

MAPEAMENTO DAS INFESTAÇÕES POR PLANTAS AQUÁTICAS EM RESERVATÓRIOS UTILIZANDO IMAGENS MULTIESCALA E REDES NEURAS ARTIFICIAIS

Mapping of the aquatic plants infestation in reservoirs using multiscale image and artificial neural networks

Narjara Carvalho da Cruz¹
Maria de Lourdes Bueno Trindade Galo²

Universidade Estadual Paulista – UNESP
Faculdade de Ciências e Tecnologia - FCT
¹Programa de Pós-Graduação em Ciências Cartográficas
narjaracruz@yahoo.com.br

²Departamento de Cartografia
Rua Roberto Simonsen , 305 – CEP 19060-900, Presidente Pudente, SP, Brasil
mlourdes@prudente.unesp.br

RESUMO

Nos últimos anos, infestações por plantas aquáticas em reservatórios 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. Esse tipo de ocorrência, assim como a presença algumas substâncias, provocam mudanças na radiancia da água registrada por sensores orbitais, de modo que, técnicas de processamento e análise de dados de sensoriamento remoto podem se constituir em uma fonte complementar de dados e fornecer informações relacionadas ao grau de infestação de reservatórios. Nesse contexto, o presente trabalho teve como objetivo verificar a influência da resolução espacial de imagens multiespectrais na detecção e mapeamento de áreas infestadas por plantas aquáticas emersas em um reservatório de pequeno porte, através de utilização de procedimentos de análise multiescala e classificação supervisionada usando redes neurais artificiais. Para isso foram utilizadas imagens IKONOS multiespectrais do reservatório de Salto Grande localizado em Americana- SP. Inicialmente, foi gerada uma imagem multiescala, resultando em imagens de 8, 16 e 32 metros de resolução espacial. Na classificação das imagens, utilizando Redes Neurais Artificiais, os dados de entrada constituíram-se de cenas multiespectrais IKONOS, imagem de textura, e uma imagem índice de vegetação, resultando em mapas temáticos representando variações espectrais da água e áreas de infestação por plantas aquáticas, nos quatro níveis de resolução espacial. Além disso, foi feita uma análise das imagens classificadas através de uma tabulação cruzada, o que permitiu comparar os resultados obtidos nos 4 níveis multiescala. Como resultado ressalta-se que os mapas temáticos produzidos foram representativos nos 4 níveis de resolução espacial. O procedimento metodológico adotado mostrou-se adequado para o mapeamento das variações espectrais da água e detecção das infestações por plantas aquáticas, nos vários níveis de resolução da imagem. A classificação pela rede neural, com os parâmetros definidos para a imagem original e aplicados no treinamento de uma arquitetura adotada para os demais níveis de resolução, foi satisfatória.

Palavras chaves: Análise Multiescala; Redes Neurais Artificiais; Mapeamento de Plantas Aquáticas em Reservatórios; Sensoriamento Remoto.

ABSTRACT

In past few years, infestations of aquatic plants in reservoirs have been studied as an effect of the environmental unbalance caused by pollution and damming of rivers. The excessive amount of plants, deriving from this unbalance, makes navigation and the production of electricity difficult. This kind of occurrence, as well as the appearance of some substances in the water, cause changes in the water radiance detected by satellite sensors. Thus, processing techniques

of remote sensing and data analysis may be used as a complementary data source to give information related to the degree of infestation of these plants in reservoirs. So, this research aimed at verifying the influence of the spatial resolution of multispectral images in the detection and mapping of areas infested by aquatic plants in a small reservoir, using multiscale analysis procedures and supervised classification by artificial neural networks. Multispectral images IKONOS of the Salto Grande reservoir, in the city of Americana-SP were used. At first, a multiscale image was generated, resulting in images of 8, 16 and 32 meters of spatial resolution. In the classification of these images, the input data for artificial neural networks was constituted of multispectral images IKONOS, texture data, and a vegetation index image and allowed represent the spectral variations of the water body and infested areas of aquatic plants in the various levels of spatial resolution. Furthermore, an analysis was made comparing classified multiscale images by using cross tabulation, which permits comparing the results obtained in the multiscale levels. As result is pointed out that the thematic maps were representative for the 4 levels of spatial resolution. The method used was adequate to map the spectral variation of the water body and to detect infested areas of aquatic plants in the various levels of resolution of the image. The classification by neural network using parameters defined for the original image and applied in the training of the scheme adopted for the different resolution levels was satisfactory.

Keywords: Multiscale Analysis; Artificial Neural Networks; Mapping of Aquatic Plants in Reservoirs; Remote Sensing.

1. INTRODUÇÃO

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

Nesse contexto, o manejo das plantas aquáticas tornou-se objeto de estudos nos últimos anos, devido à disseminação de áreas infestadas e aos prejuízos provocados por esse tipo de vegetação em reservatórios de usinas hidrelétricas. Nesse último caso, o controle dessas infestações exige constante manutenção de grades de tomada de água das turbinas, o que muitas vezes interrompe a geração de energia. Devido a esses problemas e ao alto custo do controle mecânico, várias investigações vêm sendo realizadas com o intuito de otimizar o processo, ou mesmo encontrar alternativas para um possível manejo.

O Sensoriamento Remoto devido a sua capacidade de registrar mudanças na radiação da água partir das substâncias presentes, ou pigmentos fotossintetizantes nas plantas, pode se constituir em uma ferramenta útil para monitorar a ocorrência de plantas aquáticas, avaliar a evolução das comunidades e subsidiar estimativas do potencial atual e futuro de danos decorrentes do aumento destas populações no meio ambiente. Assim, a utilização de metodologias que incorporem uma representação da distribuição

espacial das plantas aquáticas, desenvolvidas a partir de procedimentos de classificação de imagens de sensoriamento remoto, pode constituir em um primeiro passo no sentido de fornecer informações relacionadas ao grau de infestação dessas plantas em reservatórios.

Por outro lado com a disponibilidade de imagens multiespectrais de alta resolução espacial, espera-se que o desempenho dos classificadores possa ser melhorado, mesmo que para muitas aplicações, principalmente em estudos de água, um considerável aumento na resolução espacial não se configure em um também aumento na separabilidade entre as classes que representam os fenômenos de interesse. No entanto, independente da aplicação, é importante avaliar o nível de detalhamento necessário para detectar o fenômeno de interesse, uma vez que o custo da aquisição de imagens de alta resolução é elevado. A proposta de avaliar imagens multiescala para fins de classificação de plantas aquáticas vem de encontro a esse propósito.

No que se refere à classificação de imagens, a utilização de Redes Neurais Artificiais (RNA) tem se apresentado como uma alternativa vantajosa em relação aos classificadores supervisionados baseados em conceitos estatísticos, uma vez que para a sua aplicação 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.

Nesse contexto, o objetivo do presente trabalho é verificar a influência da resolução espacial de imagens multiespectrais na detecção e mapeamento de áreas infestadas por plantas aquáticas emersas em um reservatório de pequeno porte, através de utilização de procedimentos de análise multiescala e classificação supervisionada, usando redes neurais artificiais. Para essa investigação foi selecionado como caso de estudo o reservatório de Salto Grande, localizado em Americana-SP no qual está caracterizado no item 3), para o qual foram delineados os seguintes objetivos específicos: (a) gerar imagens com diferentes níveis de resolução espacial, a partir de uma imagem IKONOS; (b) aplicar

procedimentos de classificação de imagens multiespectrais utilizando um modelo de rede neural artificial, aplicado nos diversos níveis de resolução da imagem multiescala; (c) analisar os resultados da classificação da imagem multiescala, a fim de verificar até que nível de resolução espacial um classificador, neste caso uma rede neural artificial, consegue distinguir as infestações de plantas aquáticas em reservatórios.

2. CONSIDERAÇÕES SOBRE A ABORDAGEM ADOTADA

2.1. Sensoriamento remoto da água

Diferente do solo e da vegetação, a maior parte do fluxo radiante incidente sobre a água não é refletido, mas absorvido ou transmitido. MOREIRA (2001) destaca que a água no estado líquido absorve quase toda a radiação eletromagnética abaixo de 380 nm e acima de 700 nm e que, mesmo nessa faixa intermediária, a reflectância da água é relativamente pequena, ultrapassando pouco mais de 5%. Especificamente para a água pura, a reflectância no espectro visível decresce desde cerca de 5% no azul até menos de 1% no infravermelho próximo (NOVO, 1989). Desse modo, a forte absorção da radiação do infravermelho próximo e médio pela água resulta em um forte contraste entre a água e os limites de terra.

NOVO et al. (1994) argumentam que os componentes presentes na 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 uma redução na quantidade dessa energia e a cor da água é percebida como verde. A matéria orgânica dissolvida é também responsável por uma mudança no coeficiente de absorção da água, ocorrendo um máximo na região do azul e decrescendo com um aumento no comprimento de onda. Como consequência, a cor da água muda do azul (água limpa) e verde (água rica em fitoplâncton) para o amarelo, conforme o aumento da quantidade dos componentes orgânicos dissolvidos.

Da mesma maneira que para os diferentes alvos da superfície terrestre, variações na resposta espectral da água podem ser registradas em imagens de sensoriamento remoto, adquiridas por sensores instalados em plataformas terrestres, aéreas ou orbitais. Essas imagens são formadas numericamente, por uma matriz bidimensional, na qual, linhas e colunas definem as coordenadas espaciais do pixel, caracterizado também por um atributo que corresponde ao valor radiométrico registrado pelo sensor. No caso de imagens multiespectrais, esse atributo é representado por um vetor de tantas dimensões quantas forem as bandas espectrais consideradas na aquisição dos dados (RICHARDS, 1986).

2.2 Representação multiescala de uma imagem

A representação multiescala de uma imagem está ligada ao conceito de se ter várias medidas de um objeto, realizadas a partir de diferentes escalas. A razão técnica para se representar uma imagem em múltiplas escalas reflete a necessidade de usar um procedimento de suavização como um passo de pré-processamento ou um meio de supressão de ruídos (LINDEBERGE, 1994).

O conceito de escala cartográfica é inerente à observação de qualquer objeto físico e está intimamente ligado ao conceito de resolução (ou detalhe). A resolução pode também ser entendida como escala do fenômeno, e apresenta-se como o inverso da escala cartográfica.

Na literatura, existe um grande número de meios para construir imagens para uma representação multiescala, porém neste trabalho foi tratada especificamente a representação por pirâmides de imagens. Esse procedimento foi adotado por se tratar de um método simples de geração de imagens e também pelo fato dessa estrutura, além de suavizar a imagem, também a reamostra, fazendo com que, em cada nível de resolução, a imagem fique cada vez menor, assim diminuindo o tempo computacional gasto para o processamento (MIKHAIL et al, 2001).

As imagens geradas por estruturas piramidais são geralmente formadas por múltiplos de dois. Assim, uma imagem original de tamanho $2^n \times 2^n$ pixels define representações piramidais sucessivas da imagem com tamanhos de $2^k \times 2^k$, sendo $k = n, n-1, \dots, 0$.

2.3 Classificação e Redes Neurais Artificiais

Classificação é o processo de extração de informação em imagens com a finalidade de reconhecer padrões e objetos homogêneos. A discriminação e posterior identificação desses padrões são possibilitadas pelo fato dos diferentes objetos da superfície terrestre apresentar um comportamento espectral específico, o qual pode ser usado para identificá-los (INPE, 2002).

Para a análise de dados multiespectrais, RICHARDS (1986) destaca dois procedimentos abrangentes de classificação: não-supervisionado e supervisionado. O método supervisionado se constitui na ferramenta analítica essencial usada na extração da informação quantitativa a partir de dados multiespectrais. O processo é dito supervisionado pois implica na interação entre o intérprete humano e o sistema de análise, possibilitando o treinamento do algoritmo de classificação, através de amostras usadas para caracterizar ou estimar parâmetros estatísticos de cada classe. Essas amostras (que correspondem a padrões conhecidos das classes) são normalmente chamadas de padrões de treinamento, sendo que sua totalidade define o conjunto de treinamento (GONZÁLES & WOODS, 2000).

Atualmente, a utilização de redes neurais artificiais tem se apresentado como uma alternativa vantajosa em relação aos classificadores estatísticos, uma vez que nenhuma hipótese prévia sobre a distribuição

dos dados a serem classificados é exigida e face à maior flexibilidade que esses modelos oferecem quanto à entrada de dados para a classificação (ESPINHOSA, 2004).

As redes neurais artificiais são organizadas em camadas que compõem sua topologia ou arquitetura. Podem ser definidas redes neurais de camada simples (*perceptron*), constituídas por um grupo de neurônios arranjados em apenas uma camada ou redes multicamadas, formadas por uma ou mais camadas intermediárias ou pela combinação de várias redes de camadas simples (VENTURIERI & SANTOS, 1998). Assim, a topologia de uma rede refere-se à maneira como os elementos de processamento são organizados, o que afeta o desempenho da rede, uma vez que sua estrutura está intimamente ligada ao algoritmo de aprendizado usado na fase de treinamento.

Segundo GALO (2000), o processo de treinamento de uma rede multicamadas, realizado usualmente por um algoritmo que possibilite a retro-propagação do erro (*backpropagation*), começa com a definição de um conjunto arbitrário de pesos para as conexões da rede e envolve duas fases distintas. Na primeira, um par constituído pelo vetor de entrada associado à respectiva saída desejada é apresentado à primeira camada da 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 uma retro-propagação desse erro a partir da última camada, durante a qual parte do 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.

Após o aprendizado da rede, ela classifica os padrões de interesse usando o conjunto dos pesos ajustados durante a fase de treinamento e calculando, para cada padrão de entrada, os valores de saída associados a cada classe. Geralmente, 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 a qual o padrão será atribuído.

3. MATERIAL E MÉTODO

3.1 Caracterização da área de estudo

O reservatório de Salto Grande localiza-se no município de Americana-SP, está inserido na sub-bacia do rio Atibaia, o qual pertence à bacia hidrográfica do rio Piracicaba. Sua localização geográfica é definida pelas coordenadas 22° 44' de latitude Sul e 47° 15' de longitude Oeste, a uma altitude de 530m. A região se caracteriza pelo clima temperado brando, sem estação seca e com verão suave. A temperatura média anual

varia de 18° a 20° C. Com relação às precipitações, o valor médio para época chuvosa é de 1500mm/ano e para a época seca é de 1300mm/ano.

A barragem localiza-se próxima a foz do rio Atibaia, que por sua vez deságua no rio Jaguari, formando o rio Piracicaba. Quando a Usina Hidroelétrica de Americana entrou em funcionamento em 1949, seu objetivo era gerar cerca de 30 MW/dia de energia elétrica. Com o decorrer dos anos, várias outras atividades foram incorporando-se à represa, como o abastecimento de cidades como Sumaré, irrigação de culturas e recreação, sendo que a Usina Hidroelétrica atualmente está operando também para a regulação da vazão na bacia do rio Piracicaba em épocas de cheia e períodos de estiagem (LEITE, 1998).

Por estar localizado em uma região com elevada densidade demográfica, altamente industrializada e com intensa atividade agrícola, o reservatório possui uma alta concentração de nutrientes, o que provoca o crescimento excessivo de plantas aquáticas. Esse tipo de desequilíbrio dificulta tanto a navegação, como a produção de energia elétrica, pois provoca o entupimento das turbinas geradoras de energia.

Nesse contexto, considera-se que uma abordagem que viabilize a identificação de áreas infestadas e o mapeamento da dispersão espacial de plantas aquáticas, realizados a partir de levantamentos de menor custo (imagens de média resolução espacial), constitua uma contribuição útil para o manejo do reservatório de Salto Grande em particular, assim como para outros reservatórios afetados por problemas dessa natureza.

3.2 Dados multiespectrais e descritivos utilizados

Os dados multiespectrais utilizados referem-se a imagem orbital adquirida pelo sistema sensor IKONOS II (bandas 1, 2, 3 e 4), abrangendo o reservatório de Salto Grande (Americana, SP), adquiridas em junho de 2004. A imagem utilizada foi disponibilizada pela Companhia de Força e Luz do Estado de São Paulo - CPFL. A Figura 1 apresenta a localização da Represa de Salto Grande na cena IKONOS utilizada, em relação à cidade de Americana, SP.

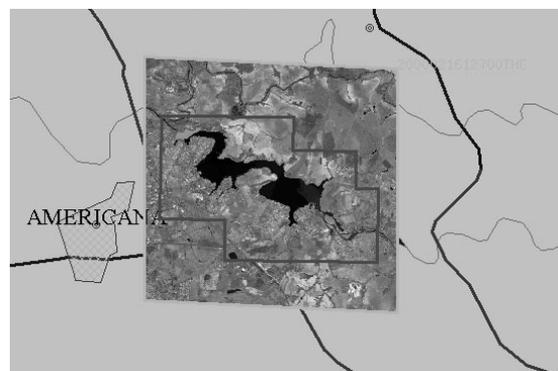


Fig. 1 – Localização do Reservatório de Salto Grande na cena IKONOS, em relação à cidade de Americana, SP.

As imagens multiespectrais do IKONOS têm resolução espacial de 4 metros e são obtidas em quatro bandas espectrais correspondentes aos intervalos de comprimento de onda: 0,45 a 0,52 µm (azul), 0,52 a 0,60 µm (verde), 0,63 a 0,69 µm (vermelho) a 0,76 a 0,90 µm (infravermelho próximo) (MOREIRA, 2001).

Os dados descritivos que possibilitaram a caracterização das classes foram levantados em um trabalho de reconhecimento de campo realizado no reservatório de Salto Grande, na mesma época da tomada da imagem (julho de 2004). Esse levantamento foi necessário para que as classes, as quais foram previamente diferenciadas somente com base nas diferenças espectrais, pudessem ser rotuladas.

Nos processamentos realizados foram utilizados, basicamente três aplicativos para o processamento e análise das imagens: Idrisi, MATLAB e ENVI. Para a reamostragem do tamanho do pixel, foi utilizado um programa computacional específico, desenvolvido em C++.

3.3 Processamento e Análise das Imagens

O fluxograma indicado na Figura 2 sintetiza os procedimentos adotados no presente estudo.

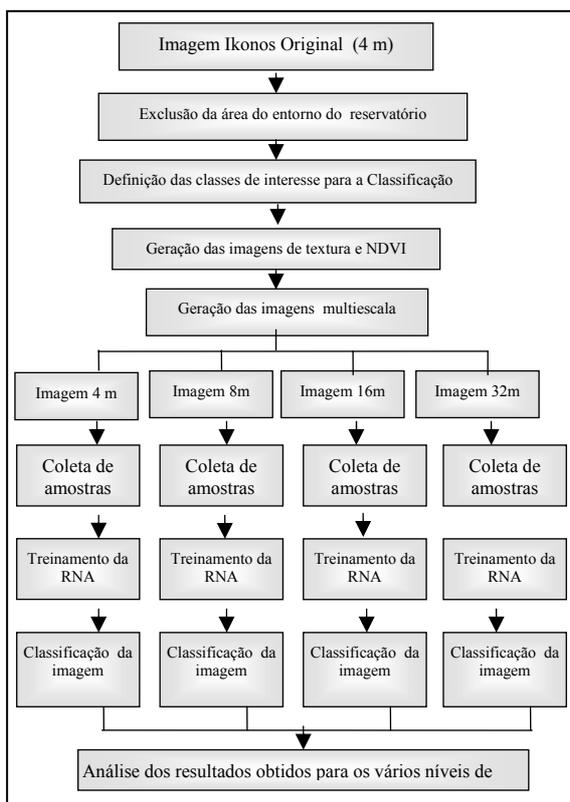


Fig. 2 - Fluxograma das atividades desenvolvidas.

Inicialmente foi excluída a região do entorno da represa, a fim de facilitar a detecção das variações espectrais no corpo d'água, uma vez que muitos alvos do entorno se confundiriam com plantas aquáticas. Numa etapa posterior foram geradas duas imagens derivadas dos dados multiespectrais IKONOS: uma

imagem de textura e uma outra correspondente ao índice de vegetação da diferença normalizada - NDVI (*Normalized Difference Vegetation Index*).

Na geração da imagem de textura, foi usado um operador de contexto que calcula um índice numérico com base na variabilidade espacial observada em uma janela de 3x3 pixels. Esta operação foi aplicada à banda do infravermelho próximo, devido a sua aparente superioridade em representar as variações na vegetação (no caso, plantas aquáticas). A imagem índice de vegetação foi elaborada usando a formulação do NDVI, que é uma combinação das bandas do vermelho e do infravermelho próximo, expressa pela diferença entre os valores de brilho registrados na banda do infravermelho próximo (IVP) pelos da banda do vermelho (VER), normalizado pela soma desses valores. A utilização de índices de vegetação permite aumentar o brilho das áreas vegetadas, facilitando a percepção da distribuição espacial de informações das imagens e tornando-as de fácil interpretação visual e computacional (SHIMABUKURO, 1991).

Em seguida foram produzidas as imagens multiescala, utilizando o procedimento de pirâmide de imagens. A partir da imagem original, foram geradas três imagens derivadas, com resolução espacial sistematicamente reduzida para 8 metros, 16 metros e 32 metros. Para isso, foi utilizado um programa desenvolvido em linguagem C++, que usa um filtro passa baixa para calcular a média de quatro pixels vizinhos, de modo a reamostrar a imagem e diminuir o número de pixels em duas vezes. A Figura 3 mostra como foi feita a reamostragem das imagens.

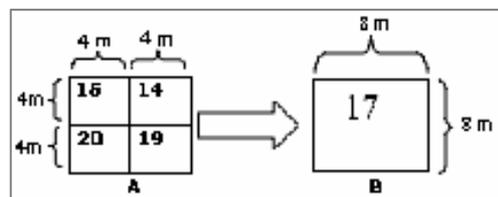


Fig.3 - Geração de um pixel da imagem pela estrutura piramidal.

O conjunto de atividades relacionadas com a classificação das imagens pode ser subdividido em: definição das classes de interesse e coleta das amostras; treinamento da Rede Neural Artificial (RNA) e aplicação de rede treinada às imagens.

3.3.1 Definição das classes de interesse

As classes definidas inicialmente e rotuladas a partir de um levantamento de campo realizado na represa foram: Planta1, Planta2, Água1, Água2 e Água3, as quais são caracterizadas na Tabela 1, em função da cor e padrão que apresentam em uma composição colorida das bandas 2, 3 e 4 do IKONOS e respectiva descrição da classe.

Estabelecidas e caracterizadas as classes de interesse, as áreas representativas de cada classe foram identificadas e demarcadas na cena, o que serviu a dois

propósitos: o primeiro foi avaliar o efeito da reamostragem do tamanho do pixel na geração da imagem multiescala, considerando a possibilidade de discriminar as classes nas quatro bandas espectrais IKONOS, a partir das médias calculadas para cada uma dessas classes. A outra finalidade desse procedimento foi adquirir amostras para o treinamento da rede neural artificial.

TABELA 1 – CLASSES DE INTERESSE.

Classes	Cor (composição colorida)	Padrão na imagem	Descrição
Plantas 1	Coloração avermelhada		População mista de plantas aquáticas, Braquiária e Aguapé, com maior concentração de Aguapé.
Plantas 2	Coloração laranja claro		População mista de plantas aquáticas (Aguapé, Braquiária e Taboa) com maior concentração de Braquiária.
Água 1	Coloração azul escuro		Maior profundidade e menor quantidade de sedimentos em suspensão
Água 2	Coloração azul claro esverdeado		Menor profundidade e maior quantidade de sedimentos em suspensão
Água 3	Coloração azul claro		Excessiva quantidade de sedimentos em suspensão

3.3.2 Treinamento da RNA

Após a definição da arquitetura básica da RNA (planos de entrada e classes de saída) e o número de camadas escondidas, o *software* ENVI, que dispõe de ferramentas para a aplicação de redes neurais artificiais em classificação, solicita a definição de alguns parâmetros para a classificação relacionados com:

- Função de ativação: verifica se um elemento de processamento é ou não ativado por uma entrada específica. Foi usada uma função sigmóide (logística).
- Limiar de contribuição: determina a contribuição do peso em relação ao nível de ativação do nó. O valor adotado para esse parâmetro variou entre 0,7 e 0,9.
- Taxa de Treinamento: especifica a magnitude do ajuste para os pesos. Valores mais altos aceleram o treinamento, porém aumentam o risco de oscilações ou não-convergência no treinamento. O valor usado foi 0,01.
- Taxa de Momento: viabiliza mudanças mais adequadas nos pesos, evitando oscilações quando a taxa de treinamento fixada é alta. Foram testados valores entre 0,1 e 0,3.
- Critério de término de treinamento (baseado no Erro Médio Quadrático - EMQ): indica para qual valor do erro o treinamento deve ser finalizado (máxima

diferença entre o valor esperado e o valor de saída). Foram usados os valores 0,05 e 0,001.

- Número de Camadas Escondidas: para classes que não são linearmente separáveis é necessário introduzir camadas escondidas, cujo número depende da complexidade do conjunto de dados. Foram testadas arquiteturas com 2 e 3 camadas escondidas.

- Número de iterações do treinamento: número de ciclos de treinamento necessários para minimizar o erro desejado.

Devido ao efeito da suavização decorrente da amostragem para a geração da imagem multiescala, foi necessário realizar o treinamento da RNA para cada nível multiescala, porém a arquitetura geral da rede adotada em cada classificação foi identificada a partir de testes realizados com a imagem original. Nas imagens multiescala, o único parâmetro modificado foi o número de iterações, uma vez que uma redução na resolução da imagem implica na necessidade de um maior número de iterações para o treinamento.

Para as imagens de 4 e 8 metros, foram necessárias 1000 iterações para o treinamento da rede, porém as imagens reamostradas para 16 e 32 metros exigiram, respectivamente 2000 e 5000 iterações.

3.3.3 Análise das classificações das imagens multiescala

Através do comportamento da rede neural durante o treinamento é possível avaliar sua adequação à classificação dos dados, de modo que, a partir do monitoramento do erro para cada arquitetura testada, foi selecionada a RNA aplicada na classificação da imagem inteira. Esse procedimento foi repetido para cada nível multiescala (4, 8, 16 e 32 metros).

As imagens multiescala classificadas foram analisadas a partir de uma tabulação cruzada (função disponível no *software* Idrisi) entre a imagem original e cada uma das cenas com resolução espacial reduzida. A tabulação cruzada entre duas imagens permite avaliar se há coincidência espacial na classe atribuída a um dado pixel em relação a dados de referência, usualmente obtidos através de verificação “in loco”. Na presente investigação, a classificação resultante da imagem de resolução espacial original (4 metros) foi adotada como referência e comparada, individualmente, com cada uma das classificações obtidas nos demais níveis de resolução espacial. Nessa comparação foi considerada a coincidência na classe atribuída a um dado pixel, a qual foi avaliada através do Índice de Concordância *Kappa* (também disponível no Idrisi).

Embora não haja unanimidade quanto aos critérios de aceitação dos valores do coeficiente *Kappa* como um indicador da qualidade dos produtos gerados a partir de sensoriamento remoto, MOREIRA (2001), entre outros, apresenta uma associação de intervalos de valores *Kappa* a critérios de concordância espacial entre as classes: de 0 a 0,20 – ruim; de 0,20 a 0,40 – razoável; de 0,40 a 0,60 – bom; 0,60 a 0,80 – muito bom; e de 0,80 a 1,00 – excelente.

4 RESULTADOS E DISCUSSÃO

4.1 Imagem Multiescala

Para avaliar a influência da redução na resolução espacial das imagens na discriminação das classes de interesse, foram elaborados os gráficos apresentados na Figura 4, indicando a média dos valores de brilho, calculada a partir das amostras de cada classe, obtidas para as quatro bandas espectrais IKONOS.

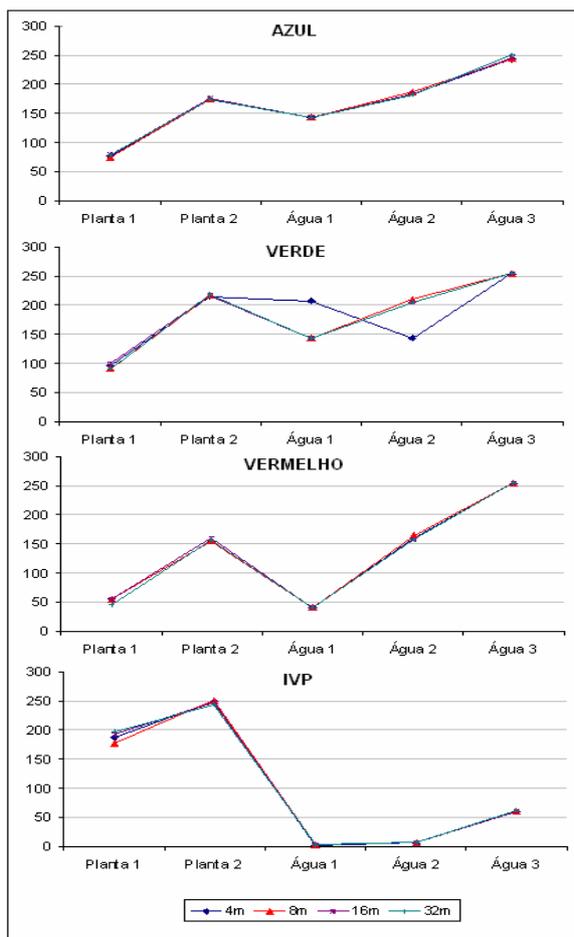


Fig. 4 - Médias dos valores de brilho estimadas a partir dos dados de treinamento das classes para as imagens multiescala, nas quatro bandas espectrais.

Nos gráficos anteriores (Figura 4), a percepção da separabilidade entre as classes está associada à variabilidade das médias estimadas a partir dos dados de treinamento adquiridos para cada classe. Por se tratarem de estimativas feitas com base em amostras tomadas na mesma posição para os diferentes níveis de resolução espacial, pode-se considerar que o comportamento das médias é homogêneo para os diversos níveis multiescala, para uma dada banda espectral, indicando a possibilidade de discriminação entre as cinco classes. A única variação nesse comportamento quase padrão ocorre para as classes Água1 e Água2, na banda do verde, na imagem de resolução original (4 metros de resolução espacial).

4.2 Imagens classificadas pela Rede Neural Artificial

A arquitetura da RNA, definida a partir dos testes realizados com a imagem de resolução espacial original, constitui-se de seis imagens de entrada (banda1, banda2, banda3, banda4, textura e NDVI), duas camadas escondidas e seis classes de saída (Planta1, Planta2, Água1, Água2, Água3 e fundo). Esses testes permitiram também a especificação de parâmetros necessários para que a RNA pudesse diferenciar e classificar adequadamente cada uma das classes.

Os parâmetros selecionados para a imagem original e adotados no treinamento das imagens sucessivas, foram: 0,8 como limiar de treinamento; 0,01 para a taxa de treinamento e 0,2 para a taxa de momento. Os erros de saída (EQMs) minimizados ao término das iterações necessárias para o treinamento das RNAs foram: 0,014; 0,007, 0,017 e 0,016, respectivamente, para as imagens de 4, 8, 16 e 32 metros de resolução espacial.

As cenas classificadas resultantes da aplicação das RNAs treinadas para as imagens de resolução espacial de 4 metros (original), 8, 16 e 32 metros (reamostradas) são apresentadas na Figura 5.

A Figura 5(a) mostra o resultado da classificação da imagem de 4 metros de resolução (original), na qual se observa que a RNA discriminou as classes de interesse, relacionadas tanto a plantas aquáticas quanto a variações espectrais da água. Nesta representação temática percebe-se que a classe Planta1 ocorre principalmente associada à água menos turva (Água1) e mais próxima à barragem. Em pontos intermediários do reservatório, os tipos de plantas aparecem entremeados na imagem classificada, porém na sua seção final passa a predominar Planta2.

Na Figura 5(b), resultante da aplicação da RNA à imagem de 8 metros de resolução espacial, também se percebe a diferenciação entre tipos de planta e água. Entretanto, nesta classificação nota-se diferenças sutis na definição espacial das classes Planta1 e Planta2, principalmente em pontos médios do reservatório onde essas classes apareciam intercaladas. Na diferenciação entre os três tipos de água, a rede neural teve um bom desempenho.

A classificação da imagem com resolução espacial reamostrada para 16 metros é apresentada na Figura 5(c), na qual se percebe nitidamente a predominância da classe Planta1 sobre Planta2. Apesar disso, os tipos de planta e água foram ainda diferenciados nesse nível de resolução, resultando em um mapa temático representando todas as classes de interesse.

A Figura 5(d) mostra a classificação da imagem de 32 metros de resolução espacial. Devido a maior dificuldade em coletar amostras representativas das diversas categorias algumas classes definiram padrões excessivamente misturados, principalmente Planta1 e Planta2. Também houve confusão entre os tipos de água (Água1 e Água2) e, portanto, dificuldade na diferenciação entre os tipos de planta e de água. Devido à

menor resolução espacial da imagem, o mapa temático resultante da classificação mostrou classes de plantas excessivamente generalizadas.

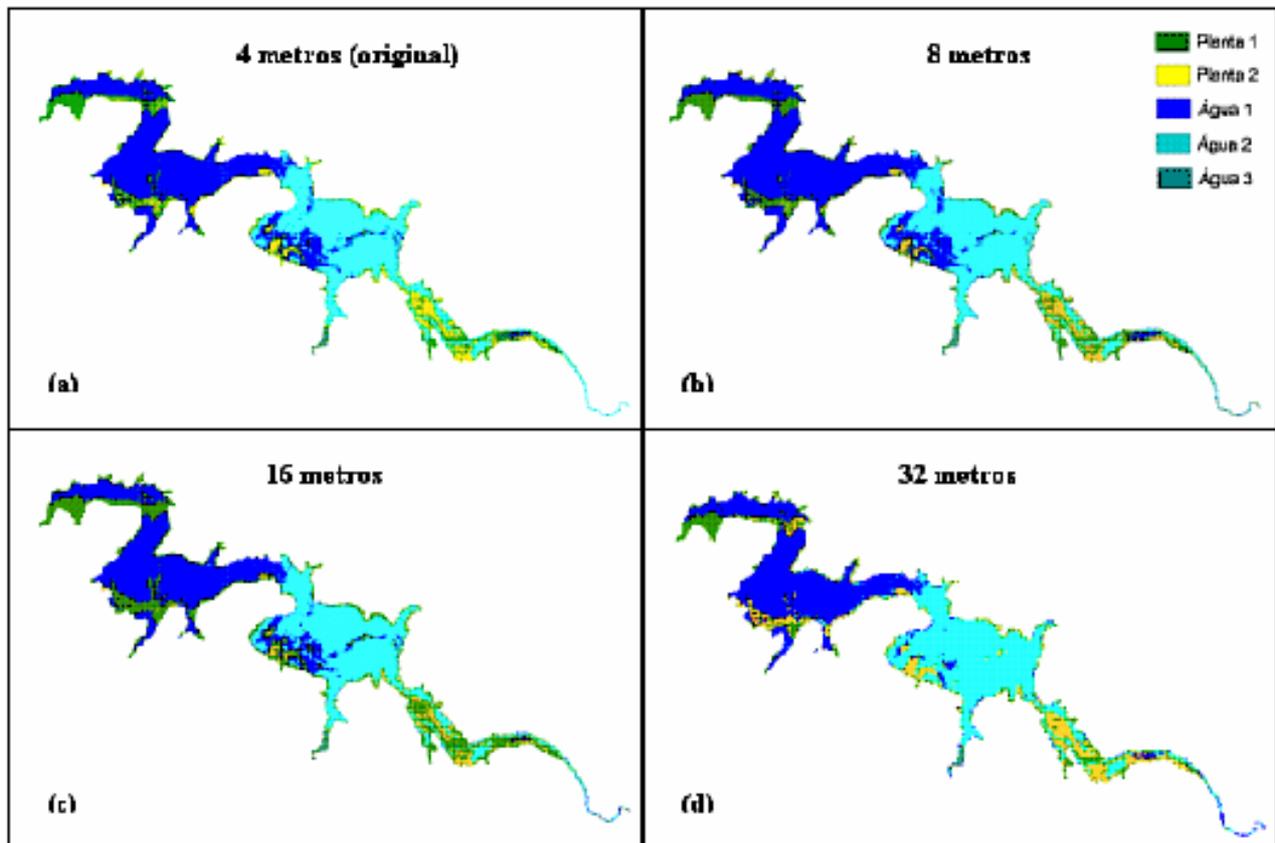


Fig. 5 – Classificações resultantes da aplicação da RNA às imagens de 4 (a) , 8 (b), 16 (c) e 32 (d) metros de resolução espacial.

A fim de se dispor de um indicador quantitativo da representatividade de cada classe nos diversos níveis de resolução espacial apresenta-se, na Tabela 2, os valores percentuais referentes à abrangência de plantas e água no reservatório de Salto Grande.

TABELA 2 – PROPORÇÃO DA OCORRÊNCIA DE CADA CLASSE EM CADA NÍVEL DE RESOLUÇÃO DA IMAGEM.

	4 metros (%)	8 metros (%)	16 metros (%)	32 metros (%)
Planta 1	14,159	15,424	22,281	9,689
Planta 2	9,823	7,274	5,305	13,689
Água 1	38,407	42,156	36,870	34,933
Água 2	36,814	34,618	35,190	40,800
Água 3	0,797	0,528	0,354	0,889
Total	100,000	100,000	100,000	100,000

Os valores mostrados na Tabela 2 indicam as oscilações na ocorrência de cada classe quando a resolução espacial da imagem é reduzida. Essas variações se devem não apenas ao efeito da reamostragem no tamanho do pixel, mas também ao fato da rede neural aplicada a cada nível de resolução ter sido treinada individualmente, definindo uma

capacidade de generalização diferente e dificultando a identificação de um padrão de comportamento para cada classe, ao longo da pirâmide multiescala.

De uma maneira geral, as oscilações nas proporções das classes ocorreram, dentro das classes genéricas, planta e água. Para a imagem de resolução original (4metros) a soma dos percentuais associados às classes Planta1 e Planta2 foi de 23,982%, enquanto que para as resoluções de 8, 16 e 32 metros, essas duas classes totalizaram 22,698%, 27,586% e 23,378%, respectivamente. Dentro dessa classe genérica (Planta) não foi possível identificar um padrão de variação associado à redução na resolução espacial da imagem.

Um comportamento similar ao que ocorre para Plantas pode ser observado para as classes Água1, Água2 e Água3 (Tabela 2).

4.3 Análise das classificações para as imagens multiescala

Para se dispor de um indicador do grau de similaridade entre cada uma das classificações das imagens de menor resolução espacial e aquela resultante da imagem IKONOS original, tomada como referência, foi utilizado o coeficiente *Kappa* para

analisar a concordância na definição das classes de interesse. Nesse sentido, mesmo considerando que as classificações resultaram da aplicação de redes neurais com diferentes pesos entre as conexões, foram realizadas comparações individuais entre as classificações obtidas para as imagens de 4 e 8 metros de resolução espacial; 4 e 16 metros e 4 e 32 metros. As variações nos valores do índice *Kappa*, por classes e global, obtidas com base nas tabulações cruzadas entre a classificação da imagem de referência e cada um dos níveis multiescala, são mostradas na Figura 6.

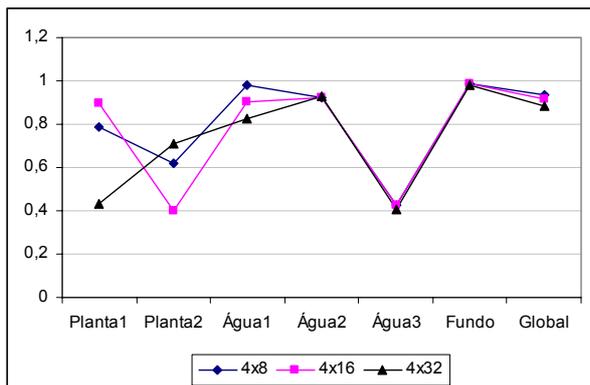


Fig. 6 - Índice *Kappa* resultante tabulações cruzadas entre a imagem de referência e as imagens de menor resolução espacial.

A concordância temática e espacial na representação das classes em relação à classificação de referência (imagem de resolução espacial original) e cada nível multiescala, mostrada na Figura 6 através do Índice de Concordância *Kappa*, indica que as maiores variações em termos de coincidência espacial ocorrem aleatoriamente para as classes Planta1 e Planta2. O fato dessas variações não obedecerem a um padrão perceptível pode ser atribuído tanto ao efeito da amostragem no tamanho do pixel, que tende a suavizar as variações nos dados de entrada para a classificação, bem como à ocorrência de infestações mistas em ambas as classes, homogeneizando as diferenças entre elas.

Por outro lado, o índice *Kappa* para a classe Água1 mostrou que, com o decréscimo na resolução espacial da imagem, a concordância espacial entre os pixels associados a essa classe, também diminuiu, mas não chega a atingir valores inferiores a 0,8. Já a classe Água2 resultou em valores homogêneos de índice *Kappa* para os três menores níveis multiescala, oscilando em torno de 0,92.

A representação da classe Água3 foi a que resultou em menor grau de concordância entre a referência e as demais resoluções (índice *Kappa* em torno de 0,4), talvez decorrente de sua pequena representatividade (em porcentagem de ocorrência) na imagem.

O coeficiente *Kappa* global obtido entre as classificações das imagens de 8, 16 e 32 metros de resolução espacial, em relação à referência, resultou em

valores de 0,9369 (4x8 metros), 0,9189 (4x16 metros) e 0,8808 (4x32 metros). Nesse sentido, o resultado é tido como excelente se for considerado o critério usualmente empregado na análise desse índice, explicitado em Moreira (2001, p.200). Deve-se ressaltar, no entanto, o fato de que a referência adotada nessa comparação é a própria classificação da imagem original. Porém, como se trata da análise de uma classificação multiescala, o uso desse indicador e dessa referência são adequados a essa comparação específica.

5. CONSIDERAÇÕES FINAIS

Para o caso de estudo em questão, os resultados da utilização de uma análise multiescala na discriminação das classes de interesse indicaram que a redução sistemática na resolução espacial das imagens multiespectrais IKONOS não teve influência considerável na detecção de áreas infestadas por plantas aquáticas emersas no reservatório de Salto Grande. Porém, deve-se ressaltar que, por se tratarem de infestações mistas, nem mesmo a imagem de resolução espacial original viabilizou a identificação de focos de infestação caracterizados pela ocorrência simultânea de diferentes tipos de plantas aquáticas.

A aplicação das Redes Neurais Artificiais na classificação dos dados, apesar de demandar um alto tempo de processamento na etapa de treinamento, permite incorporar dados de natureza não espectral que, neste caso, se constituiu da imagem de textura. A incorporação dessa imagem se mostrou importante na discriminação das plantas, visto a similaridade espectral entre as classes de plantas (1 e 2).

A questão da aquisição de dados de treinamento para as classes deve ser cuidadosamente considerada, pois é a partir das amostras coletadas que a rede trabalha. Assim, quando se diminui a resolução fica mais difícil identificar as classes de interesse. Para as imagens de 4 e 8 metros de resolução espacial não houve maior dificuldade na coleta de amostras, porém a partir de 16 metros de resolução, os tipos de plantas já não eram tão diferenciáveis e, para a imagem de 32 metros de resolução a coleta de amostras, principalmente para os tipos de plantas, foi mais complicada.

Outro aspecto relevante na aplicação das Redes Neurais Artificiais às imagens multiescala está na definição dos parâmetros necessários ao treinamento da rede e classificação dos dados. Neste estudo, os parâmetros definidos no treinamento da rede para a imagem de resolução espacial original, foram utilizados no treinamento das redes definidas para as imagens de 8, 16 e 32 metros de resolução espacial. No entanto, houve necessidade de aumentar o número de iterações no treinamento das redes aplicadas às imagens de 16 e 32 metros, pois quanto menor a resolução maior o número de iterações necessárias para que a RNA discrimine todas as classes. Isso acontece devido à menor separabilidade entre as classes nas imagens de média e baixa resolução (suavização das

variações). Os mapas temáticos resultantes dessa classificação caracterizam bem essa situação.

Pelas análises realizadas mediante a tabulação cruzada, verificou-se que as classes Planta1 e Planta2 foram as menos coincidentes, em função da maior dificuldade na diferenciação dos tipos de plantas. Apesar da necessidade de treinar individualmente a rede para cada nível de resolução das imagens, pode-se considerar que a aplicação da RNA na classificação supervisionada de plantas aquáticas e água em reservatórios mostrou-se uma abordagem promissora para a detecção e monitoramento destas plantas. Esta observação não pode ser generalizada para situações em que haja necessidade de diferenciar os tipos de plantas presentes em reservatórios. Porém se o caso for apenas detectar se existem ou mapear as áreas afetadas, imagens de média resolução (LANDSAT e CBERS) são suficientes.

AGRADECIMENTOS

Esse trabalho não teria sido possível sem a colaboração da CPFL, CAPES, Sidney de Marchi (FCA-UNESP) e professores do Programa de Pós Graduação em Ciências Cartográficas da UNESP-Presidente Prudente.

REFERÊNCIAS BIBLIOGRÁFICAS

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

ENVI. **Online Help Navigator**. Boulder, Research Systems, 2001.

ESPINHOSA, M. C. **Utilização do Sensoriamento Remoto Orbital e Redes Neurais Artificiais no mapeamento de macrófitas aquáticas emersas em grandes reservatórios**. 2004. Dissertação (Mestrado em Ciências Cartográficas) – Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista “Júlio Mesquita Filho”, Presidente Prudente.

GALO, M. L. B. T. **Caracterização Ambiental do Parque Estadual Morro do Diabo através de dados e técnicas de Sensoriamento Remoto: Abordagens utilizando redes neurais artificiais**. 2000. 205f. Tese (Doutorado em Ciências da Engenharia Ambiental) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

GONZALEZ, R. C.; WOODS, R. E.. **Processamento Digital de Imagens**. São Paulo: Edgard Blücher, 2000. 717p.

IDRISI. **Idrisi Tutorial**. Worcester, Clark Labs. 1997.

LEITE, M.A. **Varição especial e temporal da taxa de sedimentação no reservatório de Salto Grande (Americana-SP) e suas influencias sobre as características limnológicas do sistema**. 1998. Dissertação (Mestrado em Ciências da Engenharia Ambiental) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

LINDEBERGE, T. **Scale Space Theory in computer Vision**. Dordrecht, The Netherlands: Kluwer Academic Publishers, 1994.

MATLAB. **MATLAB Tutorial**. Natick, The MathWorks Inc. 1998.

MOREIRA, M. A. **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação**. São José dos Campos: Com Deus, 2001, 250p.

MIKHAIL, E. M., BETHEL, J. S. MCGLONE, J. C. **Introduction to Modern Photogrammetry**, Inc. New York: John Wiley & Sons, 2001, 479p.

NOVO, E. M. L. M.. **Sensoriamento Remoto: Princípios e Aplicações**. São Paulo: Edgard Blücher, 1989.

NOVO, E. M. L. M.; BRAGA, C. Z. F.; TUNDISI, J. G. Use of TM/Landsat data to retrieve the optically active water constituents from an eutrophic tropical reservoir. **Proceedings of ISPRS Commission VII Symposium: Resource and Environmental Monitoring**, Rio de Janeiro, sept 26-30, 1994, INPE, Vol.30, Part 76, 1994, p. 258-62.

RICHARDS, J. A.. **Remote Sensing Digital Image Analysis: Na Introduction**. New York: Springer Verlag, 1986.

SHIMABUKURO, Y.E.; SMITH, J.A. The least-squares mixing models to generate fraction images derived from remote sensing multispectral data. **IEEE Transactions on Geoscience and Remote Sensing**, v.29, n.1, 1991, p.16-20.

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. Brasília: DF. Embrapa – SPI/Embrapa-CPAC, 1998. p 351-371.

Recebido em 11 de maio de 2005 – Aceito para publicação em 17 de agosto de 2005.