cada classe na amostra de validação.

Arquiteturas de RNA	Ciclos	Número de <i>pixels</i> /Classe (%)				
		Água 1	Água2	Macrófita1	Macrófita2	fundo
[3-13-7-5]	5000	1,70	2,49	0,69	1,65	93,48
[3-21-11-5]	5500	2,38	1,41	0,65	2,07	93,48
[3-37-29-5]	1000	0	4,27	0,63	1,62	93,48
[3-25-16-5]	4000	0	3,19	0,56	2,77	93,48
[3-49-41-5]	1500	1,58	3,62	0	1,32	93,48

Como pode ser verificado na Tabela 4.7, o treinamento com as arquiteturas [3-13-7-5] e [3-21-11-5] apresentou resultados satisfatórios, pois foram discriminadas todas as classes de saída estabelecidas. Embora as duas arquiteturas tenham fornecido uma adequada representação das classes de saída estabelecidas, a arquitetura [3-21-11-5] conseguiu discriminar com melhor precisão as regiões onde ocorriam macrófitas aquáticas emersas e os tipos de água distintos na cena.

Ainda de acordo com a Tabela 4.7 pode-se verificar que a classe “fundo”, classificada apresentou-se bem diferenciada do restante das classes de saída, pois sua proporção de *pixels* manteve-se estável durante todos os treinamentos realizados.

#### 4.4 Classificação resultante da aplicação da RNA às áreas de treinamento e validação

As classificações das áreas de treinamento e validação, resultantes da aplicação da arquitetura [3-21-11-5] treinada com 5500 ciclos ou iterações, são mostradas nas figuras 4.8 e 4.9, respectivamente para as áreas de treinamento e validação.

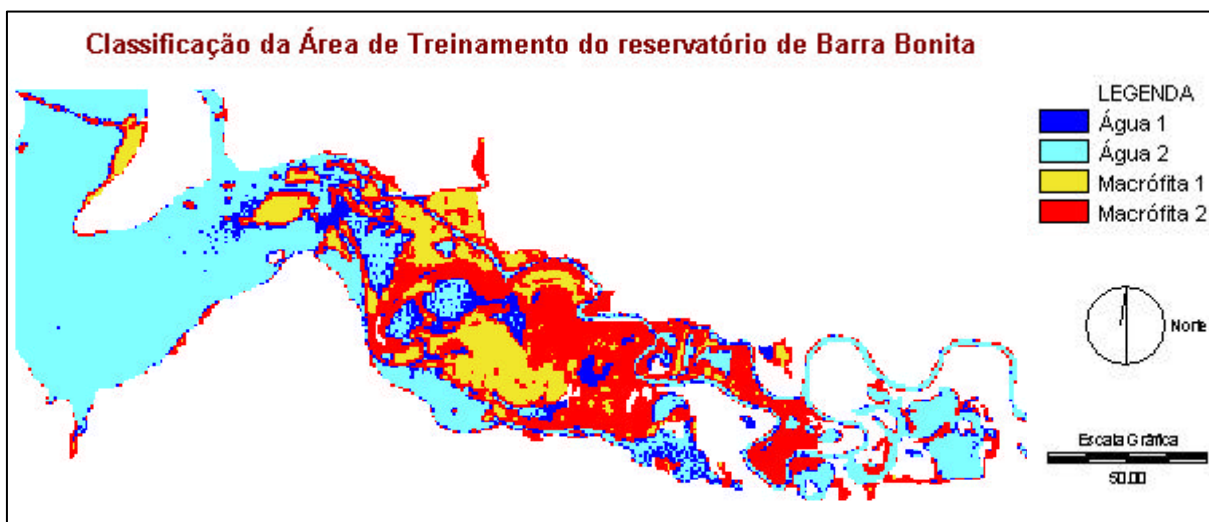


FIGURA 4.8 – Classificação resultante da aplicação da arquitetura [3-21-11-5] a área de treinamento.

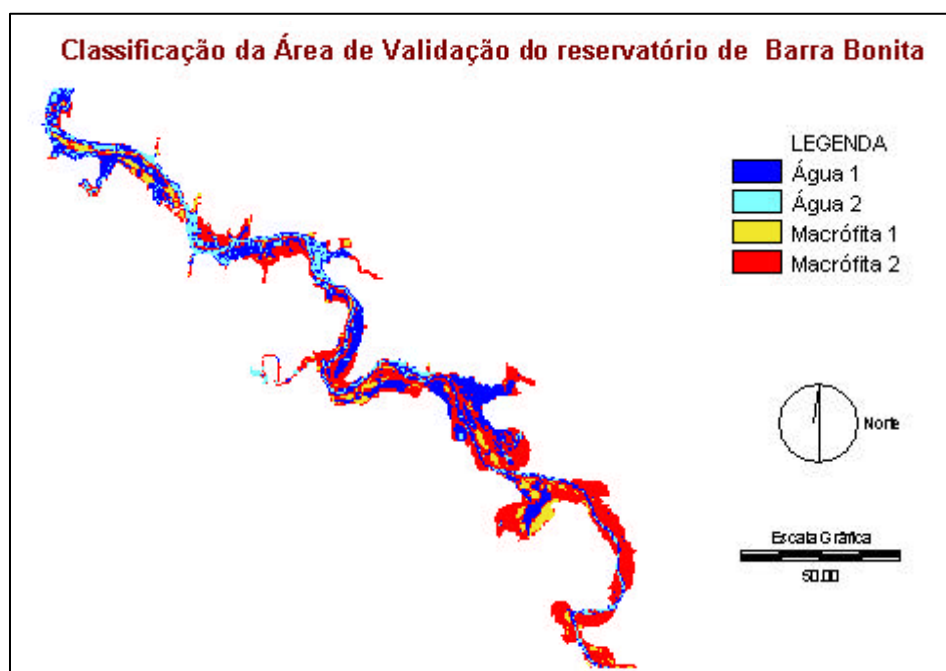


FIGURA 4.9 – Classificação resultante da aplicação da arquitetura [3-21-11-5] a área de validação.

Analisando as classificações realizadas para as áreas de treinamento (Figura 4.8) e validação (Figura 4.9) pode-se verificar a ocorrência de grandes massas de macrófitas aquáticas emersas e sua dispersão no leito dos rios Piracicaba (treinamento) e Tietê (validação), que podem ser encontradas ao longo de todo reservatório. A grande concentração de plantas aquáticas ilustra o grau de infestação por esse tipo de vegetação nesse reservatório. Os tipos de macrófitas (“macrófita1” e “macrófita2”) foram bem discriminados com a

utilização dessa arquitetura 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 entre os tipos de água e macrófitas existentes ficaram bem definidas.

Em termos gerais, as classificações obtidas para as áreas de treinamento e validação foram consideradas satisfatórias, pois possibilitaram discriminar todas as classes de saída pré-estabelecidas.

#### **4.5 Classificação resultante da aplicação da RNA treinada ao Reservatório de Barra Bonita**

A cena classificada contendo o reservatório de Barra Bonita (imagem inteira), resultante da aplicação da arquitetura [3-21-11-5] pode ser visualizada Figura 4.10.

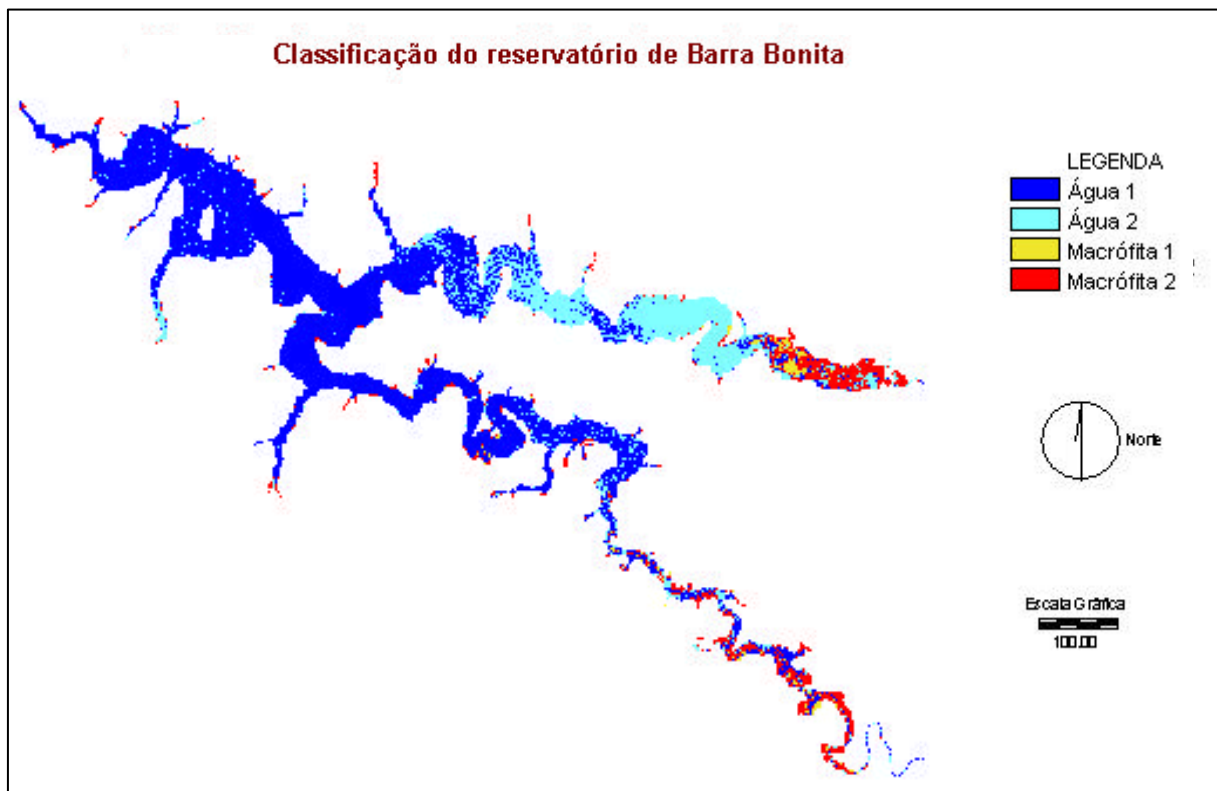


FIGURA 4.10 – Imagem resultante da classificação do reservatório de Barra Bonita a partir da aplicação da arquitetura [3-21-11-5].

Pela Figura 4.10 pode-se verificar que, com a reamostragem do tamanho dos *pixels* (imagem degradada) a rede treinada conseguiu discriminar as mesmas classes de saída estabelecidas, também de forma satisfatória nas regiões do reservatório que ainda não haviam sido classificadas.

A Tabela 4.8 mostra a proporção de *pixels* classificados para essa imagem (cena inteira de Barra Bonita) fornecidas através do programa *snns-pbm* que também apresenta o resultado da classificação de forma descritiva.

Tabela 4.8 – Proporção de *pixels* classificados para o reservatório de Barra Bonita.

	Classes	Proporção de <i>pixels</i> / Classes (%)	Número de <i>pixels</i> classificados
Arquitetura da Rede  [3-21-11-5]	Água1	6,68	51374
	Água1	2,12	16,328
	Macrófita1	0,16	1253
	Macrófita2	1,01	7797
	Fundo	90,02	692352

Analisando a Tabela 4.8 verifica-se que as classes “macrófita1” e “macrófita2” apresentaram uma porcentagem baixa de *pixels* classificados nessa cena. Na classe “macrófita1” a proporção de *pixels* associados é bem pequena, isso pode ter ocorrido devido a essa classe não ter grandes proporções de *pixels* existentes na própria imagem ou por apresentar similaridade com a classe “macrófita2”, causando confusão na discriminação dessas classes. Como se pode verificar a proporção de *pixels* referentes a classe “água1” na imagem é bem maior do que a proporção da presença de macrófitas nesse reservatório.

#### 4.6 Classificação resultante da aplicação da RNA treinada aos reservatórios de Bariri, Ibitinga, Promissão e Nova Avanhandava

As classificações para os demais reservatórios ao longo do rio Tietê (Bariri, Ibitinga, Promissão e Nova Avanhandava) resultantes da aplicação da arquitetura [3-21-11-5] treinada para Barra Bonita, visava identificar os mesmos tipos de ocorrências (água e plantas aquáticas) identificados neste reservatório. Pela Tabela 4.9 é possível verificar essa condição, através das proporções de *pixels* classificados associados a cada classe de saída, para os reservatórios em estudo, fornecidos pelo arquivo gerado através do programa *snns-pbm*.

Tabela 4.9 – Proporção de *pixels* classificados para os demais reservatórios em estudo.

Arquitetura da Rede [3-21-11-5]										
Classes/ Reservatórios	Água1		Água2		Macrófita1		Macrófita2		Fundo	
	(%)	Nº de <i>pixels</i>	(%)	Nº de <i>pixels</i>	(%)	Nº de <i>pixels</i>	(%)	Nº de <i>pixels</i>	(%)	Nº de <i>pixels</i>
BARIRI	2,53	35857	1,12	15833	0,02	258	0,69	9820	95,64	1355807
IBITINGA	3,84	95816	1,08	26834	0,04	1043	0,88	21836	94,17	2349335
PROMISSÃO	3,73	78369	3,06	64142	0,01	304	0,26	5467	92,94	1954219
NOVA AVANHANDAVA	4,54	29454	4,35	28246	0,01	58	0,76	4964	90,34	586472

Como pode ser verificado pela Tabela 4.9, a classe “macrófita1” apresentou sistematicamente, uma porcentagem muito pequena de *pixels* classificados em todos os reservatórios, o mesmo ocorrendo com a classe “macrófita2” em maior proporção. Para os reservatórios de Promissão e Nova Avanhandava, como os *pixels* foram reamostrados para 60 e 120 metros respectivamente a área estimada (*pixels*/classe) apresenta uma menor proporção em relação ao uso da imagem em tamanho original.

Nas Figuras 4.11, 4.12, 4.13 e 4.14 são apresentados os mapas temáticos, contendo as imagens classificadas dos reservatórios de Bariri, Ibitinga, Promissão e Nova Avanhandava, respectivamente, obtidas mediante aplicação da rede neural utilizando a arquitetura [3-21-11-5].

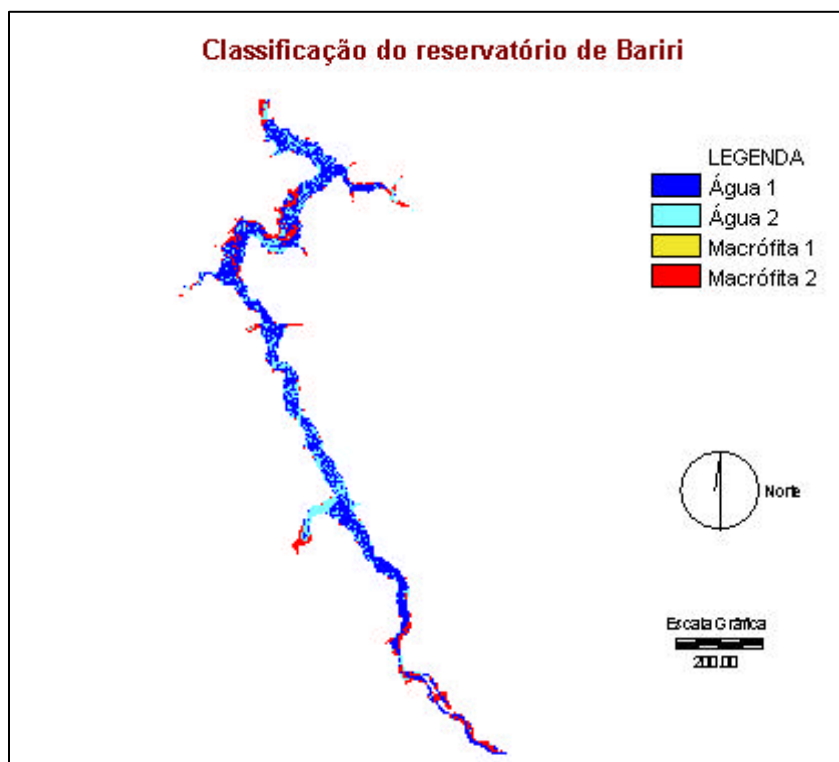


FIGURA 4.11 – Classificação resultante da aplicação da RNA treinada ao reservatório de Bariri.

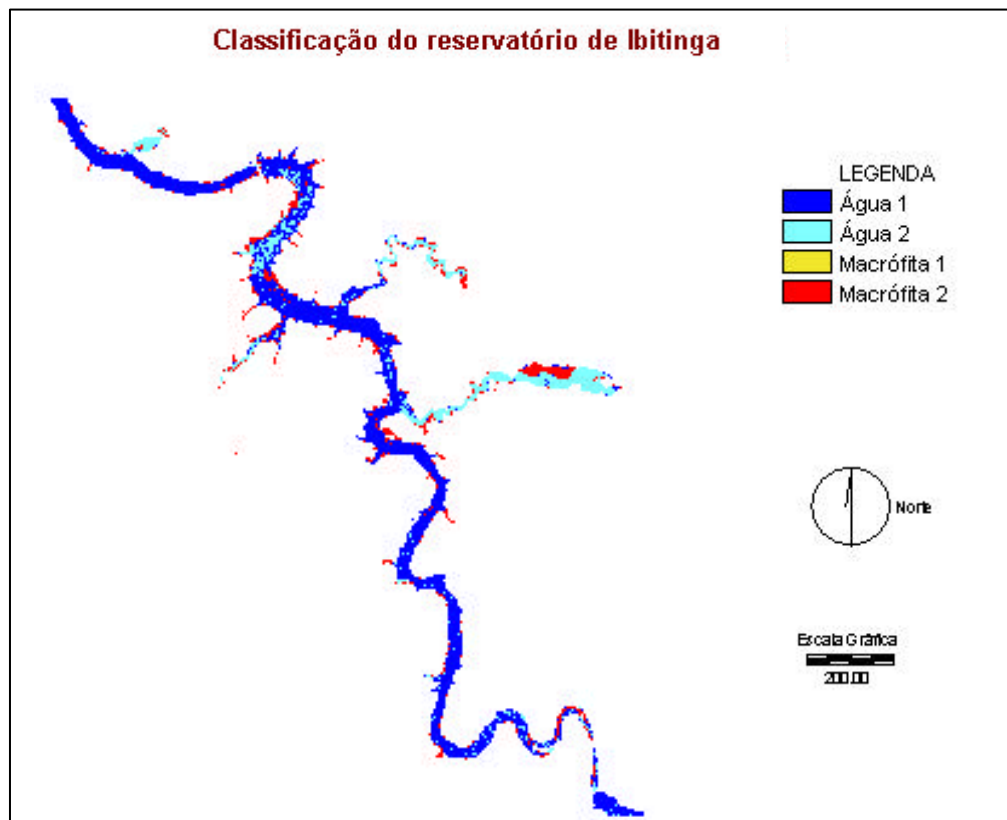


FIGURA 4.12 – Classificação resultante da aplicação da RNA treinada ao reservatório de Ibitinga.

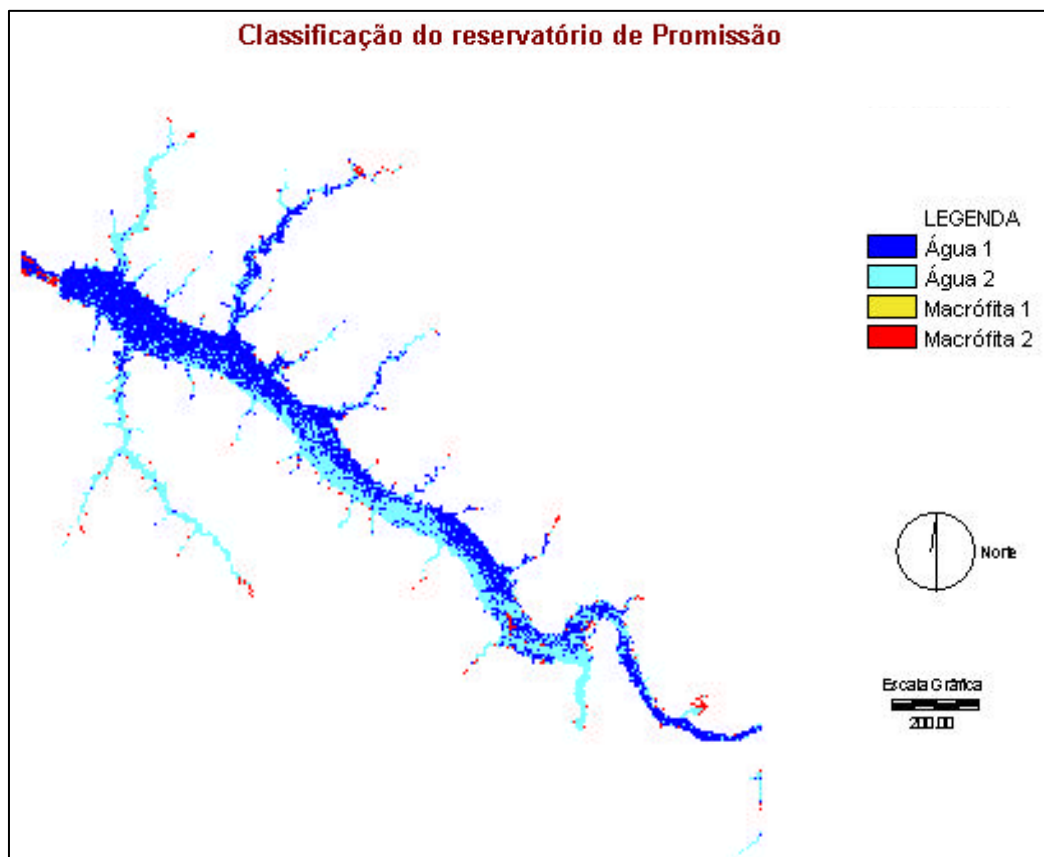


FIGURA 4.13 – Classificação resultante da aplicação da RNA treinada ao reservatório de Promissão.

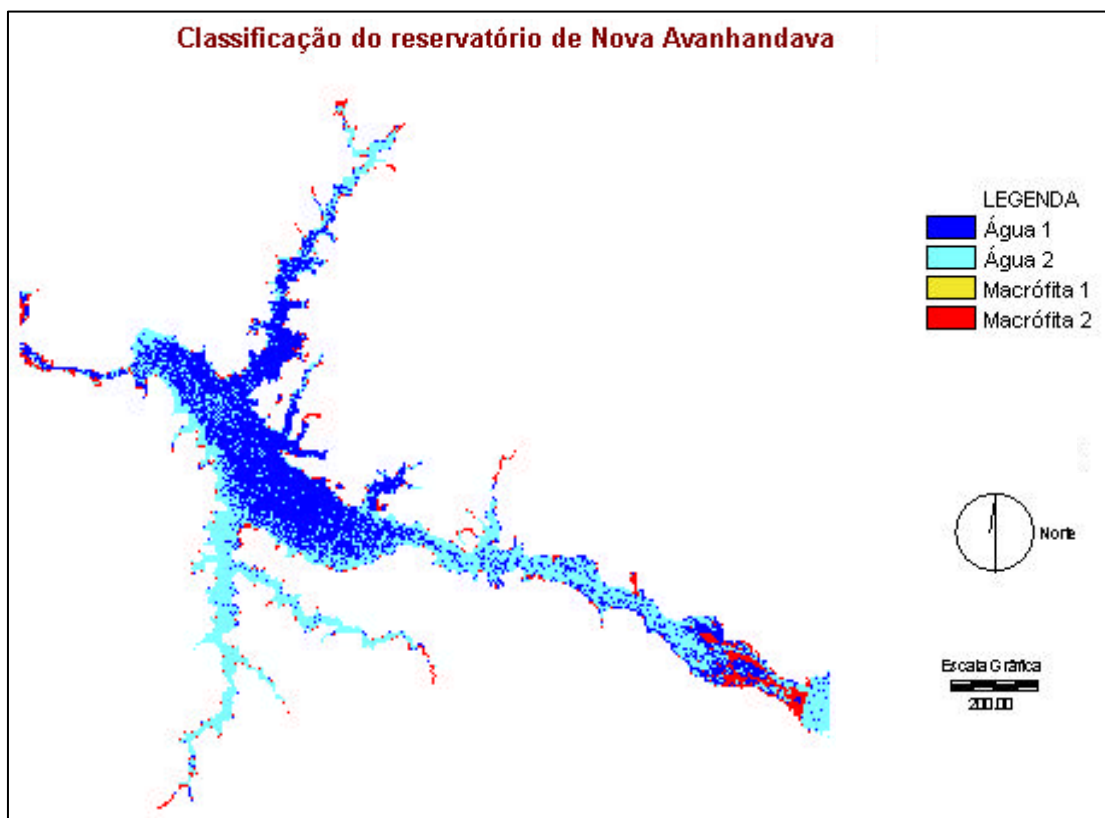


FIGURA 4.14 –Classificação resultante da aplicação da RNA treinada ao reservatório de Nova Avanhandava.

Uma primeira análise das Figuras 4.11, 4.12, 4.13 e 4.14, referentes às classificações de Bariri, Ibitinga, Promissão e Nova Avanhandava mostram que a arquitetura de rede neural treinada para o reservatório de Barra Bonita, teve relativa facilidade em reconhecer classes espectralmente definidas “água1” e “água2”. Uma questão aparente é que o uso da rede treinada a partir de amostras adquiridas em Barra Bonita não conseguiu distinguir um dos tipos de macrófitas (“macrófita1”). Esse resultado pode ter sido ocasionado pelo fato de que as plantas aquáticas oriundas do reservatório de Barra Bonita se deslocam de seu local de origem e as massas de plantas aquáticas se misturam (tipos de plantas diferentes consorciados) e, conseqüentemente, a rede não consegue individualizar os tipos de vegetação presentes.

Portanto, pelas classificações indicadas nas Figuras 4.11 a 4.14, foi possível identificar três classes de saída (“água1”, “água2” e “macrófita2”), com o uso da arquitetura

de rede treinada. Mesmo assim, como se trata da aplicação da rede treinada a partir de amostras do reservatório de Barra Bonita e não para os demais reservatórios, cabe observar que a mesma apresentou resultados satisfatórios, sendo capaz de reconhecer pelo menos três classes de saída, em todos os demais reservatórios ao longo do rio Tietê.

Portanto, pode-se concluir através das análises anteriores que a arquitetura treinada para o reservatório de Barra Bonita, resultou em classificações satisfatórias, mas não totalmente apropriadas para os demais reservatórios. Na verdade, para cada reservatório seria necessário definir classes específicas e treinar uma rede para que estas consigam distinguir todas as classes de saída pré-estipuladas.

#### **4.7 Ambigüidade entre as Classes de Saída: Água e Macrófitas**

A questão da ambigüidade entre as variações de água (1 e 2) e macrófitas (1 e 2) foi verificada somente para a área de treinamento obtida no reservatório de Barra Bonita, por apresentar maior concentração de macrófitas no leito do rio, e por se constituir, aparentemente, no local de origem dessas plantas. A partir do programa de conversão dos dados resultantes da classificação *snns-pbm*, que possibilitou a geração dos arquivos e imagens individuais para cada classe de saída da rede neural e seu valor de ativação correspondente, foi realizada uma análise desses planos de informação individualmente, e sua posterior tabulação cruzada.

O arquivo fornecido pela rede neural associa o nível de ativação de saída a cada classe, como pode ser visualizado na Figura 4.15. A partir desse arquivo são produzidas imagens representando as classes pelo seu valor de ativação obtido para cada *pixel* da imagem.

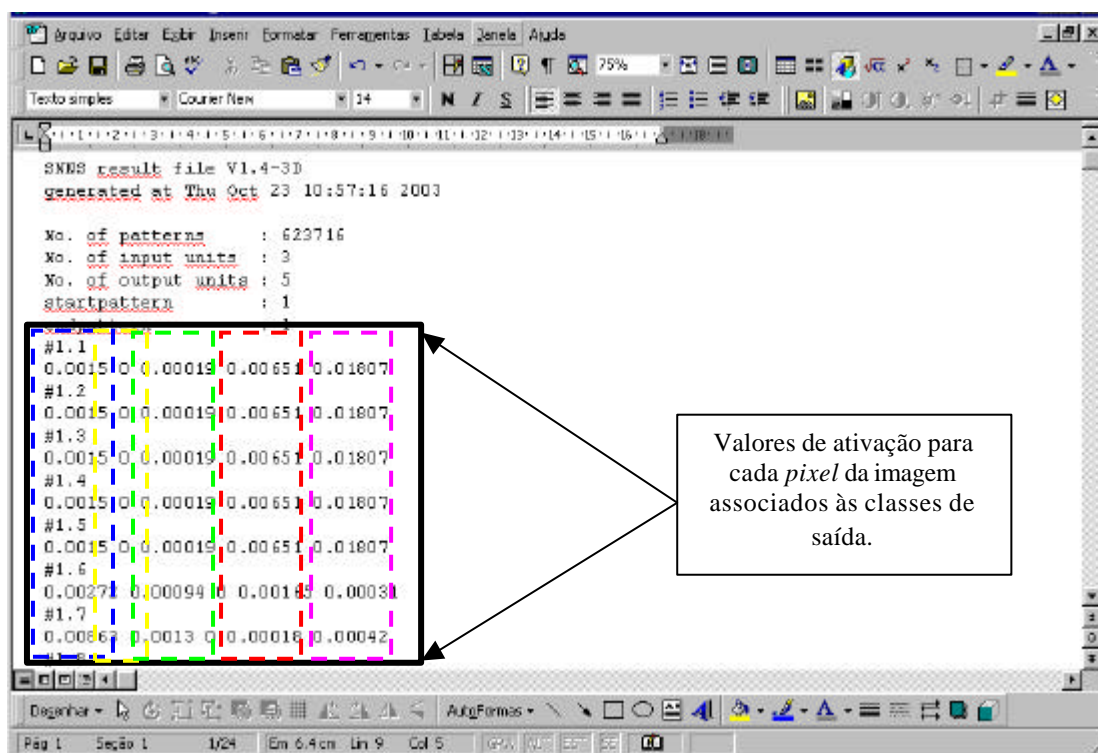


FIGURA 4.15 – Arquivo de saída da rede *snns-pbm* associando as classes de saída com seus respectivos valores de ativação.

A partir da posição de cada coluna de valores de ativação mostrada na Figura 4.15, para cada classe de saída, é gerada uma imagem contendo a classe pelos valores de ativação de cada *pixel* nessa imagem. Desse modo, foram geradas cinco imagens individuais correspondendo a cada uma das classes de saída da rede neural (água1, água2, macrófita1, macrófita2 e fundo).

As imagens mostradas nas Figuras 4.16 a 4.20 indicam o grau de aderência de cada *pixel* da imagem em relação a 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 apresentam associação com a classe de saída especificada, indicando que os *pixels* associados a esse atributo não pertencem a essa classe, 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. Os *pixels* associados a “Baixo” e “Alto” apresentam pequena ambigüidade em relação a duas classes, enquanto que aqueles indicados como “Médio” representam um maior grau de ambigüidade entre duas classes de saída, ou seja, indicam que ocorre confusão entre elas.

A Figura 4.16 ilustra o grau de associação dos *pixels* com a classe de saída da rede neural “Água1”.

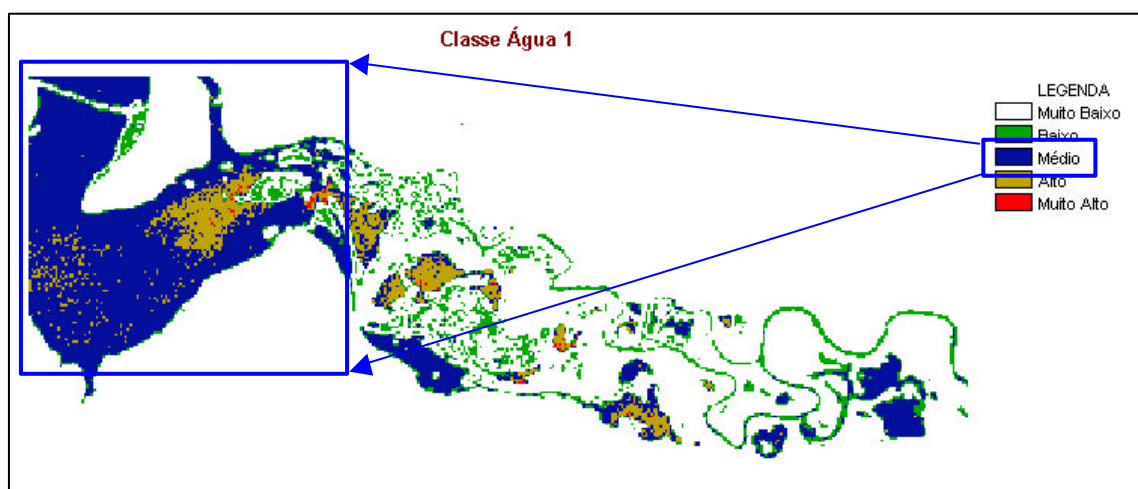


FIGURA 4.16 – Grau de Associação dos *pixels* com a classe “Água1”.

Analisando a Figura 4.16 que representa o plano de informação referente à classe “água1”, pode-se verificar 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 o 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 a outro tipo de água, e ocorrendo em pequena proporção. Nessa figura, o atributo “Médio” ilustra que as classes (“água1” e “água 2”) apresentaram ambigüidade entre si, ou seja, tem valores similares de resposta espectral.

O grau de associação dos *pixels* com a classe de saída “Água2” é ilustrada na Figura 4.17.

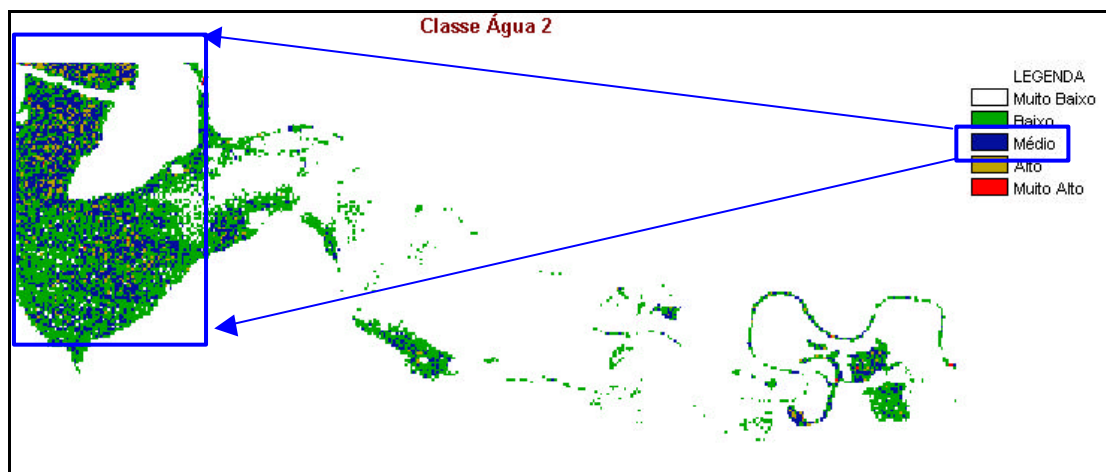


FIGURA 4.17 – Grau de Associação dos *pixels* com a classe “Água2”.

Na Figura 4.17, 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 4.18.

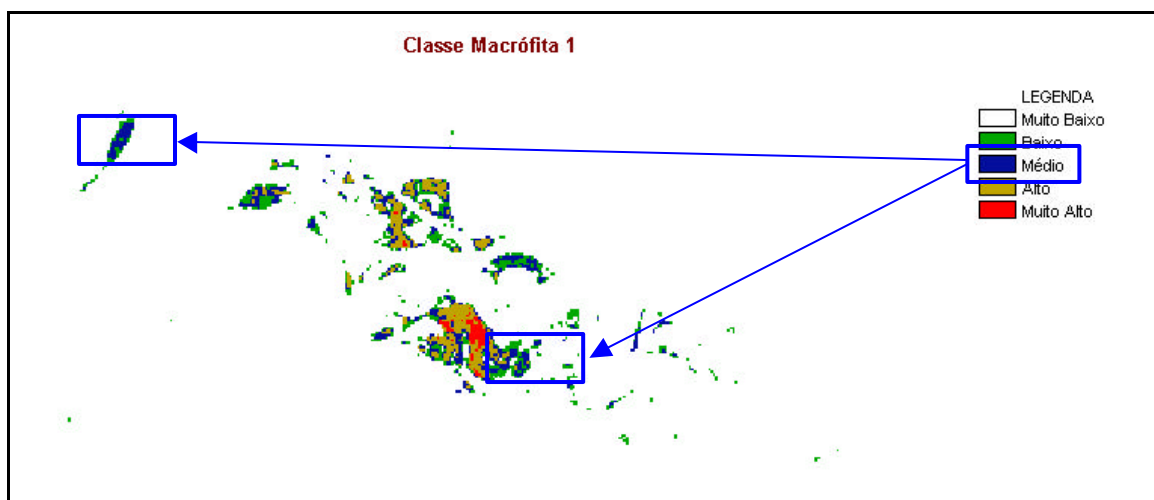


FIGURA 4.18 – Grau de Associação dos *pixels* com a classe “Macrófita1”.

De acordo com a Figura 4.18, que representa a classe “macrófita1”, pode-se observar que foram poucos os *pixels* associados ao atributo “Médio”, indicando que um número reduzido de *pixels* apresentam ambigüidade ou confusão nessa classe. Como pode ser verificado nessa 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” (classe com a qual “macrófita1” poderia se confundir). Apesar disso, em algumas pequenas regiões com a presença de macrófitas aquáticas, os *pixels* não apresentaram associação com a classe em “macrófita1”. A ocorrência do atributo “Muito Alto” ilustra que os *pixels* foram atribuídos a essa classe com segurança, ou seja, a rede conseguiu discriminar a presença dessa macrófita com relativa coerência.

A Figura 4.19 apresenta o grau de associação dos *pixels* com a classe “Macrófita2”.

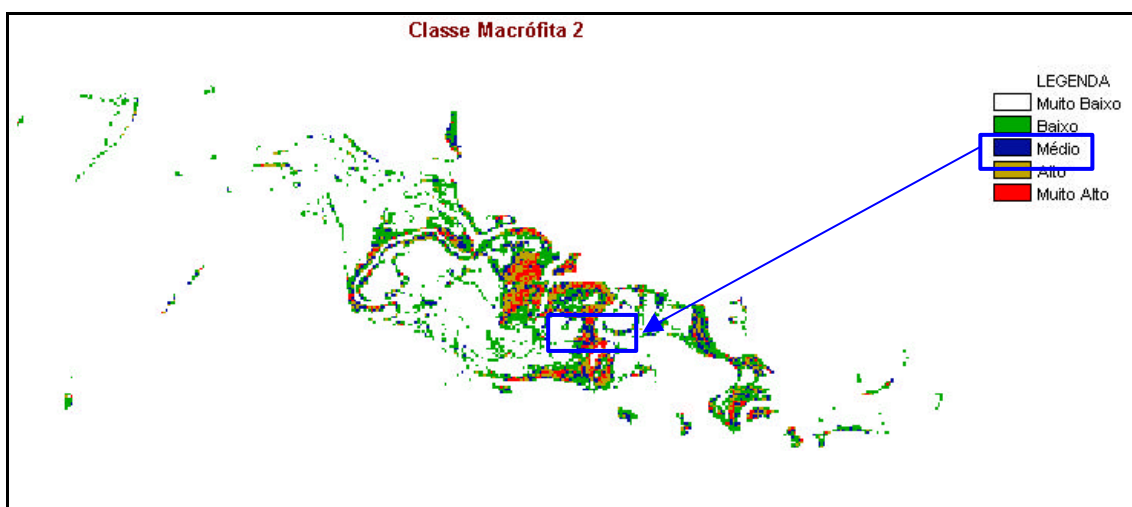


FIGURA 4.19 – Grau de Associação dos *pixels* com a classe “Macrófita2”.

A mesma análise da Figura 4.18 pode ser feita para a Figura 4.19, referente à classe “macrófita2”. Nessa figura, os *pixels* das regiões representadas por “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” que indica pouca ambigüidade existente entre essas duas classes de saída (“macrófita1” e “macrófita2”).

De certa forma tem-se que as classes “macrófitas1” e “macrófitas2” foram facilmente discriminadas, não apresentando praticamente nenhuma ambigüidade entre elas. Embora ocorra um pequeno grau de confusão pode-se afirmar que a rede treinada para essa área de treinamento conseguiu discriminar satisfatoriamente essas variações de plantas aquáticas, pois os resultados mostrados indicam que a classe “macrófita1” não apresenta grande confusão com a classe “macrófita2”.

A Figura 4.20 ilustra o plano de informação “fundo”, no qual os *pixels* excluídos do reservatório apresentam um alto grau de associação indicado no atributo “Muito Alto” para o plano de informação gerado para a classe em questão.

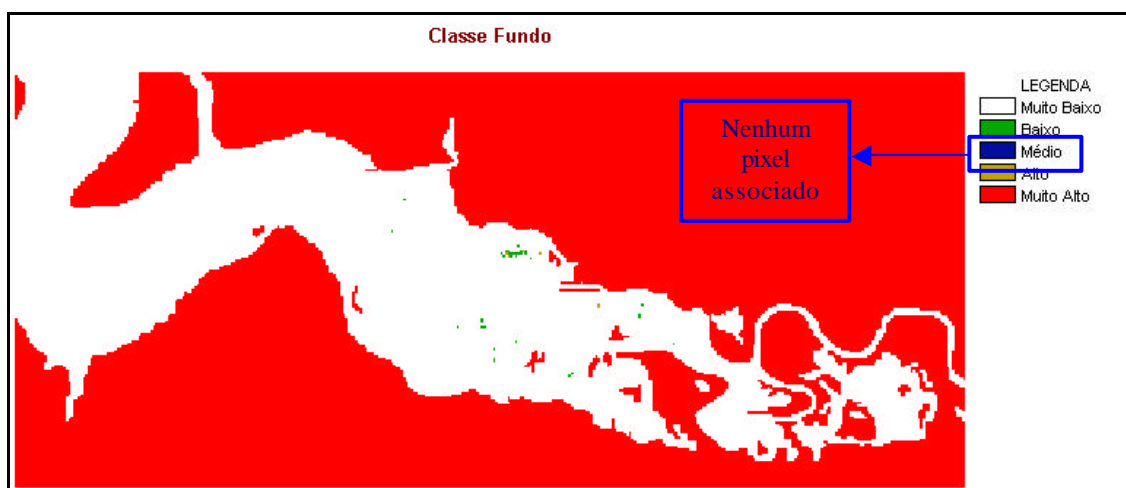


FIGURA 4.20 – Grau de Associação dos *pixels* com a classe “Fundo”.

A partir da geração dessas imagens individuais, foi realizada a tabulação cruzada dos planos de informação: água (“água1” com “água2”) e macrófitas (“macrófita1” com “macrófita2”), a fim de buscar uma melhor representação da ambigüidade entre duas classes de saída que indicam maior possibilidade de confusão.

A tabulação cruzada desses planos de informação foi realizada no IDRISI e as imagens ilustradas na Figuras 4.21 e 4.22 são os resultados dessa operação.

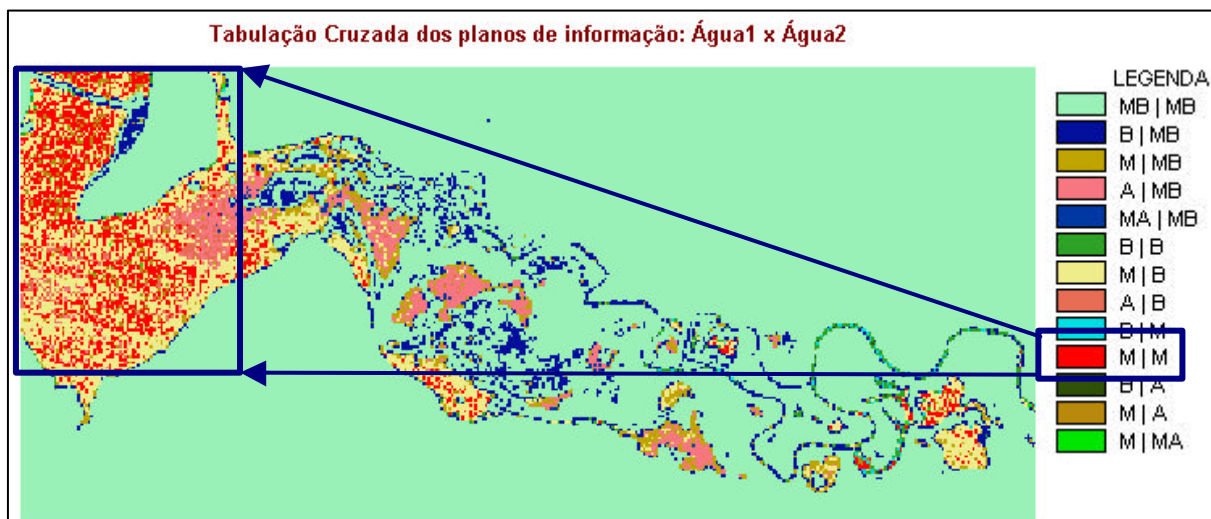


FIGURA 4.21 – Imagem resultante da tabulação cruzada entre os planos de informação “Água1” e “Água2”.

Através da tabulação cruzada entre os planos de informação “água1” e “água2” ilustrados na Figura 4.21 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 mostra 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”, “BxM” e “MxB” indicam a presença da ambigüidade, porém em menor grau, enquanto que os índice “MBxMB”, “BxB”, “AxA” e “MAxMA” mostram um nível insignificante de ambigüidade entre as classes, por apresentarem baixo ou alto grau de associação entre essas classes. Como se pode perceber, os índices “MAxMA” e “AxA” não foram identificados através da tabulação cruzada desses dois planos de informação, o que pode também ser constatado na Tabela 4.10.

Tabela 4.10 - Proporção de *Pixels* atribuídos às classes: “água1” (colunas) com “água2” (linhas), com mesmo grau de associação.

Água1/Água2	MB	B	M	A	MA	Total
MB	0,7948	0,0396	0,0199	0,0188	0,0009	0,8740
B	0,0000	0,0057	0,0680	0,0068	0,0000	0,0805
M	0,0000	0,0013	0,0373	0,0000	0,0000	0,0386
A	0,0000	0,0002	0,0066	0,0000	0,0000	0,0068
MA	0,0000	0,0000	0,0002	0,0000	0,0000	0,0002
Total	0,7948	0,0467	0,1320	0,0256	0,0009	1,0000

Coeficiente de Concordância *Kappa* Global: 0,4525

Na Tabela 4.10 é apresentada a proporção do número de *pixels* associados às classes, como pode ser verificado em “MBxMB” que apresenta 79% dos *pixels* pertencentes a essas duas imagens, para “BxB” com 0,5%, “MxM” com 3%, enquanto que para os índices “AxA” e “MAxMA” nenhum *pixel* foi associado.

Uma outra maneira de verificar a ambigüidade entre classes é através do grau de concordância (*Kappa* Global) obtido mediante a adoção de um dos planos de informação como referência para a realização da comparação entre as classes produzidas. Neste caso, o coeficiente *Kappa* de concordância global indica que 45% dos *pixels* analisados apresentaram ambigüidade entre as classes de saída.

A Figura 4.22 ilustra a tabulação cruzada entre os tipos de macrófitas (“macrófita1” e “macrófita2”).

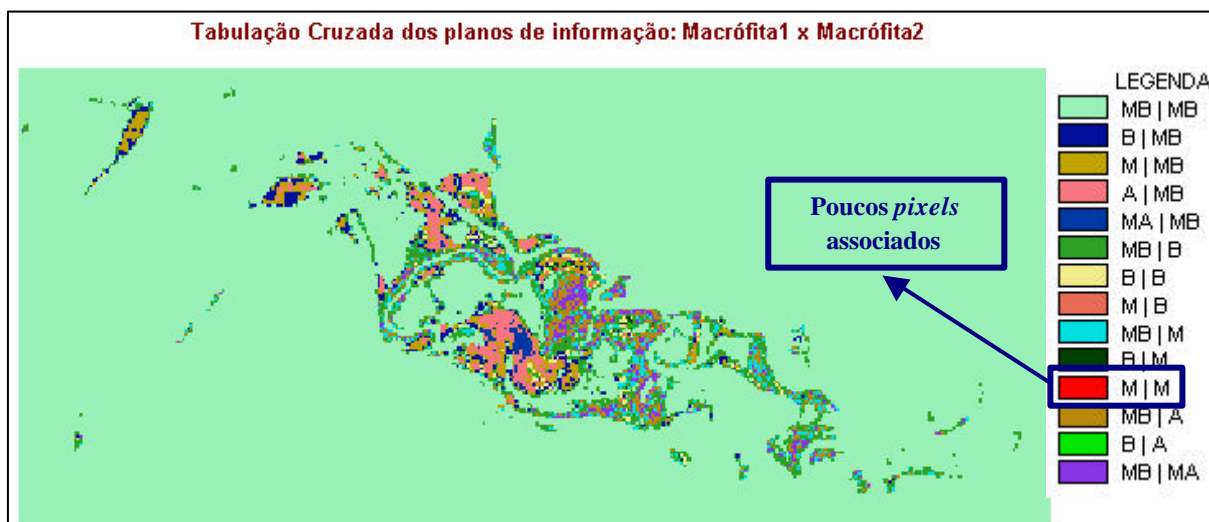


FIGURA 4.22 – Imagem resultante da tabulação cruzada entre os planos de informação “Macrófita1” e “Macrófita2”.

Na análise da Figura 4.22 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”, “BxB” e “BxM” indiquem a presença de alguma ambigüidade entre as classes associadas, enquanto que o índice (“MBxMB”), indica a não ambigüidade entre as classes, por apresentar o baixo grau de associação entre essas classes. Os índices “MAxMA” e “AxA” também não foram representados através da tabulação cruzada desses dois planos de informação. Essas análises podem ser visualizadas na Tabela 4.11.

Tabela 4.11- Proporção de *Pixels* atribuídos às classes: “macrófita1” (colunas) com “macrófitas2” (linhas), com mesmo grau de associação.

Água1/Água2	MB	B	M	A	MA	Total
MB	0,9081	0,0090	0,0098	0,0088	0,0015	0,9372
B	0,0297	0,0030	0,0009	0,0000	0,0000	0,0336
M	0,0108	0,0004	0,0000	0,0000	0,0000	0,0113
A	0,0107	0,0001	0,0000	0,0000	0,0000	0,0108
MA	0,0071	0,0000	0,0000	0,0000	0,0000	0,0071
Total	0,9664	0,0126	0,0107	0,0088	0,0015	1,0000

Coeficiente de Concordancia Kappa Global: 0,0525

Na Tabela 4.11, resultante da tabulação cruzada das classes “macrófita1” e “macrófita2”, verifica-se a ausência das categorias: “BxA”, “BxMA”, “MxM”, “MxA”, “MxMA”, “AxM”, “AxA”, “AxMA”, “MAxB”, “MAxM”, “MAxA” e “MAxMA” “BxB”. Uma análise importante a ser destacada é que o índice “MxM” não se apresenta nessa imagem, indicando que pode haver ambigüidade entre as classes, mas não é tão evidente. Assim, pode-se afirmar que nessa imagem ocorre pouca presença de classes mistas (pouca ambigüidade) como já havia sido citado anteriormente.

O coeficiente de concordância *Kappa* global indicou que 5,25% dos *pixels* analisados apresentaram ambigüidade entre as classes de saída “macrófita1” e “macrófita2”. O pequeno grau de concordância obtido na tabulação cruzada das duas ocorrências de macrófitas mostra que há pouca ambigüidade entre elas. Cabe salientar que o coeficiente *Kappa* ressaltou o que já havia sido verificado em análises anteriores, ou seja, a pouca presença de ambigüidade entre as duas variações de plantas aquáticas emersas mapeadas.

Também como já foi especificada, a não realização dessas análises aos outros reservatórios em estudo deve-se ao fato de que a ocorrência de plantas aquáticas é proveniente do desprendimento de seu local de origem, no reservatório de Barra Bonita e sendo assim, elas apresentariam-se misturadas e de difícil identificação.

## 5 CONCLUSÕES E CONSIDERAÇÕES FINAIS

A aplicação de Redes Neurais Artificiais na classificação da água e macrófitas aquáticas emersas em grandes reservatórios ao longo do rio Tietê, utilizando imagens-fração derivadas do modelo de mistura como dados de entrada, apresentou resultados satisfatórios, principalmente para o reservatório de Barra Bonita, para o qual a rede foi treinada a partir das amostras representativas desse reservatório.

A questão de se considerar o fenômeno de mistura espectral, inerente aos dados de menor resolução espacial, determinou a geração de imagens-fração de “água”, “solo” e “vegetação” a partir das bandas espectrais ETM+/Landsat, onde o número de bandas originais foi reduzido para o número de componentes do modelo de mistura. Os resultados obtidos indicam que as imagens-fração resultantes da análise de mistura espectral permitiram uma boa separação espectral de duas ocorrências distintas de macrófitas emersas, mais especificamente, a componente vegetação, que parece ter maior contribuição na discriminação das classes de vegetação aquática. A utilização das imagens-fração “água”, “solo” e “vegetação” como dados de entrada para a classificação pela rede neural considerou o pressuposto de que essas componentes “puras” representam melhor as classes de interesse, auxiliando assim o reconhecimento das classes de saída.

Pelas análises realizadas para o reservatório de Barra Bonita, percebe-se que as classes “macrófita1” e “macrófita2” apresentaram-se melhor discriminadas, enquanto que as classes “água1” e “água2” apresentaram maior confusão no processo de classificação.

A classificação da imagem de Barra Bonita apresentou bons resultados, visto que o treinamento da arquitetura de rede neural foi realizado a partir de amostras coletadas nesse reservatório. A aplicação dessa arquitetura treinada aos demais reservatórios apresentou, também, resultados satisfatórios, embora a rede não tenha identificado todas as classes de saída pré-estabelecidas. No caso dos reservatórios de Bariri, Ibitinga, Promissão e

Nova Avanhandava, foram discriminadas três classes, sendo que a não separação da classe “macrófita1” pode estar relacionada com a mistura de constituintes, fato que ocorre quando massas de plantas aquáticas se despreendem de seu local de origem e se deslocam ao longo do rio.

Devido a algumas dificuldades ocorridas na realização dessa dissertação, como limitação de *hardware* ocasionando um alto tempo computacional no treinamento da rede, e pela falta de memória virtual do microcomputador utilizado no processo de classificação a partir do simulador de redes neurais artificiais SNNS, houve a necessidade de reamostrar o tamanho dos *pixels* das imagens correspondentes aos reservatórios de Barra Bonita (imagem inteira), Promissão e Nova Avanhandava, mas, apesar da redução na resolução espacial dessas imagens, a classificação apresentou bons resultados, tendo sido identificadas as mesmas classes de saída dos demais reservatórios ao longo do rio Tietê que não necessitaram ser reamostradas.

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, quando da geração da imagem classificada pela rede neural. A classificação gerada para a área de treinamento de Barra Bonita, 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.

Para a verificação da ambigüidade foi adotado um procedimento de tabulação cruzada, contendo graus de associação dos *pixels* à cada classe, pois apesar do arquivo de saída da rede neural fornecer os valores de ativação referente a cada classe de

saída, esses valores de ativação não atendiam às propriedades fundamentais necessárias para a aplicação de uma abordagem *fuzzy*, visto que o somatório dos valores de pertinência das classes, para um dado *pixel* não resultaram no valor 1 o que era restrição importante para a aplicação do modelo *fuzzy*.

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 às variações de macrófitas mapeadas apresentaram-se espectralmente separáveis na imagem, o que também pôde ser verificado através do coeficiente de concordância *Kappa*.

Assim, a partir da análise da ambigüidade entre as classes, pode-se considerar que o programa *snns-pbm* modificado pode ser uma alternativa na avaliação de classes espectralmente misturadas.

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 do reservatório de Barra Bonita, 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 Redes Neurais Artificiais na classificação supervisionada da água e macrófitas aquáticas emersas em grandes reservatórios mostrou-se uma abordagem promissora para a detecção e monitoramento destas plantas aquáticas nestes ambientes.

Tendo em vista os resultados apresentados, considera-se que as imagens orbitais de Sensoriamento Remoto constituem-se de uma fonte de dados úteis para representar espacialmente e fornecer informações importantes para a análise de grandes reservatórios. O

uso das Redes Neurais Artificiais permitiu avaliar a dispersão espacial das plantas aquáticas emersas presentes na área de estudo do reservatório de Barra Bonita, e, portanto, o procedimento metodológico adotado mostrou-se adequado para definir espacialmente a ocorrência de plantas aquáticas em grandes reservatórios.

Como considerações finais sobre a abordagem envolvendo técnicas de PDI e Sensoriamento Remoto, no processo de classificação por Redes Neurais Artificiais, pode-se dizer que o uso dessas metodologias mostrou seu potencial em discriminar dados da superfície terrestre, pois produziu bons resultados, respondendo as expectativas esperadas.

Com relação ao uso do simulador SNNS, apesar de ter sido utilizado em ambiente LINUX, este apresentou flexibilidade na criação e na representação dos dados apresentados às redes neurais. No entanto, como o uso de redes neurais trabalha com conexões em paralelo seria necessário o uso de um microcomputador com maior capacidade de processamento.

Recomenda-se em trabalhos futuros, que outras redes possam ser testadas com diferentes arquiteturas e que uma abordagem *fuzzy* possa vir a ser aplicada visando uma análise mais aprofundada da ambigüidade das classes de saída, para isso é necessário modelar os valores e ativação de saída de modo que as propriedades fundamentais para utilização dessa abordagem possam ser atendidas.

Uma outra recomendação seria o uso de imagens orbitais com melhor resolução, visando obter informações mais precisas sobre a identificação dos tipos de macrófitas aquáticas existentes nesses reservatórios.

## REFERÊNCIAS BIBLIOGRÁFICAS

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, 2002.

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 Agronômicas, Universidade Estadual Paulista “Julio Mesquita Filho”, Botucatu.

COSTA, P.T.B. Uma análise do consumo de energia em transportes nas cidades portuguesas utilizando redes neurais artificiais. 2003. 133 f. Dissertação (Mestrado em Engenharia Municipal) – Escola de Engenharia, Universidade do Minho, Rio de Janeiro.

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, 486 p.

EASTMAN, J.R. Idrisi for windows – user’s guide, version 2.0. Worcester, Clark Labs for Cartographic Technology and Geographic Analysis, Clark University, 1998.

ENGESAT. Site Oficial da Engesat: Imagens de Satélites. Disponível em: <<http://www.engesat.com.br>> Acesso em: julho, 2002.

FLORENZANO, T.C. Imagens de Satélite para Estudos Ambientais. e.5. São Paulo. Inpe. 2002. 97 p.

GALO, M. L. B. T. Aplicação de redes neurais artificiais na classificação de dados de sensoriamento remoto: Relatório de projeto de pesquisa referente ao triênio 29/07/94 a 28/07/97. Presidente Prudente, FCT/ Unesp/Digitado. 1997.

\_\_\_\_\_. 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.* Uso do Sensoriamento Remoto Orbital no Monitoramento da Dispersão de Macrófitas nos Reservatórios do Complexo Tiete. Revista Plantas Daninhas, Viçosa, v:20, Edição Especial, 2002a, p. 7-20.

\_\_\_\_\_ *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, 2002b, p.219-247.

GONZALEZ, R. C.; WOODS, R. E. Processamento Digital de Imagens. e. 2. Edgard Blücher, 2000. 717 p.

HAYKIN, S. Neural Networks: A Comprehensive Foundation. Macmillan College Publishing Company, 1994. p. 1-88.

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.

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

MACRÓFITAS. Site oficial de Macrófitas. Disponível em < [www.macrófitas.com.br](http://www.macrófitas.com.br)>. Acesso em: abril, 2003.

MEDEIROS, J. S. Banco de Dados Geográficos e Redes Neurais Artificiais: Tecnologia de Apoio à Gestão do Território, 1999, 221 f. Tese (Doutorado em Geografia Física) – Faculdade Filosofia, Letras e Ciências Humanas, Universidade de São Paulo, São Paulo.

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.

\_\_\_\_\_; SHIMABUKURO, Y.E. Spectral mixture analysis of inland tropical waters. Revista International Journal of Remote Sensing, v.15, n.6, p. 1351-56. 1994.

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.

RUMELHART, D. *et al.* Learning internal representations by error propagation parallel distributed processing: explorations in microstructure of cognition, 1: foundations. MIT Press, Cambridge, Massachusetts, 1986. p.318-362.

SCHALKOFF, R. Pattern Recognition: Statistical, Structural and Neural Approachs. Canadá, John Wiley & Sons, 1992.

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.

SPRING. Site oficial do INPE – Instituto Nacional de Pesquisas Espaciais. Disponível em: <[www.dpi.inpe.br/spring](http://www.dpi.inpe.br/spring)>. Manual do SPRING 3.6.03. Acesso: janeiro de 2003.

VELINI, E.D. *et al.* Monitoramento dos Problemas com Macrófitas nos Reservatórios da AES. Desenvolvimento de Programas de Manejo Integrado das Principais Especiais 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.

WANG, F. Fuzzy supervised classification of remote sensing images. IEE Transactions on Geoscience and Remote Sensing. v.28, n.2, 1990. p. 194-2001.

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.

## **BIBLIOGRAFIA CONSULTADA**

ANTUNES. A. F. B.; LINGNAU C. In: Uso de Índices de acurácia para avaliação de mapas temáticos obtidos por meio de classificação digital. Anais GIS BRASIL, 2001, Curitiba.

ANTUNES. A. F. B.; LINGNAU C. Classificação Digital de imagens de alta resolução. Anais GIS BRASI, 2001, Curitiba.

BECERRA, J. A. B.; BITENCOURT, M. D. A In: Classificação contínua (Fuzzy) no mapeamento temático de áreas de cerrado. SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., 2003, Belo Horizonte. Anais XI SBSR, 2003. p. 2663-2670.

BOTELHO, M. F.; CENTENO, J. S. In: A influência da alternância entre classes e amostras na entrada da rede neural na classificação de imagem digital. Anais COLÓQUIO BRASILEIRO DE CIÊNCIAS GEODÉSICAS, 3., 2003, Curitiba.

BROWN, D. G. Classification and boundary vagueness in mapping presettlement forest types. Internation Journal of Geographical Information Science, 1998, p. 105-129.

FOODY, G. M. Relating the Land-Cover Composition of Mixed *Pixels* to Artificial Neural Network Classification Output. Photogrammetric Engineering & Remote Sensing - PE&RS, v. 62, n. 5, 1996, p. 491 - 498.

FOODY, G. M.; BOYD, D. S. Detection of partial cover change associated with the migration of inter-class transitional zones. International Journal of Remote Sensing, v. 20, n. 14, 1999, p. 2723 - 2740.

GRACIANI, S. D.; NOVO, E. M. L. M. Determinação da cobertura de macrófitas aquáticas em reservatórios tropicais. Anais XI SBSR, 11, 2003, INPE, P. 2509 – 2516.

LILLESAND, T. M.; KIEFER, R. W. Remote Sensing and Image Interpretation. New York, Jonh Wiley & Sons. 2 ed., 1987.

RAMIRES, M. C. V. *et al*, Aplicação de Redes Neurais Artificiais e Transformada de Ondeletas para Estimativas de Precipitação usando imagens do satélite GOES-8 : Resultados Preliminares. Proceedings of the IV Brazilian Conference on Neural Networks - IV Congresso Brasileiro de Redes Neurais, ITA, São José dos Campos, 1999, p. 252-256.

TIMOTHY, A. W.; SHANK, M. An evaluation of the potential for fuzzy classification of multispectral data using artificial neural network. *Photogrammetric Engineering & Remote Sensing - PE&RS*, v. 63, n. 11, 1997.