



NARJARA CARVALHO DA CRUZ

A stylized graphic featuring a globe in the center, surrounded by several intersecting elliptical lines that resemble orbital paths or a complex network. The entire graphic is set against a light yellow background.

**Uma análise da infestação por plantas
aquáticas utilizando imagens multiescala e
redes neurais artificiais**

Dissertação de mestrado

Presidente Prudente

2005

NARJARA CARVALHO DA CRUZ

**Uma análise da infestação por plantas
aquáticas utilizando imagens
multiescala e redes neurais artificiais**

Dissertação de mestrado

**Presidente Prudente
2005**

NARJARA CARVALHO DA CRUZ

**Uma análise da infestação por plantas
aquáticas utilizando imagens multiescala e
redes neurais artificiais**

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

Orientadora: **Prof^a. Dr^a. Maria de Lourdes B. T. Galo**

Presidente Prudente
2005

Comissão Examinadora

Profa. Dra. Maria de Lourdes Bueno Trindade Galo

(Orientadora)

Prof. Dr. Nilton Nobuhiro Imai

Prof. Dr. Francisco Antônio Dupas

Narjara Carvalho da Cruz

Presidente Prudente, 2004

Resultado: _____

DEDICATÓRIA

Aos meus pais, minhas irmãs, e todos meus verdadeiros amigos.

AGRADECIMENTOS

- A Dr^a. Maria de Lourdes Bueno Trindade Galo por todos esses anos de orientação, pelos ensinamentos, paciência e amizade.
- A Companhia de Força e Luz do Estado de São Paulo, pelo auxílio financeiro e disponibilização das imagens, imprescindível para o desenvolvimento deste trabalho.
- A Coordenação de Aperfeiçoamento Pessoal de Nível Superior (CAPES), pela concessão da Bolsa.
- Ao Doutorado da FCA-UNESP de Botucatu Sidnei Roberto de Marchi pela disponibilização dos dados utilizados para esse trabalho.
- A todos os professores do PPGCC, do departamento de Cartografia pela colaboração a este trabalho.
- A todos meus amigos pelo companheirismo e momentos de descontração durante esses anos.

EPÍGRAFE

*“Nunca ande pelo
caminho traçado, pois ele
conduz somente até onde os
outros já foram”*

(Alexander Graham Bell)

RESUMO

Nos últimos anos, infestações de 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 de algumas substâncias na água, provocam mudanças na radiação da mesma, registradas por sensores orbitais. Nesse sentido, 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 (4 metros de resolução espacial) do reservatório de Salto Grande localizado na cidade de Americana- SP. Assim, foram geradas imagens 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 imagens multiespectrais IKONOS (bandas 1, 2, 3 e 4), imagem de textura (banda do IVP), e uma imagem de índice de vegetação (NDVI). 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. Os resultados obtidos mostraram que 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. Além disso, foi feita uma análise comparando as imagens classificadas através da tabulação cruzada, o que permite comparar os resultados obtidos nos 4 níveis de resolução, e mostrar que os mapas temáticos produzidos foram representativos para os 4 níveis de resolução espacial.

Palavras-chave: Classificação de imagens, Redes Neurais Artificiais, Infestações de Plantas aquáticas.

ABSTRACT

In past few years, great 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 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, the present dissertation 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, through the use of multiscale analysis procedures and supervised classification using artificial neural networks. Multispectral images IKONOS (spatial resolution of 4 meters) of the reservoir of Salto Grande, in the city of Americana-SP were used. So, multiscale images were generated, resulting in images of 8, 16 and 32 meters of spatial resolution. In the classification of these images, using Artificial Neural Networks, the input data was constituted of multispectral images IKONOS (bands 1, 2, 3 and 4), image of texture (band of NIR), and one image of vegetation index (NDVI). The method used was adequate to map the spectral variation of the water and to detect infested areas of aquatic plants in the various levels of resolution of the image. The results obtained showed that the classification by the parameters defined for the original image and applied in the training of the scheme adopted for the different resolution levels was satisfactory. Furthermore, an analysis was made comparing multiscale images classified through crossed comparison, which permits comparing the results obtained in the 4 levels of resolution, and showing that the thematic maps made were representative for the 4 levels of spatial resolution.

Keywords: Image Classification, Artificial Neural Networks, Infestations of Aquatic Plants

SUMÁRIO

DEDICATÓRIA.....	3
AGRADECIMENTOS.....	4
EPÍGRAFE.....	5
RESUMO.....	6
ABSTRACT.....	7
SUMÁRIO.....	8
LISTA DE FIGURAS.....	10
LISTA DE TABELAS.....	12
1 INTRODUÇÃO.....	14
2 OBJETIVOS.....	15
3 JUSTIFICATIVA.....	16
4 FUNDAMENTAÇÃO TEÓRICA.....	18
4.1 Sensoriamento remoto	18
4.1.1 Sensores utilizados para a coleta de dados em nível orbital.....	19
4.1.2 Comportamento espectral de alvos	22
4.2 Representação de uma imagem digital.....	27
4.2.1 Imagem Multiespectral.....	28
4.2.2 Representação multiescala de uma imagem.....	28
4.3 Processamento de imagens de Sensoriamento Remoto.....	32
4.4 Classificação de imagens e Mapeamento Temático.....	34
4.4.1 Classificação de Imagens por Redes Neurais Artificiais.....	36
5 MATERIAL E MÉTODO.....	48
5.1 Caso de estudo: Plantas aquáticas.....	48
5.2 - Material e Equipamentos.....	49
5.2.1 Dados Multiespectrais de Sensoriamento Remoto.....	49
5.2.2 Dados espaciais e descritivos (plantas aquáticas).....	50

5.2.3 Ferramentas Computacionais utilizadas no processamento e análise dos dados.....	53
5.3 Desenvolvimento Proposto.....	56
5.3.1 Recorte da Imagem (Exclusão da Área Externa do Reservatório de Salto Grande).....	57
5.3.2 Geração da imagens de textura e índice de vegetação.....	57
5.3.3 Geração das imagens multiescala.....	59
5.3.4 Definição das classes de interesse para a classificação.....	60
5.3.5 Classificação das imagens.....	61
5.3.6 Análise dos resultados.....	64
6 RESULTADOS: APRESENTAÇÃO E ANÁLISE.....	67
6.1 Recorte da região de interesse.....	67
6.2 Dados Espaciais: planos de entrada para a RNA.....	68
6.3 Imagens Multiescala.....	69
6.4 Resultados da classificação utilizando a RNA.....	71
6.4.1 Arquiteturas, parâmetros selecionados e tempo de processamento.....	71
6.4.2 Desempenho da rede neural na classificação dos dados.....	72
6.4.2.1 Imagem de resolução espacial original (4 metros).....	73
6.4.2.2 Imagem amostrada com resolução de 8 metros.....	73
6.4.2.3 Imagem amostrada com resolução de 16 metros.....	74
6.4.2.4 Imagem amostrada com resolução de 32 metros.....	76
6.4.3 As cenas Classificadas.....	77
6.5 Análise dos Resultados (tabulação e classificação cruzada).....	81
6.5.1 Índice Kappa.....	83
6.5.2 Imagens resultantes da Tabulação e Classificação Cruzada.....	85
6.5.4 Análise do desempenho das classificações para as imagens multiescala.....	87

7	CONSIDERAÇÕES FINAIS.....	90
8	REFERÊNCIAS BIBLIOGRÁFICAS.....	93
	APENDICE I.....	97
	APENDICE II.....	100

LISTA DE FIGURAS

Figura 1	Curva espectral média da vegetação fotossinteticamente ativa.	23
Figura 2	Comportamento Espectral da água em seus diferentes estados físicos ..	24
Figura 3	Curvas de Reflectância da água obtidas nos rios Tietê e Piracicaba e no reservatório de Barra Bonita, estado de São Paulo.....	26
Figura 4	Representação esquemática de uma imagem digital.....	28
Figura 5	Representação de uma imagem multiespectral.....	28
Figura 6	Representação Multiescala de uma imagem.....	30
Figura 7	Geração de um pixel em uma imagem através da estrutura piramidal...	31
Figura 8	A representação piramidal.....	32
Figura 9	Organização das camadas em uma rede neural artificial.....	39
Figura 10	Modelo sináptico de neurônio artificial ou elemento de processamento de uma rede.....	39
Figura 11	Rede <i>Multicamadas</i> com Retro-propagação do erro.....	41
Figura 12	Esquema de Treinamento <i>Backpropagation</i>	42
Figura 13	Superfície de erro de treinamento <i>backpropagation</i>	43
Figura 14	Delimitação da área de estudos.....	48
Figura 15	Composição colorida (RGB-423) para a imagem IKONOS da Represa de Salto Grande.....	49
Figura 16	Detalhe de uma área de infestação por plantas aquáticas na represa de Americana.....	50
Figura 17	Indicações de pontos de maior infestação de plantas aquáticas (fotografadas).....	51
Figura 18	Ponto 1: População mista de plantas aquáticas (Braquiária e Aguapé)...	51
Figura 19	Ponto 2: População mista de plantas aquáticas (Braquiária e Aguapé)..	52
Figura 20	Ponto 3: População mista de plantas aquáticas (Braquiária e Aguapé)...	52
Figura 21	Ponto 4: População mista de plantas aquáticas (Braquiária e Aguapé)...	52

Figura 22	Ponto 5: População mista de plantas aquáticas (Braquiária, Taboa e Aguapé).....	53
Figura 23	Fluxograma das atividades desenvolvidas neste projeto.....	56
Figura 24	Composição colorida IKONOS, caracterizado o corpo d'água.....	67
Figura 25	Imagem de textura da banda do IVP.....	68
Figura 26	Imagem índice de vegetação para o reservatório de Salto Grande...	69
Figura 27	Pirâmide de imagem multiescala para a área de interesse.....	70
Figura 28	Media dos valores de brilho obtidas a partir das amostras representativas das classes para as imagens multiescala : Azul (a), Verde (b), Vermelho (c) e IVP(d).	71
Figura 29	Evolução do EMQ durante o treinamento para a imagem de 4 metros de resolução espacial.....	73
Figura 30	Evolução do EMQ durante o treinamento para a imagem de 8 metros de resolução espacial.....	74
Figura 31	Evolução do EMQ durante o treinamento para a imagem de 16 metros de resolução espacial.....	75
Figura 32	Erro RMS durante o treinamento para a imagem 32 metros de resolução espacial.....	76
Figura 33	Imagem de 4 metros de resolução espacial classificada.....	78
Figura 34	Imagem de 8 metros de resolução espacial classificada.....	79
Figura 35	Imagem de 16 metros de resolução espacial classificada.....	80
Figura 36	Imagem de 32 metros de resolução espacial classificada.....	81
Figura 37	Tabulação Cruzada 4 e 8 metros de resolução espacial.....	85
Figura 38	Tabulação Cruzada 4 e 16 metros de resolução espacial.....	86
Figura 39	Tabulação Cruzada 4 e 32 metros de resolução espacial	87
Figura 40	Proporção de pixels por classe para os 4 níveis de resolução das classificações.....	88
Figura 41	Índice <i>Kappa</i> para as tabulações cruzadas.....	89

LISTA DE TABELA

Tabela 1	Resoluções do sistema sensor IKONOS.....	22
Tabela 2	Classes de interesse.....	63
Tabela 3	Parâmetros, tempo de processamento e RMS final para a imagem original (4m).....	72
Tabela 4	Número de iterações, tempo de processamento e EMQ final para a imagem de 16 metros de resolução espacial.....	76
Tabela 5	Número de iterações, tempo de processamento e EMQ final para a imagem de 32 metros de resolução espacial.....	78
Tabela 6	Proporção de pixels coincidentes (%) nas classificações resultantes da tabulação cruzada entre as imagens de 4 e 8, 4 e 16, e 4 e 32 metros de resolução espacial	82
Tabela 7	Índice de concordância <i>Kappa</i> (4-8, 4-16 e 4-32 metros de resolução espacial).....	84
Tabela 8	Proporção de pixels por classes para os 4 níveis de resolução da imagem.....	88

1 INTRODUÇÃO

Nos últimos anos, grandes 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.

O Sensoriamento Remoto devido a sua capacidade de registrar as mudanças de radiância a partir de substâncias presentes na água, 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 e à utilização da água para suas várias finalidades, especialmente para a geração de energia elétrica. Assim, a utilização de metodologias que incorporem uma representação da dispersão espacial das plantas aquáticas, 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.

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 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 de probabilidade dos dados a serem classificados é exigida e face à maior flexibilidade que esses modelos possuem quanto à entrada de dados para a classificação.

Para a realização deste projeto, foram utilizadas imagens IKONOS multiespectrais com 4 metros de resolução espacial, abrangendo a área do reservatório de Salto Grande na cidade de Americana, estado de São Paulo. A definição desta área de estudos deve-se à disponibilidade de imagem IKONOS, e dados descritivos, mas principalmente à grande quantidade de áreas infestadas por plantas aquáticas nesse reservatório, e também por possuir uma área favorável a pesquisa por não ser tão extensa.

2 OBJETIVO

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 da 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 na cidade de Americana (SP), para a qual foram delineados os seguintes objetivos específicos:

- Gerar imagens com diferentes níveis de resolução espacial, a partir de uma imagem IKONOS, utilizando procedimentos de processamento digital de imagens. Isso foi feito até que a resolução da imagem multiescala estivesse próxima de uma imagem multiespectral de média resolução;

- Aplicar procedimentos de classificação de imagens multiespectrais utilizando um modelo de rede neural artificial, aplicado nos diversos níveis de resolução da imagem multiescala;
- 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.

3 JUSTIFICATIVA

O manejo de plantas aquáticas tornou-se alvo de estudos nos últimos anos, devido a disseminação de áreas infestadas e aos prejuízos provocados por esse tipo de vegetação em reservatórios e usinas hidrelétricas. Nesse último caso, o controle dessas infestações exige 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 realizados com o intuito de otimizar o processo, ou mesmo encontrar alternativas, para um possível manejo.

O Sensoriamento Remoto pode se constituir em uma ferramenta útil para monitorar a ocorrência dessas plantas, já que a presença de áreas infestadas por plantas aquáticas é facilmente perceptível em imagens tomadas no intervalo espectral do infravermelho próximo. Assim, a partir de imagens adquiridas por sensores orbitais é possível avaliar a evolução das comunidades e subsidiar estimativas do potencial atual e futuro de danos causados por essas populações ao meio ambiente e à utilização da água para suas várias finalidades, especialmente para a geração de energia elétrica (ESPINHOSA, 2004).

Imagens de alta resolução podem ser muito úteis no processo de monitoramento dessas plantas, porém o custo de aquisição dessas imagens torna-se um obstáculo para esse tipo de trabalho, quando se trata de reservatórios de

grandes dimensões. Assim, um estudo sobre a capacidade de discriminação e necessidade de detalhamento para avaliar o fenômeno em questão é necessário. A presente concepção propõe-se a avaliar a questão da utilização de imagens multiescala, de forma analisar qual o detalhamento necessário para a detecção de plantas em reservatórios, a partir da classificação das imagens utilizando uma rede neural artificial.

Espera-se que a contribuição prática deste estudo seja no sentido de indicar se imagens de média resolução espacial, obtidas por sensores instalados em plataformas orbitais (CCD/Cbers, TM/Landsat, entre outros), podem ser usadas nos mapeamentos de áreas infestadas por plantas aquáticas em reservatórios e fornecer um resultado comparável com o mapeamento realizado a partir de imagens de alta resolução, os quais são mais onerosos e envolvem processamento de maior complexidade.

4 FUNDAMENTAÇÃO TEÓRICA

4.1 Sensoriamento remoto

Ao interagir com a superfície terrestre, a radiação eletromagnética pode sofrer absorção, reflexão e transmissão, dependendo das propriedades desta superfície e do intervalo espectral considerado. Os comprimentos de onda nos quais a radiação é refletida e transmitida, são utilizados na identificação dos alvos em sensoriamento remoto.

Os sistemas de aquisição de dados de sensoriamento remoto, definidos como sistemas sensores, constituem-se de qualquer equipamento capaz de transformar a radiação eletromagnética em um sinal passível de ser convertido em informações sobre o meio ambiente (NOVO, 1989). Dentre a grande variedade de equipamentos que apresentam essa capacidade, podem ser destacados os sensores imageadores, os quais fornecem como produto uma imagem da cena observada.

As imagens digitais obtidas por satélites, fotografias aéreas ou *scanners* aerotransportados, são armazenadas como matrizes, sendo que cada elemento que a constitui (denominado pixel) tem um valor proporcional à intensidade de energia eletromagnética refletida ou emitida pela área da superfície terrestre correspondente ao tamanho do elemento de resolução espacial do sensor considerado. Portanto, essas imagens representam formas de captura indireta da informação espacial (NOVO, 1989).

As imagens multiespectrais possuem uma representação digital complexa: cada pixel com coordenadas espaciais (x, y) é representado por um conjunto de valores de brilho (níveis de cinza), ou seja, cada pixel é representado por um vetor com tantas dimensões quantas forem às bandas espectrais analisadas (RICHARDS, 1986).

4.1.1-Sensores utilizados para na coleta de dados em nível orbital

Segundo MOREIRA (2001), os sistemas sensores são dispositivos capazes de detectar e registrar a radiação eletromagnética em determinada faixa do espectro eletromagnético e gerar informações que possam ser transformadas num produto passível de interpretação quer seja na forma de imagem, na forma gráfica ou de tabelas.

Conforme descreve NOVO (1989), os diferentes sistemas sensores são caracterizados pela sua resolução, definida como a medida da habilidade que o sensor possui em discernir entre respostas espectralmente semelhantes e espacialmente próximas. Além da resolução espacial que mede a menor separação linear ou angular entre dois objetos da superfície terrestre, os sistemas de varredura dos satélites podem ser caracterizados pela sua resolução espectral, a qual define-se como a medida da largura e o número de bandas espectrais nas quais o sensor opera; a resolução radiométrica, relacionada com a sensibilidade do sensor em diferenciar dois níveis de intensidade do sinal de retorno; e a resolução temporal que se refere ao intervalo de tempo entre a aquisição de duas imagens de uma mesma área.

CROSTA (1992) define a resolução espacial de um sensor como sendo sua capacidade em “enxergar” objetos na superfície terrestre; quanto menor o objeto, maior deve ser a resolução espacial do sistema, para que sua detecção seja possível.

A aquisição de dados de sensoriamento remoto, com aplicação em recursos naturais, pode ser feita através de sensores instalados em plataformas orbitais, de média e alta resolução. A seguir é apresentada uma pequena descrição dos sistemas sensores mais utilizados no sensoriamento remoto.

Entre os satélites de média resolução mais utilizados e atualmente em operação, podem ser destacados a série americana LANDSAT, o francês SPOT e o satélite brasileiro/chinês CBERS.

O sistema TM - *Thematic Mapper* (instalado a bordo dos satélites LANDSAT 4 e 5), conta com sete bandas espectrais, as três primeiras localizam-se na faixa visível do espectro (0,45 - 0,69 μm), duas no infravermelho próximo (0,76 – 1,75 μm), uma no infravermelho distante (2,08 – 2,35 μm), e uma banda termal (10,4 – 12,5 μm). Sua resolução espacial é de 30 metros para as seis primeiras bandas e 120 metros para a banda termal. A resolução temporal desse sensor é de 16 dias, e sua resolução radiométrica de 8 bits (256 níveis de cinza). O sensor ETM+ (*Enhanced Thematic Mapper Plus*), instalado no LANDSAT 7 conta das mesmas bandas espectrais do TM, com uma banda pancromática com resolução espacial de 15 metros. Outro aprimoramento é a redução do tamanho do pixel na banda termal, que passou a ser 60 metros (CENTENO, 2003).

Os sensores HRV - *Haute Resolution Visible*, os quais constituem a carga útil do satélite francês SPOT possuem uma resolução espacial de 20 metros nas bandas multiespectrais (4 bandas, intervalo espectral de 0,50 – 1,75 μm) e 10 metros para a banda pancromática com intervalo espectral entre 0,51 – 0,73 μm . Sua resolução radiométrica é de 8 bits (256 níveis de cinza). Uma vantagem desse sensor é a possibilidade de movimentação da plataforma ao longo da sua órbita, com isso o tempo de exposição para cada ponto da Terra é maximizado e é garantida qualidade fotogramétrica ao longo do eixo da linha de varredura. Outra vantagem desse sistema é a possibilidade de girar lateralmente os arranjos de sensores para apontar em direção fora do nadir. Embora a plataforma sobrevoe o mesmo ponto a cada 26 dias, aproveitando o movimento descrito é possível observar uma região em intervalos menores com ângulos de visão diferentes (CENTENO, 2003).

O sensor CCD, a bordo do satélite CBERS (Satélite Sino-Brasileiro de Recursos Terrestres) possui a resolução de 20 metros, e também pode ser apontado lateralmente, inclinando o sistema em até 32 graus para cobrir as faixas adjacentes, de maneira similar ao sistema HRV-SPOT. Sua resolução espectral é de

4 bandas multiespectrais com intervalo entre 0,45 a 0,89 μm e uma pancromática (de 0,51 – 0,73 μm). Sua resolução temporal está entre 3 e 5 dias, a resolução radiométrica de 8 bits (256 níveis de cinza) (CENTENO, 2003).

Para sensores de alta resolução pode-se destacar o sensor IKONOS, com resolução espacial de 1 metro na banda pancromática e multiespectrais com 4 metros de resolução. Uma breve explanação sobre esse sensor será feita a seguir, já que uma imagem obtida por esse sistema foi utilizada no desenvolvimento deste trabalho.

Sistema IKONOS

O sistema IKONOS revolucionou o mercado de imagens de satélite principalmente pela alta resolução espacial de seus produtos. As quatro bandas do modo multiespectral não oferecem uma resolução espectral singular, comparada com os outros sistemas sensores, com quatro bandas na região do visível e uma banda na região do infravermelho próximo, com resolução espacial de 4 metros, o grau de detalhe presentes nestas imagens aumentou significadamente, superando com isso a quantidade de informação disponível por outros sistemas. O sistema oferece ainda uma imagem no modo pancromático (de 0,45 a 0,9 μm) com resolução temporal ainda maior, pois o pixel neste caso é de apenas 1 metro. Independente do modo de aquisição, a resolução radiométrica é de 11 bits (2048 níveis de cinza), proporcionando um maior poder de contraste e discriminação para as imagens produzidas.

O sistema IKONOS possui a habilidade de inclinar seus sensores, da mesma forma que faz o SPOT, no sentido perpendicular ao deslocamento da plataforma. O sistema ainda pode efetuar, além das visadas nadirais convencionais, visadas avante e para trás na mesma faixa do terreno. Com isto pode ser obtido um modelo estereoscópio da região imageada. (CENTENO, 2003)

A Tabela 1 mostra os valores de resolução espacial, espectral, temporal e radiométrica para as quatro bandas espectrais e para a banda pancromática do sensor IKONOS II.

Tabela 1- Resoluções do sistema sensor IKONOS

Bandas	Resolução Espectral	Resolução Espacial	Resolução Temporal	Resolução radiométrica
Azul	0,45 a 0,52 μm	4 metros	1,5 dia	8 e 11 bits
Verde	0,52 a 0,60 μm	4 metros	1,5 dia	8 e 11 bits
Vermelho	0,63 a 0,69 μm	4 metros	1,5 dia	8 e 11 bits
IVP	0,76 a 0,90 μm	4 metros	1,5 dia	8 e 11 bits
Pancromática	0,45 a 0,90 μm	1 metro	2,9 dias	8 e 11 bits

Fonte: Adaptado de MOREIRA 2001.

4.1.2- Comportamento espectral dos alvos

O conhecimento do comportamento espectral de alvos não é imprescindível somente para a extração de informações a partir das imagens obtidas pelos sensores, é também importante 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).

O comportamento espectral dos alvos é normalmente representado por um gráfico que relaciona a reflectância do alvo em função do comprimento de onda.

Para a interpretação dos dados é necessário conhecer as condições experimentais em que foram realizadas as medidas e também os instrumentos utilizados. 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 será tratado de modo generalizado, o comportamento espectral de dois dos principais componentes da superfície terrestre, pois estes alvos são os mais importantes para esse trabalho: a vegetação e a água.

Vegetação

Segundo NOVO (1989), através da análise da curva espectral média da vegetação fotossinteticamente ativa (Figura 1), pode-se identificar três regiões espectrais, em função dos fatores que condicionam seu comportamento:




Figura 1: Curva espectral média da vegetação

Fonte: NOVO, 1989

- a . até 0,7 μm a reflectância é baixa ($< 0,2$), dominando a absorção da radiação incidente pelos pigmentos da planta em 0,48 μm (*carotenóides*) e em 0,62 μm (*clorofila*). Em 0,56 μm , 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 μm a 1,3 μm , tem-se a região dominada pela alta reflectância da vegetação ($0,3 < \rho < 0,4$), devido estrutura celular da vegetação;

c . entre 1,3 μm e 2,5 μm , 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 μm e 1,95 μm . A esta região correspondem também as bandas de absorção atmosférica. Por isso, os sensores desenvolvidos têm suas faixas espectrais deslocadas para regiões sujeitas à atenuação atmosférica (NOVO,1989).

Água

A água apresenta-se na natureza sob diferentes estados físicos, que influenciam de modo fundamental no seu comportamento espectral. A Figura 2 apresenta o comportamento espectral da água em seus diferentes estados físicos.




Figura 2- Curva Espectral da água em seus diferentes estados físicos
Fonte: NOVO,1989

Como pode ser observada na Figura 2, a água pura em seu estado líquido apresenta baixa reflectância entre 0,38 μm e 0,70 μm ($\rho < 0,1$), absorvendo quase toda a radiação acima de 0,7 μm .

Diferente do solo e da vegetação, a maior parte do fluxo radiante incidente sobre a água não é refletido, mas absorvido ou transmitido. Nos comprimentos de onda do visível, pouca luz é absorvida, uma pequena quantidade é refletida e a

maior parte é transmitida. MOREIRA (2001) destaca que a água no estado líquido absorve quase toda a radiação eletromagnética abaixo de $0,38\ \mu\text{m}$ e acima de $0,7\ \mu\text{m}$ 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 de cerca de 5% no azul para 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.

Conforme descreve ROBIN (1995), a água pura tem uma resposta espectral característica: sua reflectância é elevada no intervalo espectral correspondente à luz azul, diminui no verde, fraca no vermelho e quase nula no infravermelho próximo. Na realidade, a água absorve inteiramente a radiação do infravermelho próximo incidente já nos primeiros milímetros da coluna d'água.

Segundo CURRAN (1985) 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.

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 o 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.

Segundo MOREIRA (2001), partículas minerais inorgânicas, provenientes de rochas e solos, que são carregadas para corpos d'água, por ação do vento, da chuva, da ressuspensão e erosão do fundo, também interferem na absorção da energia pela massa de água.

A Figura 3 exemplifica a concentração de material inorgânico em suspensão a partir de um estudo no qual os autores mediram a reflectância da água em três pontos distintos: a) no reservatório de Barra Bonita: formado pelos rios Piracicaba e Tietê, estado de São Paulo; b) no rio Tietê e c) no rio Piracicaba. Os autores chegaram as seguintes conclusões:




Figura 3– Curvas de Reflectância da água obtidas nos rios Tietê e Piracicaba e no reservatório de Barra Bonita, estado de São Paulo.

Fonte STEFFEN et al (1992) apud MOREIRA (2001).

- A reflectância da água do rio Tietê é típica de água com elevada concentração de material inorgânico em suspensão, com acentuada reflectância na faixa do vermelho, indicando baixa absorção da energia nesta região do espectro.

- A água do rio Piracicaba apresenta uma reflectância bastante baixa, com pico de máxima reflectância na região do verde (23%). Este fato é um forte indicador da presença de material orgânico em suspensão.
- A reflectância da água, obtida no corpo central do reservatório de Barra Bonita, onde as águas dos dois rios já estão misturadas, mostra claramente a transição entre os dois aspectos anteriores.

4.2 Representação de uma imagem digital

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. Assim, uma imagem digital constitui uma matriz bidimensional que define um conjunto de *pixels*. Cada *pixel* é definido pelas coordenadas espaciais (x,y) que indicam sua localização na cena, sendo que a cada posição (x, y) é atribuído um valor digital (nível de cinza) correspondente ao valor radiométrico registrado pelo sensor. A Figura 4 ilustra um exemplo dessa representação.




Figura 4 - Representação esquemática de uma imagem digital.
(Adaptado de RICHARDS, 1986)

4.2.1 Imagem Multiespectral

As imagens multiespectrais possuem uma representação digital mais complexa: cada *pixel* com coordenadas espaciais (x, y) é representado por um conjunto de valores de brilho (níveis de cinza), ou seja, cada *pixel* é representado por um vetor com tantas dimensões quantas forem as bandas espectrais analisadas. A Figura 5 ilustra uma imagem multiespectral, onde x e y definem as coordenadas espaciais do *pixel* e n é o vetor que representa as bandas espectrais.




Figura 5 - Representação de uma imagem multiespectral
(Adaptado de RICHARDS, 1986)

4.2.2 Representação multiescala de uma imagem

Ao observar uma imagem, algumas quantidades físicas podem ser medidas, gerando um conjunto de observáveis diretamente ligadas a imagem. Um problema básico que surge neste contexto é: qual nível de detalhe (resolução) se deseja ou é necessário para solucionar um dado problema? (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 é também conhecida como escala do fenômeno, e apresenta-se como o inverso da escala cartográfica. Assim, os conceitos de escala cartográfica e escala do fenômeno podem ser entendidos como:

- **Escala cartográfica:** é a razão entre as dimensões gráficas (mapa) e dimensões naturais (objeto real).

- **Escala do fenômeno:** é “a escolha de uma forma de dividir o espaço, definindo uma realidade percebida/concebida, é uma forma de dar-lhe uma figuração, uma representação, um ponto de vista que modifica a percepção da natureza deste espaço e, finalmente, um conjunto de representações coerentes e lógicas que substituem o espaço observado” (MARQUES, 2004).

Através desta analogia, pode-se verificar que quanto maior for a área compreendida por um fenômeno, menor deverá ser a escala cartográfica adequada para a sua representação e quanto menor for a área de ocorrência de um fenômeno, maior deverá ser a escala cartográfica necessária para a sua representação. Assim, para a obtenção de uma determinada informação ou detalhe de um objeto deve-se usar uma escala apropriada.

A representação multiescala de uma imagem está ligada ao conceito de se ter várias medidas usando observações em diferentes escalas, conforme é apresentado na Figura 6. Nesta Figura é mostrada a imagem original e suas imagens derivadas. A partir da imagem original surgem as imagens derivadas, pois é uma exigência crucial que estruturas de escalas grosseiras na representação multiescala devam constituir simplificações de estruturas correspondentes às escalas finas. Para a criação de imagens multiescala, é embutido na imagem original um parâmetro gerando os sinais derivados (LINDEBERGE,1994). Este parâmetro pode ser representado por um filtro passa baixa (na figura é representado por “incremento t ”).




Figura 6 - Representação multiescala
Fonte: LINDEBERGE, 1994

A razão técnica para se representar uma imagem em múltiplas escalas, reflete a necessidade comum de suavização como um passo de pré-processamento ou um meio de supressão de ruídos. Na literatura, existe um grande número de meios para construir imagens derivadas, que aqui serão tratadas como representação multiescala, como: Quad-Tree, Wavelets, Espaços de Escala e Pirâmides de Imagens.

Neste trabalho será tratada especificadamente a representação por **pirâmides de imagens**. Esse procedimento de representação multiescala foi escolhido por se tratar de um método simples na geração das imagens, e também porque além de suavizar a imagem, esta estrutura também reamostra a imagem, 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).

Neste contexto, na formação de uma estrutura piramidal, as imagens são filtradas por um filtro passa-baixa, e a imagem resultante dessa filtragem é sub-amostrada, resultando em uma componente de baixa frequência, com resolução espacial mais baixa (GOMES & VELHO, 1994).

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

Na Figura 7 é esquematizada geração de um pixel de uma imagem a partir de uma estrutura piramidal, com resolução espacial de quatro metros. Os números no interior das células na Figura 7A exemplificam níveis de cinza para os pixels da imagem de entrada (imagem original). A Figura 7B mostra o resultado obtido para a filtragem (média) e reamostragem do tamanho do pixel. Como resultado da aplicação do filtro média e a reamostragem do tamanho do pixel.




Figura 7 - Geração de um pixel em uma imagem através da estrutura piramidal.

Uma das principais vantagens nas representações por estruturas piramidais é um rápido decrescimento do tamanho da imagem e uma redução exponencial da quantidade de dados o que, conseqüentemente, reduz o esforço computacional, tanto em termos de processamento (custo) quanto na representação das imagens (memória). Por outro lado, a desvantagem principal consiste nas estruturas piramidais serem quantizações grosseiras ao longo da escala (SCHENK, 1999). A Figura 8 mostra a representação de uma estrutura piramidal.




Figura 8 - A representação piramidal

Nessa estrutura (Figura 8) o primeiro nível representa a imagem original, os outros 2 níveis, representam os dados reamostrados considerando a potência de 2^n , assim, se o primeiro nível tiver a resolução espacial de 2 metros, o segundo nível terá 4 metros e o terceiro nível 8 metros.

4.3 Processamento de imagens de Sensoriamento Remoto

A utilização de computadores nos procedimentos de extração de informações a partir de dados de sensoriamento remoto tem aumentado consideravelmente nos últimos anos, possibilitando o desenvolvimento de análises direcionadas à caracterização dos processos ambientais com sucesso.

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 abrangências da cena considerada e com o número de bandas espectrais

disponíveis, as resoluções espaciais e radiométrica é que determinam o volume de dados que será analisado.

Nesse contexto, o processamento digital de imagens envolve a manipulação e interpretação de dados de sensoriamento remoto com o auxílio de computadores, e tem como 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 radiométrica e geometricamente retificados, 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.

As técnicas de realce incluem uma 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 em 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 ao máximo o intervalo de variação dos valores de brilho (RICHARDS, 1986).

Entre as técnicas que implementam transformações geométricas em uma imagem unidimensional, aquelas que representam o atributo textural merecem destaque no contexto de análise espacial.

De acordo com GALO (2000) as medidas de textura foram desenvolvidas originalmente para quantificar certos aspectos de padrões presentes em imagens digitais, relacionadas com propriedades estatísticas ou estruturais de uma

vizinhança de pixels, ou seja, descrevem a variabilidade da cena. Como a estrutura da paisagem pode ser analisada pelo arranjo de seus elementos constituintes, relacionado com a heterogeneidade da paisagem, é razoável presumir que a variabilidade da cena reflete essa heterogeneidade espacial da paisagem, a qual pode ser analisada, em um primeiro momento, a partir de bordas definidas pela aplicação de operadores texturais.

No que se refere às operações aritméticas entre as imagens, RICHARDS (1986) destaca que as razões de diferenças de bandas espectrais são usadas principalmente, para realçar diferenças súbitas nas características de reflectância dos alvos. Quando operações desse tipo baseiam-se nas interações que ocorrem entre a vegetação e a radiação eletromagnética nos intervalos de comprimento de onda do vermelho e infravermelho próximo, o valor resultante é expresso como índice de vegetação; assim aumentando o brilho das áreas vegetadas, melhorando a aparência da distribuição espacial de informações das imagens tornando-as de fácil interpretação visual e computacional.

4.4 Classificação de imagens e Mapeamento Temático

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

A classificação é um importante componente na análise de dados de sensoriamento remoto. Na análise de dados multiespectrais, VENTURIERI & SANTOS (1998) ressaltam que a classificação de imagens consiste no estabelecimento de um processo de decisão no qual um grupo de pixels é definido como pertencente a uma determinada classe. Primeiro faz-se uma observação qualitativa e medem-se quantitativamente os fenômenos espaciais com os

instrumentos disponíveis. Como resultado, obtém-se descrições e medidas sobre o alvo de interesse. Pode-se então, dizer que a classificação é um processo de extração de informação das imagens com o objetivo de reconhecer padrões e objetos homogêneos. Neste sentido, os sistemas computacionais podem constituir-se em ferramentas bastante adequadas ao processo de interpretação das imagens orbitais.

Um dos aspectos básicos da aplicação do sensoriamento remoto aos mapeamentos temáticos é a definição de um sistema de classificação que seja adequado ao estudo que se pretende desenvolver. É importante estabelecer claramente as classes que constarão do mapeamento, e nesse processo deve ser levado em consideração o nível de detalhamento oferecido pelos dados disponíveis.

O nível de detalhamento estabelecido para um dado esquema de classificação é direcionado pelo uso que será dado à informação representada no mapa e pelos atributos da terra que são discerníveis nos dados disponíveis para sua elaboração. Segundo CONGALTON e GREEN (1999), um esquema de classificação tem dois componentes críticos: o conjunto de categorias ou rótulos definidos para representar as classes de interesse e um conjunto de definições ou regras que caracterizem os diferentes tipos de ocorrências a serem mapeadas.

Os mapas temáticos procuram generalizar as feições da superfície terrestre através de categorias especificadas em um projeto (esquema) de classificação apropriado para cada aplicação. Os esquemas de classificação constituem, então, os meios usados para organizar a informação espacial de uma maneira lógica e ordenada e possibilita para quem produz o mapa, caracterizar as feições da paisagem e, para o usuário do mapa, reconhece-las (CONGALTON e GREEN, 1999).

Para a análise de dados multiespectrais, RICHARDS (1986) destaca dois procedimentos abrangentes de classificação. Um deles, definido como classificação não-supervisionada, é um meio pelo qual os pixels de uma imagem são associados a classes espectrais, sem que haja um conhecimento prévio da existência ou nome

destas classes. Posteriormente é feita uma rotulação das classes, orientada por trabalhos de reconhecimento de campo.

O outro método é a classificação supervisionada, a qual se constitui na ferramenta analítica essencial usada na extração de 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. O processo pelo qual um conjunto de treinamento é usado para obter as funções de decisão é denominado aprendizagem ou treinamento (GONZALEZ e WOODS, 1993).

Um pressuposto importante adotado na maioria dos procedimentos mais consolidados de classificação supervisionada é o de que as classes de interesse podem ser modeladas por uma distribuição de probabilidade no espaço multiespectral e, conseqüentemente, descritas pelos parâmetros dessa distribuição, em geral normal ou Gaussiana.

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

4.4.1 Classificação de Imagens por Redes Neurais Artificiais

Muitas vezes, as propriedades estatísticas de uma classe não podem ser estimadas, de modo que os problemas de teoria de decisão são mais bem

trabalhados pelos métodos que produzem diretamente as funções de decisão através dos dados de treinamento (GONZALEZ e WOODS, 1993). No contexto de reconhecimento de padrões, LEE et al. (1990) relatam que 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 ser classificados, seja explicitada.

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 ou conexões. A principal função dessas células é distribuir padrões de ativação através de suas conexões, de maneira similar ao mecanismo básico do cérebro humano (ZELL et al., 1995).

Segundo BRONDINO (1999), as redes neurais artificiais 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:

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;

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, elas 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;

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 convencionais.

As redes neurais artificiais são organizadas em camadas que compõem sua topologia ou arquitetura. Existem redes neurais de camada simples (*perceptron*) constituídas por um grupo de neurônios arranjados em apenas uma camada, e as 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 da rede.

Desse modo, as estruturas multicamadas são de uma camada de entrada, uma ou mais camadas escondidas e uma camada de saída.

- **Camada de Entrada:** na qual os padrões são apresentados à 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:** na qual o resultado final é concluído e apresentado.

Essa arquitetura é tida como a arquitetura mais conhecida e utilizada pelos pesquisadores (BRONDINO, 1999).

Na Figura 9, apresenta-se a organização das camadas em uma rede Multicamadas, com apenas uma camada escondida.




Figura 9 – Organização das camadas em uma rede neural artificial Multicamadas.

Fonte: Adaptado de Tatibana & Kaetsu (2000)

Na descrição de uma rede neural multicamadas feita por BOCANEGRA (2002), o elemento fundamental é o neurônio artificial que consiste da unidade ou elemento de processamento, também designado nó, que recebe uma ou mais entradas transformando-as em saída. Nessa descrição, a entrada de cada neurônio tem um peso associado que determina a sua intensidade do sinal de saída. A Figura 10 mostra o esquema de neurônio artificial.




Figura 10 - Modelo sináptico de neurônio artificial ou elemento de processamento de uma rede. Fonte: (HAYKIM, 1994 *apud* BRONDINO,1999).

A partir da Figura 10 é possível distinguir os elementos que compõe a estrutura de um neurônio artificial, designado:

- **Sinapses (Conexões):** caracterizadas por um peso, w , que pode representar sua intensidade. O papel do peso w_{kj} 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 (função soma):** realiza a soma de todas as entradas ponderadas pelos seus pesos respectivos, ou seja:

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

- **Limiar (threshold), θ_k :** tem o papel determinante na saída do neurônio. Sua função é controlar a intensidade da função de ativação para se obter o desempenho desejado da rede. Se o valor de u_k for menor que este limiar, então a saída do neurônio fica inibida, caso contrário o neurônio fica ativo;

- **Função de ativação:** funciona como um 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):**

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

onde:

φ é a função de ativação.

Segundo BRONDINO (1999), a função de ativação define a saída do neurônio em termos de nível de atividade do mesmo. Dentre as funções de ativação mais comuns se enquadram as seguintes:

- ✓ **Função Linear:** $j_i(t+1) = v_i(t)$

✓ **Função *threshold* ou limiar:** $j_i(t+1) = \begin{cases} 1, & \text{se } v_i(t) \geq \theta \\ 0, & \text{se } v_i(t) < \theta \end{cases}$

✓ **Função sigmóide logística:** $j_i(t+1) = 1/(1 + e^{-v_i(t)})$

✓ **Função tangente hiperbólica:** $j_i(t+1) = (1 - e^{-v_i(t)}) / (1 + e^{-v_i(t)})$

✓ **Função linear por partes:** $j_i(t+1) = \begin{cases} +1, & \text{se } v_i(t) > \theta \\ -1, & \text{se } v_i(t) < \theta \\ v_i(t), & \text{fora do intervalo definido.} \end{cases}$

As redes multicamadas têm sido muito utilizadas para soluções de problemas envolvendo altos graus de não-linearidade, quando os dados de entrada são dados muitos similares. Tais redes adotam um treinamento supervisionado que 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 (HAYKIN, 1994 *apud* BOCANEGRA, 2002).

Para facilitar esse entendimento, a Figura 11 mostra parte da rede multicamadas, onde dois tipos de sinais podem ser identificados:




Figura 11 - Rede *Multicamadas* com Retro-propagação do erro.

Fonte: (HAYKIM, 1994 *apud* BRONDINO,1999).

onde:

→ **Sinal funcional:** sinal de entrada (estímulo) que chega na entrada e é propagado positivamente (neurônio a neurônio) através da rede definindo um sinal de saída.

→ **Sinal de erro:** origina-se nas saídas e é retro-propagados (neurônio a neurônio) através da rede, atualizando os pesos durante o treinamento.

Normalmente o algoritmo de treinamento ou aprendizagem “*backpropagation*” utilizado para treinar uma rede *Multicamadas* é derivado Regra Delta Generalizada, e é o algoritmo mais conhecido para aprendizagem supervisionada. Esse algoritmo permite um ajuste de pesos em cada uma das camadas da rede e é projetado para minimizar a soma do quadrado do erro (ou erro médio quadrático) 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). A Figura 12 representa o esquema de treinamento da rede *backpropagation*.




Figura 12 – Esquema de Treinamento *Backpropagation*.

Fonte: TATIBANA & KAETSU (2002).

Segundo GALO (2000), o processo de treinamento pelo algoritmo 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 apresentada à rede e propagada 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 é calculada uma medida de erro, normalmente o erro médio quadrático (EMQ). 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, este erro diminui com o aumento do número de iterações e o procedimento converge para um conjunto estável de pesos. Na Figura 13 É mostrado um gráfico que representa a superfície de erro gerada no treinamento de uma rede treinada por *backpropagation*.




Figura 13 - Superfície de erro de treinamento *backpropagation*

Fonte: TATIBANA e KAETSU (2002).

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 e a desejada constitui o erro. A intenção do treinamento é buscar cada vez mais diminuir o valor deste erro. Para tal intuito, o valor dos pesos deve ser ajustado a cada nova iteração. A regra *backpropagation* proporciona 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 obtido, 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 esta 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, Δw_{ij} , ou seja, para um peso w_{ij} (o peso do nó i para o nó j), o seu 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:

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

δ_j : a diferença (erro) entre a camada de saída computada e a saída desejada do neurônio j ;

o_i : a saída do neurônio i , e

d_j : a saída desejada de n_j .

Para atualizar os pesos das camadas escondidas, considerando o peso w_{ki} de um neurônio n_i de uma camada escondida, o qual está ligado a outro neurônio n_k na camada anterior, tem-se :

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

Onde, δ/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 via w_{ki} .

A parâmetro η é denominado taxa de aprendizado e seu valor vai determinar o quão suavemente se dará à atualização dos pesos. Se η for grande, o valor de Δw_{ij} também o será e, conseqüentemente, os pesos sofrerão uma alteração mais brusca.

O algoritmo *backpropagation* apresenta alguns problemas quanto às dificuldades de aprendizado. Em superfícies muito complexas, o treinamento é muito lento e existe o risco da rede cair num mínimo local. Além disso, pode ocorrer *overfitting*, fenômeno que surge depois de um certo 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 citadas como: diminuir a taxa de aprendizado, adicionar nós na camada intermediária ou utilizar um termo de *momentum* e adicionar 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 que, segundo Brondino (1999), são:

- **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 uma função da diferença entre a saída desejada e aquela fornecida pela rede. Esta minimização se dá pelo ajuste dos pesos da rede. Um exemplo deste paradigma de aprendizado é o método *backpropagation*, apresentado anteriormente;

- **não supervisionado** - a rede aprende sozinha, sem uma mensagem de erro externa, ou seja, não há supervisão externa. É necessário que entradas

parecidas sejam apresentadas à rede, para que esta possa extrair características estatisticamente relevantes e criar classes de maneira automática; e

- **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.

Para dimensionar uma arquitetura de rede neural artificial que seja adequada para classificar uma dada situação de interesse deve-se definir o número de camadas que a constituirão, assim como o número de nós (ou neurônios) que contarão de cada camada da rede.

Durante o treinamento, a adaptação dos neurônios na camada de saída é simples, uma vez que a saída desejada de cada nó é conhecida.

De acordo com GONZALEZ e WOODS (1993) o número de elementos de processamento (nós) da primeira camada corresponde ao número de variáveis ou dimensão 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.

A definição do número de camadas escondidas também pode ser feita através de alguma regra que estabeleça o número de nós e até mesmo o número de camadas escondidas que uma rede possa ter. Um exemplo a ser citado é a regra ou teorema de Kolmogorov, que segundo SCHALKOFF (1992), diz que dada qualquer 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, ϕ pode ser obtida por uma rede neural de três camadas, tendo d elementos de processamento na camada de entrada, $(2d + 1)$ elementos de processamento na única camada escondida e c elementos de processamento em uma única camada de saída. Contudo, pode-se dizer que a

definição de quantas camadas escondidas e do número de nós dessas camadas depende da variabilidade dos padrões a serem classificados, ou seja, da complexidade dos dados.

A arquitetura de rede neural multicamadas que seja adequada para classificar um conjunto de dados específicos é estabelecida a partir da determinação prévia da dimensionalidade dos dados de entrada e das classes de interesse, os quais especificam, respectivamente, o número de elementos de processamento (nós) das camadas de entrada e de saída da rede.

Em linhas gerais, o critério de decisão adotado estabelece que, para um dado padrão de entrada, o elemento de processamento da camada de saída (associado a uma classe específica) que produzir o maior resultado numérico definirá a classe à qual o padrão será atribuído. Para algumas implementações de rede neural, além dessa saída ser maior para uma das classes, ela deve ter um valor superior a um limite de tolerância, para que o padrão possa ser atribuído àquela classe.

5 MATERIAL E MÉTODO

5.1: Caso de estudo: Plantas aquáticas

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).

Considerando os problemas ambientais e econômicos decorrentes da infestação por plantas aquáticas no reservatório de Salto Grande, na cidade de Americana-SP, pesquisadores da FCA/UNESP campus de Botucatu, realizaram uma série de levantamentos e estudos com o intuito de elaborar um plano de manejo para esse reservatório. Os dados levantados e estudos realizados foram utilizados no desenvolvimento da presente pesquisa. A Figura 14 mostra a área de estudo delimitada para este trabalho.




Figura 14 – Delimitação da área de estudos

5.2 - Material e Equipamentos

5.2.1 Dados Multiespectrais de Sensoriamento Remoto

Os dados multiespectrais utilizados no projeto, correspondem a imagens orbitais IKONOS II (bandas 1, 2, 3 e 4), abrangendo o reservatório de Salto Grande. As imagens foram disponibilizadas pela Companhia de Força e Luz do Estado de São Paulo. A data de aquisição da imagem em questão é de 26 de junho de 2004.

A imagem IKONOS da represa de Salto Grande é mostrada na Figura 15, na forma de uma composição colorida dos canais 4, 2,3 associados respectivamente as cores primarias vermelho, verde e azul.



Figura 15- Composição Colorida (RGB-423) para a imagem IKONOS da Represa de Salto Grande

A Figura 16 mostra um detalhe da imagem representada na Figura 15, destacando o problema de infestação por plantas aquáticas (indicadas por setas) na Represa de Salto Grande, Americana.




Figura 16- Detalhe de uma área de infestação por plantas aquáticas na represa de Salto Grande

5.2.2 Dados espaciais e descritivos (plantas aquáticas)

Os dados descritivos sobre as plantas aquáticas foram obtidos através de 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, que anteriormente foram diferenciadas somente com base nas diferenças espectrais, pudessem ser rotuladas.

Alguns pontos críticos quanto a ocorrência de plantas aquáticas foram fotografados, e a localização destes pontos é mostrada na Figura 17.




Figura 17 – Indicações de pontos com maior infestação de plantas aquáticas (fotografadas)

As Figuras 18, 19, 20, 21 e 22 mostram as áreas fotografadas no trabalho de reconhecimento da área, respectivamente para os pontos 1, 2, 3, 4, e 5, indicados na Figura 17 .



Figura 18 – Ponto 1: População mista de plantas aquáticas (braquiária e aguapé)



Figura 19 – Ponto 2: População mista de plantas aquáticas (braquiária e aguapé)



Figura 20 – Ponto 3: População mista de plantas aquáticas (braquiária e aguapé)



Figura 21 – Ponto 4: População mista de plantas aquáticas (braquiária e aguapé)



Figura 22 – Ponto 5: População mista de plantas aquáticas (Braquiária, Taboa e Aguapé)

Como evidenciado pelas figuras anteriores, as infestações são ocasionadas por populações mistas de espécies infestantes, principalmente, braquiária e aguapé, em diferentes proporções (variadas quantidades para cada uma das plantas). Apenas o ponto 5, além de braquiária e aguapé, apresenta também populações de taboa.

5.2.3 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 IV com 512 MB de memória RAM, no sistema operacional Windows.

Foram utilizados, basicamente três aplicativos para o processamento e análise das imagens: IDRISI, MATLAB e o ENVI. Para a reamostragem do tamanho do pixel, foi utilizado um programa computacional específico, desenvolvido em C++, disponível na FCT/UNESP.

▪ Reamostragem Espacial

O programa para realizar a reamostragem do tamanho do elemento de resolução, foi desenvolvido no ambiente de programação C++, disponível na

FCT/UNESP. Este programa é basicamente formado por um filtro média (passa baixa), que reamostra cada pixel da imagem utilizando 4 pixels vizinhos (soma os 4 pixels vizinhos e divide por 4), conseqüentemente também diminuindo o tamanho da imagem pela metade.

▪ **IDRISI**

O *software* IDRISI versão 3.2, é 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, visualização e análise de dados geográficos. Também possui um módulo de conversão vetor-matriz, pois ele trabalha com imagens e operações que permitem o cruzamento entre planos de informações.

O IDRISI trabalha de forma analítica matriz (imagem), cobrindo um amplo 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 à decisão por critérios múltiplos e por objetivos múltiplos; análise de incerteza e modelagem de simulação (EASTMAN, 1998).

▪ **MATLAB 6.1**

MATLAB é um software interativo de alta performance voltado para o cálculo numérico. Foi desenvolvido por “*The Mathworks*” e integra análise numérica, cálculo com matrizes, processamento de imagens e construção de gráficos em ambiente de fácil uso, uma vez que problemas e soluções são expressos como eles são escritos matematicamente, ao contrário da programação tradicional.

Um de seus aspectos mais poderosos é o fato de que a “linguagem Matlab” permite construir suas próprias funções e programas especiais para atender os objetivos de cada trabalho. Há também a possibilidade de agrupar tais funções em diretórios especiais, gerando assim caixas de ferramentas específicas.

Os comandos utilizados para o desenvolvimento do trabalho, a partir do software Matlab, estão descritos no APÊNDICE1.

▪ ENVI 3.5

O ENVI 3.5 (*Environment for Visualizing Images*) foi desenvolvido pela “RSI Mission Statement” e é um software para processamento de imagens multiespectrais que permite interações gráficas entre as funções e os dados com grande facilidade. Este software está sendo comercializado de duas formas: com e sem a linguagem de desenvolvimento IDL “Interactive Data Language”, a base do ENVI que permite rodar procedimentos complexos em modo batch (não-interativo) e agregar novas funcionalidades. O ENVI possui várias ferramentas para análise e extração de dados de Sensoriamento Remoto, trabalhando com análise espectral, imagens georreferenciadas, imagens com resolução espacial diferentes, Superfícies 3D, e inclui, no módulo de classificação, uma ferramenta para aplicação de redes neurais artificiais. Finalmente este software também inclui rotinas de novas programações e melhorias para ferramentas de programação existentes.

5.3 Desenvolvimento Proposto

O fluxograma mostrado na Figura 23 indica as atividades que foram desenvolvidas neste projeto, as quais são descritas na sequência.




Figura 23 - Fluxograma das atividades desenvolvidas neste projeto.

O desenvolvimento do projeto pode ser sistematizado em cinco etapas: a primeira se constituiu na exclusão da área de entorno do reservatório de Salto Grande, seguido da geração da imagem de textura e de índice de vegetação (planos de entrada para a RNA). A terceira etapa está relacionada com a produção das imagens multiescala; a quarta etapa na classificação das imagens multiescala utilizando uma rede neural artificial; e a quinta etapa na análise dos resultados e comparação entre as imagens multiescala classificadas.

5.3.1 Recorte da Imagem (Exclusão da Área Externa do Reservatório de Salto Grande)

A região do entorno da represa foi excluída, pois sua inclusão poderia dificultar a classificação do corpo d'água, uma vez que muitos alvos do entorno se confundiriam com as plantas aquática, que é o objeto da análise.

Para a exclusão da área do entorno à represa de Salto Grande, foi demarcado um polígono contornando o espelho d'água, sendo esse polígono transformado em imagem, utilizando recursos disponíveis no software IDRISI. Esse procedimento resultou então em uma imagem contendo apenas a delimitação da represa. Assim, as bandas multiespectrais da imagem IKONOS, foram multiplicadas pela imagem resultante do recorte do espelho d'água, utilizando recursos disponíveis no software MATLAB (Apêndice I). Porém, este software trabalha apenas com imagem de 8 bits (256 níveis de cinza), assim não foi feito nenhum procedimento com as imagens de 11 bits, visto que são poucos softwares que trabalham com imagens com 2048 níveis de cinza.

5.3.2 Geração das imagens de textura e índice de vegetação

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 realizada para a banda do infravermelho próximo (banda 4 do IKONOS), devido a sua aparente superioridade em

representar a variação espectral e espacial da vegetação (no caso, plantas aquáticas), já conhecida e comprovada mediante comparação visual com as demais bandas.

O operador adotado foi avaliado por GALO e NOVO (1998b) e está implementado no IDRISI, sob a designação de índice de fragmentação (F). Esse índice é calculado pela expressão:

$$F = (n-1) / (c-1) \quad (11)$$

Na qual n é o número de pixels com diferentes atributos (valores radiométricos atribuídos aos pixels) presentes em uma janela de dimensão c (no caso da janela 3x3, c é igual a 9).

O índice de fragmentação é uma medida local de textura e indica que, se todo e qualquer atributo não se repete na janela, o valor calculado para o pixel central será máximo ($F = 1,0$). Caso contrário, se todos os pixels da janela tiverem o mesmo atributo ($F = 0$), não ocorre variabilidade espacial na região analisada de 3x3 pixels.

A utilização desse operador de contexto produziu uma imagem representando os indicadores texturais gerados a partir da banda 4 (infravermelho próximo). Tal imagem foi incluída na composição dos dados de entrada para a classificação desenvolvida pela rede neural artificial, para facilitar a diferenciação entre as classes de plantas e água na imagem.

A utilização de uma imagem de índice de vegetação se justifica em função do próprio comportamento espectral das plantas aquáticas.

Para minimizar a variabilidade causada pelos fatores externos, a reflectância espectral da cobertura vegetal, tem sido transformada e combinada em vários índices de vegetação, sendo que os mais comumente empregados utilizam a informação contida nas reflectâncias referentes às regiões do vermelho e do infravermelho próximo, as quais são combinadas na forma de razões.

As técnicas de realce de imagem por meio de índices de vegetação aumentam o brilho das áreas vegetadas, melhorando a aparência da distribuição espacial de informações das imagens tornando-as de fácil interpretação visual e computacional (SHIMABUKURO, 1991).

Os índices de vegetação são combinações aritméticas simples baseadas no contraste entre as respostas espectrais da vegetação na região do vermelho e do infravermelho próximo. Índices de vegetação podem ser entendidos como razões matemáticas entre as respostas espectrais de bandas. Um dos índices de vegetação amplamente utilizado em análises da vegetação é o chamado NDVI (*Normalized Difference Vegetation Index*). O índice de vegetação da diferença normalizada utiliza uma combinação simples das bandas do vermelho e do infravermelho próximo, de acordo com EASTMAN (1998), é expresso como a diferença entre a banda do infravermelho próximo (IVP) e vermelho (VER), normalizada pela soma das bandas, o NDVI é expresso pela seguinte fórmula:

$$NDVI = (IVP - VER)/(IVP + VER) \quad (12)$$

No qual:

IVP = resposta espectral do pixel na banda do infravermelho próximo (banda 4);

VER= resposta espectral do pixel na banda do visível (banda 3).

A partir dessa equação foi gerada uma imagem do índice de vegetação da diferença normalizada (NDVI) para a imagem IKONOS representando a represa de Salto Grande. Esta imagem também foi utilizada na composição dos dados de entrada para rede neural artificial.

5.3.3 Geração das imagens multiescala

Na geração das imagens multiescala foi utilizado um programa desenvolvido na linguagem C++ que utiliza um filtro passa baixa, no qual calcula a média entre quatro pixels vizinhos, assim reamostrando a imagem e diminuindo o número de pixels em 2 vezes, para cada nível de resolução no qual é aplicado. Assim, uma

imagem com 4 metros de resolução espacial, resultará em uma imagem de 8 metros de resolução; uma imagem de 8 metros de resolução espacial, resultará em uma imagem de 16 metros de resolução espacial, e assim sucessivamente (segue estrutura piramidal 2ⁿ conforme Figura 7 - página 31).

5.3.3 Definição das classes de interesse para a classificação

Os esquemas de classificação constituem os meios usados para organizar a informação espacial de uma maneira lógica e ordenada e possibilita, para quem produz o mapa, caracterizar as feições da paisagem e, para o usuário do mapa, reconhece-las (CONGALTON e GREEN, 1999). Nesse sentido, uma primeira questão a ser tratada é a definição das classes de interesse.

Inicialmente, foi feita uma definição dessas classes levando em consideração apenas às diferenças espectrais percebidas em cada banda espectral da imagem IKONOS e, a partir dessa definição, as classes foram rotulados através de levantamento de campo realizado na represa.

As classes definidas a princípio foram: Agua1, Agua2, Plantas1, Plantas2 e Fundo. Na Tabela 2 são mostradas as classes definidas a partir das diferenças espectrais, suas respectivas cores e partes da imagem exemplificando cada uma das classes. Posteriormente, foi inserida uma descrição de cada classe, possibilitada pelo levantamento de campo. A composição colorida usada pra mostrar as diferenças espectrais na cena resultaram da associação dos canais RGB, respectivamente às bandas 4 (IVP), 2 (G) e 3 (R) .

Tabela 2 – Classes de interesse

Classes	Cor (composição colorida)	Figura	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
Fundo	Coloração escura (preto)		Fundo da imagem

Assim, definidas as classes, foram obtidas então as classes de saída de rede neural artificial (Plantas1, Plantas2, Agua1, Agua2, Agua3 e Fundo).

Os planos de entrada foram definidos pelas bandas multiespectrais da imagem IKONOS (1, 2, 3 e 4), e pelas imagens de textura e índice de vegetação, totalizando 6 planos de entrada.

5.3.5 Classificação das imagens

Todos os procedimentos para a classificação das imagens foram feitos no software ENVI 3.6, utilizando ferramentas específicas para Redes Neurais Artificiais. Cada uma das imagens multiescala foi classificada separadamente, de modo que todo o procedimento de classificação foi repetido quatro vezes. Os passos seguidos para a classificação da imagem, foram:

- 1- Coleta de amostras de treinamento para a classificação dos dados
- 2- Definição da arquitetura e Treinamento da RNA
- 3- Classificação a partir da RNA treinada

- **Coleta de amostras para treinamento da RNA**

Para que possa ser feita uma classificação supervisionada, é preciso selecionar alguns conjuntos de pixels para servir de amostras representativas das classes. No software ENVI essas amostras são chamadas de Regiões de Interesse (ROI). Os dados referentes a cada classe foram coletados de acordo com as diferenças espectrais percebidas, e como já foi dito, posteriormente foi feita uma rotulação para cada uma das classes definidas.

- **Definição da arquitetura e treinamento da RNA**

Definidas as classes e coletadas as amostras representativas dessas classes, o próximo passo para a classificação é definir a arquitetura básica da RNA que será treinada. Assim, uma vez que as imagens que constituem os planos de entrada para a rede neural são as bandas espectrais 1, 2, 3 e 4 da imagem IKONOS, a imagem de textura gerada a partir da banda 4, e a imagem de índice de vegetação (NDVI), sendo a saída da RNA compostas pelas classes: plantas1, plantas2, água1, água2, água3 e fundo; a arquitetura inicial da rede fica estabelecida em seis elementos na camada de entrada e seis na camada de saída. O número de camadas escondidas foi definido por tentativa e erro, e o número de camadas escondidas que resultaram em uma classificação consistente foram de 2 camadas escondidas, porém no ENVI não é possível modificar o número de elementos das camadas escondidas, apenas o número de camadas.

Após a definição da arquitetura básica da RNA (planos de entrada e classes de saída) e o número de camadas escondidas o *software* ENVI solicita a definição de alguns parâmetros para a classificação, estes são:

- **Função de ativação** : para verificar se um elemento de processamento é ou não ativado por uma entrada específica, foi usada uma função sigmóide (logística).
- **Limiar de contribuição do treinamento**: esse limiar determina o tamanho da contribuição do peso interno com respeito ao nível de ativação do nó. É usado para ajustar as mudanças ao peso interno de um nó e pode variar entre 0 e 1.
- **Taxa de Treinamento**: a taxa de treinamento determina a magnitude do ajuste para os pesos, sendo que seu valor pode variar de 0 a 1. Uma taxa mais alta acelerará o treinamento, mas também aumentará o risco de oscilações ou não-convergência do resultado do treinamento.
- **Taxa de Momento**: varia de 0 a 1. Uma taxa de momento maior que zero permite fixar uma taxa de treinamento mais alta e sem oscilações, viabilizando mudanças de peso mais adequadas.
- **Critério de término de treinamento baseado no Erro Médio Quadrático (RMS)**: valor do erro no qual o treinamento deve ser finalizado (máxima diferença entre o valor esperado e o valor de saída). Quando o RMS, que é mostrado durante o treinamento, estiver abaixo do valor estabelecido para o erro, o treinamento pára mesmo se o número de iterações previstas não for completado, e então a classificação será efetuada.
- **Número de Camadas Escondidas**: para classes linearmente separáveis o número de camadas escondidas é zero, ou seja, a RNA é caracterizada apenas pela camada de entrada e a camada de saída. Quando as classes não são linearmente separáveis é necessário introduzir camadas escondidas cujo número depende da complexidade do conjunto de dados.
- **Número de iterações do treinamento**: número de ciclos de treinamento necessários para minimizar o erro desejado.

- **Limiar de ativação** : valor que define se um pixel será ou não classificado.

Se o valor de ativação do pixel que é classificado for menor que este valor de limiar, então este pixel não será classificado.

No presente trabalho, para taxa de treinamento foi fixado um valor de acordo com a recomendação encontrada na literatura especializada e alguns experimentos anteriores. Em GALO (2000), foram recomendados os valores de 0,01 para a taxa de treinamento e 0,05 para o erro admissível (erro de treinamento). Outro componente importante do treinamento é estabelecer um critério de término das iterações do algoritmo de aprendizagem.

Os outros parâmetros foram definidos a partir do treinamento da imagem original. Assim, se os parâmetros resultassem em um erro baixo, estes seriam aplicados às outras imagens de menor resolução espacial.

- **Classificação a partir da Rede Neural Artificial treinada**

Através do comportamento da rede neural durante o treinamento pôde-se avaliar sua adequação à classificação de dados. Assim, a partir dos resultados dos erros para as arquiteturas testadas, foi avaliado se a RNA era adequada ou não para a classificação dos dados da imagem. Esse procedimento foi repetido para cada uma das imagens multiescala (4, 8,16 e 32 metros)

5.3.6 Análise dos resultados

A análise dos resultados das classificações das imagens multiescala foi feita a partir de uma tabulação cruzada (função disponível no IDRISI), a qual compara as imagens em termos de concordância espacial entre as classes, e resulta em dados numéricos (proporção de pixels classificados em cada classe e índice de concordância *Kappa*) e uma imagem, que proporciona mostrar onde a classe temática alterou-se e onde se manteve.

O índice de concordância *Kappa* expressa a diferença entre a coincidência das classes resultantes de uma classificação, com os dados de referência, cujos valores são representados em uma matriz de confusão, na qual as concordâncias entre as classes são apresentadas na diagonal de matriz, e a concordância casual é dada pelo produto dos valores marginais das linhas e colunas. Esta medida é calculada por:

$$K = \frac{\left(\sum_{i=1}^r X_{ii} / N \right) - \left[\sum_{i=1}^r (X_{i+} * X_{+i}) / N^2 \right]}{1 - \sum_{i=1}^r \left(X_{i+} * X_{+i} / N^2 \right)} \quad (13)$$

onde: $r = o$ número de linhas da matriz;

X_{ii} - número de observações na linha i e coluna i ;

X_{i+} e X_{+i} - totais marginais da linha i e coluna i , respectivamente;

N - número total de observações (COHEN, 1960; citado por CONGALTON et al., 1983).

Os resultados numéricos da tabulação cruzada permitem avaliar quais classes tiveram uma maior ou menor quantidade de pixels coincidentes nos três níveis de resolução das imagens classificadas, e também o índice de concordância *Kappa*.

Os mapas temáticos resultantes da classificação das imagens multiescala foram cruzados dois a dois (4 e 8 m, 4 e 16 m e 4 e 32 m), tendo como referência a imagem de 4 metros de resolução. Para essa comparação foi necessário redefinir o tamanho do pixel das imagens resultantes das classificações multiescala para a mesma resolução original (8, 16 e 32). Essa readequação do tamanho do pixel para cada uma das imagens, para a resolução de 4 metros, foi feita a partir da replica de seus pixels vizinhos.

As tabulações cruzadas realizadas possibilitaram a comparação entre os as classes, mais precisamente “água1” e “água2”, e também “plantas1” e “plantas2”, resultando em novas imagens mostrando o grau de associação de cada *pixel* da imagem para as classes de saída analisadas.

O resultado da tabulação cruzada pode ser expresso também como um mapa temático que permite identificar, de maneira objetiva, onde houve alteração na classe temática e onde se manteve.

6 RESULTADOS: APRESENTAÇÃO E ANÁLISE

6.1 Região de interesse

O resultado do recorte da área de interesse é mostrado na Figura 24, na forma de uma composição colorida das bandas 4 (IVP), 2 (verde) e 1 (azul) associados respectivamente aos cores primárias vermelho, verde e azul. Nessa composição colorida, as plantas aquáticas são mostradas em tons avermelhados, devido ao fato da banda do IVP (4) estar associada ao canal do vermelho (R), e da vegetação apresentar uma resposta espectral alta no infravermelho próximo. Com a associação da cor azul (B) à banda 1 (azul), os tipos de água ficaram bem definidos, pois no intervalo espectral da luz azul, a água responde de acordo com a quantidade de sedimentos em suspensão e a profundidade do corpo d' água. Nesse estudo, a água com maior quantidade de sedimentos e menor profundidade resultou em um tom azul claro, e a água com menor quantidade de sedimentos e maior profundidade, está apresentada na figura em tons de azul escuro (menor resposta).




Figura 24 - Composição colorida IKONOS, caracterizado o corpo d'água

Com base nas variações espectrais percebidas, as classes foram definidas, e então, rotuladas a partir de um trabalho de reconhecimento da área na represa de Salto Grande. Estas classes deverão ser caracterizadas em função de sua real ocorrência e já foram descritas na Tabela 2, na página 63.

6.2 Dados espaciais: planos de entrada para a RNA

O resultado do processamento que produziu a imagem de textura a partir da banda 4 (infra-vermelho próximo) da imagem IKONOS, é mostrado na Figura 25. Este procedimento foi feito para cada uma das imagens (4, 8, 16 e 32 metros de resolução espacial).




Figura 25 – Imagem textura da banda do IVP

Analisando a Figura 25, pode-se perceber as diferenças nos tons da imagem. Os tons mais escuros representam uma maior variabilidade do fenômeno em questão (plantas aquáticas). Os tons mais claros representam as áreas com menos variações, formadas pela água do reservatório.

A Figura 26 mostra o resultado do processamento que gerou a imagem utilizando a expressão: $NDVI = (IVP - VER) / (IVP + VER)$, que define o índice de vegetação da diferença normalizada (NDVI). Como para a imagem de textura, a imagem NDVI foi gerada para cada resolução individualmente.

As partes mais claras na cena representam as áreas de vegetação (plantas aquáticas), e as partes mais escuras, a água.



Figura 26- Imagem índice de vegetação para o reservatório de Salto Grande

As imagens processadas (Textura e NDVI) foram utilizadas como plano de entrada para a rede neural, com o propósito de melhorar a diferenciação das classes, e consequentemente o resultado da classificação.

6.3 Imagens Multiescala

A redução sistemática da resolução espacial da cena original IKONOS, resultou em imagens com 8, 16 e 32 metros de resolução espacial. Essa reamostragem do tamanho do pixel foi feita para as quatro bandas da imagem IKONOS, e as imagens de textura e índice de vegetação (planos de entrada da RNA), resultando em seis imagens com quatro resoluções.

A Figura 27 mostra as imagens (banda 3- vermelho) obtidas nesse processo explicitando sua estrutura piramidal.




Figura 27- Pirâmide de imagem multiescala para a área de interesse

Para avaliar a influência da redução da resolução espacial das imagens na discriminação das classes de interesse, foram elaborados gráficos mostrados na Figura 28, indicando a média dos valores de brilho calculada a partir das amostras representativas de cada classe, obtidas para as quatro bandas espectrais Ikonos.

Como indica a Figura 28, não se percebe diferenças significativas nas médias dos valores de brilho para as classes de plantas nas quatro bandas espectrais. Esta diferenciação só é perceptível para as classes Água1 e Água2, na banda do verde, para a imagem de resolução original (4 metros de resolução espacial).




Figura 28 - Média dos valores de brilho obtidas a partir das amostras representativas das classes para as imagens multiescala Azul (a), verde (b), vermelho (c), IVP (d).

6.4 Resultados da classificação utilizando RNA

6.4.1 Arquiteturas, parâmetros selecionados e tempo de processamento para as RNA

Serão descritas as arquiteturas das redes neurais selecionadas para a classificação da imagem do reservatório de Salto Grande, juntamente com os parâmetros para cada uma das redes testadas e o tempo de processamento.

A arquitetura básica definida para a RNA para a imagem original, e repetidos para as imagens de menor resolução foi de:

- **Camada de entrada:** 6 planos de informação (banda1, banda2, banda3, banda4, textura e NDVI).
- **Camada escondida:** 2 camadas, definidas a partir de tentativa e erro.
- **Camada de saída:** 6 classes (plantas1, plantas2, água1, água2, água3 e fundo).

A dificuldade maior foi encontrar os parâmetros adequados para que a RNA fosse capaz de diferenciar e classificar cada uma das classes corretamente.

Os parâmetros considerados adequados foram definidos a partir do treinamento da imagem original. A Tabela 3 mostra os parâmetros testados para a classificação, juntamente com o erro médio quadrático final para cada uma das RNA testadas para a imagem original.

Tabela 3 - Parâmetros, tempo de processamento e EMQ final para a imagem original (4 m)

	Limiar de treinamento	Taxa de treinamento	Taxa de momento	Erro médio Quadrático	Camadas escondidas	Nº de iterações	RMS final
RNA1	0,9	0,01	0,3	0,05	3	400	0,064
RNA2	0,8	0,01	0,2	0,05	3	500	0,052
RNA3	0,7	0,01	0,1	0,001	2	600	0,021
RNA4	0,8	0,01	0,3	0,001	2	800	0,016
RNA5	0,8	0,01	0,2	0,001	2	1000	0,014

O número de camadas escondidas foi escolhido após vários testes realizados com a imagem de resolução original (por tentativa e erro), porém o software ENVI, permite apenas modificar o número de camadas, e não o número de elementos de processamento em cada uma delas (não é mostrado durante os processamentos).

A rede que resultou em um menor erro médio quadrático foi a arquitetura de da rede RNA5 que possuía duas camadas escondidas e o maior número de iterações (1000).

6.4.2 Desempenho da rede neural na classificação dos dados

Os resultados do desempenho da rede neural que apresentou o menor erro médio quadrático são apresentados a seguir. Primeiramente para a imagem original (4 metros de resolução), na qual a rede foi treinada, e para as imagens de 8, 16 e 32 metros de resolução espacial.

6.4.2.1 Imagem de resolução espacial original (4 metros)

Para a imagem original, como já foi especificada, a arquitetura que resultou em um menor erro médio quadrático foi a RNA5, porém esse erro só foi obtido com um maior número de iterações. Assim, para 1000 iterações, com um tempo de processamento de aproximadamente 220 minutos, foi obtido um erro final de 0,014.

A Figura 28 mostra o comportamento do erro no treinamento da rede RNA5 para a imagem original, com 1000 iterações.




Figura 29- Evolução do EMQ durante o treinamento para a imagem de 4 metros de resolução espacial

A partir da Figura 29, pode-se observar uma queda brusca no erro na iteração número 100, estabilizando durante as próximas 40 iterações. Na iteração número 190 observa-se outra queda acentuada, com o erro estabilizando próxima a iteração número 600 e finalizando o treinamento com 1000 iterações, com um erro final de 0,014.

6.4.2.2 Imagem amostrada com resolução de 8 metros

Para a imagem de 8 metros de resolução espacial foram utilizados os mesmos parâmetros da RNA5 da imagem original, inclusive o mesmo número de iterações (1000). O tempo de processamento foi de 100 minutos, resultando em

um erro médio quadrático final após 1000 iterações de 0,007. O comportamento do erro durante o treinamento para a imagem com resolução espacial amostrada para 8 metros é mostrado na Figura 30.




Figura 30- Evolução do EMQ durante o treinamento para a imagem de 8 metros de resolução espacial

Na Figura 30, pode-se observar que perto da iteração 40 o erro teve uma alta, porém logo em seguida teve uma queda, até se estabilizar perto da iteração número 800, chegando ao final das iterações (1000) com um erro relativamente baixo (0,007).

6.4.2.3 Imagem amostrada com resolução de 16 metros

Para a imagem amostrada para 16 metros de resolução espacial, foram também utilizados os mesmos parâmetros da RNA5 (que foram testados na imagem original), porém foi necessário um maior número de iterações para o treinamento. A rede não conseguiu discriminar todas as classes com um treinamento de 1000 iterações, além do que o erro médio quadrático para 1000 iterações foi alto (0,1306). Assim, foi feito um novo treinamento utilizando 2000 iterações. A Figura 31 mostra o comportamento do erro durante o treinamento para a imagem de resolução espacial de 16 metros, para as 2000 iterações, que foi efetivamente utilizada.




Figura 31 – Evolução do EMQ durante o treinamento para a imagem de 16 metros de resolução espacial

A partir da Figura 31, pode-se perceber que o erro do treinamento iniciou em 0,6 o qual comparado com o erro para as imagens de 4 e 8 metros de resolução espacial, pode ser considerado muito alto (respectivamente, 0,35 e 0,32). No gráfico, foi registrada uma queda brusca do erro até a iteração número 300, estabilizando-se na iteração número 1750, no qual sofreu outra queda, concluindo as 2000 iterações com um erro de 0,017.

O número de iterações, tempo de processamento e o erro médio quadrático final para os dois treinamentos, utilizando os parâmetros definidos a partir da imagem original para a imagem de 16 metros de resolução espacial, é apresentado na Tabela 4.

Como pode ser observado na Tabela 4, com 1000 iterações a rede finalizou com um erro considerado alto, comparado aos erros obtidos para as imagens de resolução espacial de 4 e 8 metros.

Tabela 4 - Número de iterações, tempo de processamento e erro médio quadrático final para a imagem de 16 metros de resolução espacial

Nº de iterações	Tempo de processamento	RMS final
1000	40 minutos	0,1306
2000	75 minutos	0,0172

6.4.2.4 Imagem amostrada com resolução de 32 metros

Para a imagem de resolução espacial de 32 metros, foram também utilizados os mesmos parâmetros da RNA5 que foram testados na imagem original, porém foi necessário testar uma maior quantidade de iterações (como na imagem de 16m), pois com 2000 e 3000 iterações realizadas, o erro resultante foi considerado alto, (0,1262 e 0,1085 respectivamente) comparado aos erros obtidos para as imagens de 4 e 8 metros de resolução (0,014 e 0,007 , respectivamente).

A Figura 32 mostra o comportamento do erro durante o treinamento para a imagem de resolução espacial de 32 metros, utilizando 5000 iterações.




Figura 32 – Evolução do EMQ durante o treinamento para a imagem de 32 metros de resolução espacial

Na Figura 32, como na imagem de 32 metros de resolução espacial, o erro iniciou acima de 0,6, sofrendo uma queda brusca até a iteração número 350, a

partir daí foi caindo e na iteração número 2500, sofreu outra queda, estabilizando-se, e finalizando as 5000 iterações com um erro de 0,016.

A Tabela 5 mostra o número de iterações, tempo de processamento e o erro médio quadrático final para os três treinamentos (2000, 3000 e 5000), utilizando os parâmetros definidos a partir da imagem original para a imagem de 32 metros de resolução espacial.

Tabela 5 - Número de iterações, tempo de processamento e erro médio quadrático final para a imagem de 32 metros de resolução espacial

Nº de iterações	Tempo de processamento	RMS final
2000	10 minutos	0,1262
3000	15 minutos	0,1085
5000	30 minutos	0,016

6.4.3 As cenas classificadas

A seguir são apresentados os resultados das classificações resultantes da aplicação da RNA5 treinadas para as imagens de resolução espacial de 4 metros (original), 8 16 e 32 metros (reamostradas).

Imagem original (4 metros de resolução espacial)

A Figura 33 mostra o resultado da classificação para a imagem de 4 metros de resolução (original). A partir da análise visual, pode-se perceber que as classes foram bem discriminadas e a classificação foi realizada com sucesso. A RNA conseguiu discriminar e diferenciar bem as plantas, também as diferenças entre as águas.




Figura 33 - Imagem de 4 metros de resolução espacial classificada

Imagem de 8 metros de resolução espacial

A Figura 34 mostra a classificação resultante da aplicação da RNA5 à imagem de 8 metros de resolução espacial. Nessa imagem também os tipos de plantas e os tipos de água foram diferenciados. Porém devido à reamostragem da imagem, alguns pixels que na imagem de 4 metros foram classificados como Planta1, nessa imagem de 8 metros, foram classificados como Planta2. Na diferenciação entre os 3 tipos de água, a rede neural teve um bom desempenho comparada com a classificação da imagem original, considerando que a resolução espacial da imagem foi reduzida para 8 metros.




Figura 34 - Imagem de 8 metros de resolução espacial classificada

Imagem de 16 metros de resolução espacial

A Figura 35 mostra a classificação da imagem com resolução espacial reamostrada para 16 metros. Como na imagem de 8 metros, devido a reamostragem dos pixels na imagem, a quantidade de pixels pertencentes a classe Planta2 diminuiu, classificados como Planta1 (menor resposta espectral comparada a classe Planta2). Apesar disso, as classes foram bem diferenciadas, resultando em um mapa temático representativo do reservatório de Salto Grande.




Figura 35 - Imagem de 16 metros de resolução espacial classificada

Imagem de 32 metros de resolução espacial

A Figura 36 mostra o resultado da classificação da imagem de 32 metros de resolução espacial. Devido ao efeito da reamostragem do tamanho do pixel, e da maior dificuldade em coletar amostras, as classes Planta1 e Planta2 ficaram confusas. Também houve confusão entre os tipos de água (Água1 e Água 2). A diferenciação entre planta e água ocorreu normalmente, a confusão maior está na diferenciação entre as subclasses, tipos de plantas e tipos de água.

Devido a menor resolução espacial da imagem, a aparência do mapa temático resultante da classificação não foi satisfatória, comparado com o mapa obtido a partir da imagem de 4 metros de resolução espacial (original), já que esta foi submetida a um processo de suavização.




Figura 36 - Imagem de 32 metros de resolução espacial classificada

Com relação ao uso do *software* ENVI, este apresentou flexibilidade na criação e na representação dos dados apresentados a RNA para os quatro níveis de resolução da imagem, resultando assim em bons mapas temáticos da região de interesse, comparados a verdade terrestre (verificada a partir do trabalho de campo). O mapa temático obtido a partir da classificação da imagem de 4 metros, está apresentado no Apêndice II.

6.5 Análise dos resultados (tabulação e classificação cruzada)

O procedimento de tabulação cruzada permite comparar as duas classificações em termos de concordância espacial entre as classes, resultando em dados numéricos (proporção de pixels coincidentes inseridos em cada classe e índice de concordância *Kappa*) e uma imagem, que proporciona visualizar onde a classe temática alterou-se e onde se manteve.

Para a tabulação cruzada, é necessário tomar uma imagem como referência. Como a classificação da imagem utilizando a imagem original, foi a que obteve a melhor diferenciação das plantas aquáticas, incluindo os tipos, e também na diferenciação da água, a imagem resultante da classificação da imagem de 4 metros de resolução foi tomada como referência. Os resultados da tabulação cruzada (dados numéricos, índice *Kappa* e imagens) entre as imagens de 4 e 8 metros de resolução espacial, 4 e 16 metros de resolução espacial e 4 e 32 metros de resolução espacial são mostrados a seguir.

O resultado em termos percentuais da tabulação cruzada entre as imagens de 4 e 8, 4 e 16, 4 e 32 metros de resolução espacial, tomando a cena original (4 metros) como referência, é mostrado na Tabela 6, considerando as classes que representam plantas aquáticas e água. Os números em **negrito** mostram os pixels coincidentes nas classificações. Os números em **vermelho** representam as classes que obtiveram maior proporção de pixels inseridos em classes diferentes nas duas cenas.

Tabela 6 – Proporção de pixels coincidentes (%) nas classificações resultantes da tabulação cruzada entre as imagens de 4 e 8, 4 e 16, 4 e 32 metros de resolução espacial

classes	Planta 1			Planta 2			Água 1			Água 2			Água 3		
	4-8	4-16	4-32	4-8	4-16	4-32	4-8	4-16	4-32	4-8	4-16	4-32	4-8	4-16	4-32
Planta1	79,2	89,8	43,5	33,9	55,9	17,3	0,8	6,55	1,09	0,62	1,60	0,62	21,3	20,5	4,35
Planta2	2,54	2,7	32,0	62,4	40,1	71,1	0,00	0,05	2,52	1,97	2,05	2,49	16,1	19,0	21,8
Água1	16,3	2,9	9,97	1,2	0,16	1,21	97,7	90,8	83,2	4,60	3,37	1,77	1,86	2,60	5,47
Água2	0,97	0,46	5,6	1,7	0,92	4,47	1,18	2,52	12,3	92,4	92,6	93,2	17,7	11,4	22,5
Água3	0,38	0,01	0,1	0,3	0,90	0,63	0,00	0,00	0,00	0,30	0,08	1,22	42,7	42,7	40,6
Fundo	0,49	4,04	8,6	0,2	2,02	5,17	0,17	0,00	0,82	0,04	0,24	0,58	0,12	3,60	5,12

De acordo com a Tabela 6, as classes que obtiveram uma menor quantidade de pixels inseridos em outras classes para a tabulação entre as imagens de 4 e 8 metros de resolução, tendo uma porcentagem alta de pixels coincidentes

foram: Água1 (97,7%) e Água2 (92,4%). Isso acontece pelo fato dessas classes apresentarem diferenças espectrais acentuadas, comparando com as classes Planta1 e Planta2, que apresentam características muito similares. A classe Água3, foi a que resultou em menor proporção de pixel coincidentes (42,7%) porém, como esta classe não é muito representativa na cena (possui uma quantidade pequena de pixels), a mudança mais representativa foi na classe Planta2, que obteve apenas 62,4% de pixels espacialmente coincidentes.

Para a tabulação entre as imagens de 4 e 16 metros de resolução, as classes que obtiveram uma maior quantidade de pixels coincidentes foram: Água2 (92,6%) e Água1 (90,8%), devido a acentuada diferença dessas classes em relação as outras, como dito anteriormente. A classe Planta2 foi a que obteve uma menor quantidade de pixels (em porcentagem) classificados corretamente (40,1%).

Para a tabulação entre as imagens de 4 e 32 metros de resolução espacial, as classes que obtiveram uma menor quantidade de pixels inseridos em outras classes, tendo uma porcentagem alta de pixels classificados coincidentes foram: Água2 (93,2%) e Planta2 (71.1%). A classe Planta1, e a classe Água3 foram as que obtiveram uma menor quantidade de pixels (em porcentagem) classificados corretamente, respectivamente 43,5 % e 40,6 %.

6.5.1 Índice Kappa

Uma outra maneira de verificar a confusão entre as classes é através do grau de concordância (*Kappa*). Tomando a imagem classificada a partir dos dados originais (4 metros de resolução espacial) como referência, o resultado do índice kappa para as imagens 4-8, 4-16 e 4-32 é mostrado na Tabela 7.

Tabela 7 – Índice de concordância *Kappa* (4-8, 4-16 e 4-32 metros de resolução espacial)

	4-8	4-16	4-32
Planta1	0,7890	0,8955	0,4293
Planta2	0,6217	0,4000	0,7070
Água1	0,9776	0,9048	0,8252
Água2	0,9216	0,9234	0,9297
Água3	0,4268	0,4270	0,4062
Fundo	0,9876	0,9877	0,9792
Global	0,9369	0,9189	0,8808

Para a imagem de 4-8 metros, as classes que obtiveram uma maior porcentagem de pixels coincidentes foram: Fundo (0,9876), Água1 (0,9776) e Água2 (0,9216), como já indicado na Tabela 6. Também como verificado anteriormente, as classes Planta2 e Água3 apresentaram uma concordância considerada baixa, respectivamente de 0,6217% e 0,4268%. O índice de concordância global entre as imagens classificadas a partir dos dados de 4 e 8 metros de resolução espacial foi de 0,9369.

Para a tabulação entre as imagens de 4 e 16 metros as classes que obtiveram uma maior quantidade de pixel coincidentes foram: Fundo (0,9877%), Água2 (0,923) e Água1 (0,9048) como para a imagem formada pela tabulação cruzada entre 4 e 8 metros. Também como verificado anteriormente, a classe Planta2 apresentou uma concordância considerada baixa (0,4000). O valor do índice de concordância global foi de 0,9189, sendo considerado satisfatório, porém um pouco mais baixo que o valor obtido para a imagem de 8 metros de resolução espacial (*Kappa* = 0.969).

Para as imagens 4 e 32 metros de resolução espacial, as classes que apresentaram uma maior quantidade de pixels coincidentes nas duas cenas, foram: Fundo (0,9792), Água2 (0,9297) e Água1 (0,8252), como foi verificado anteriormente para as outras imagens. As classes Planta1 e Água3 apresentaram

uma concordância espacial baixa (respectivamente 0,4293 e 0,4062), comparadas com as outras classes. O valor do índice de concordância *kappa* global foi de 0,880, consideravelmente menor quando comparado as imagens de 8 e 16 metros de resolução espacial, que obtiveram respectivamente os valores de 0,969 e 0,9189, porém ainda considerado bom.

6.5.2- Imagens resultantes da Tabulação e Classificação cruzada

Para uma melhor percepção das diferenças entre as classificações das imagens de 4 e 8 metros, 4 e 16 e 4 e 32 metros de resolução, as Figuras 37, 38 e 39 mostram as imagens resultantes da tabulação cruzada entre essas imagens respectivamente.

Na Figura 37 é representada a imagem resultante da tabulação entre as imagens de 4 e 8 metros de resolução. Porém só estão representadas as classes que indicam menor concordância espacial entre as classes, ou seja, as que apresentaram uma maior confusão. Essas classes foram: Planta1/Água1 (16.36); Planta2/Planta1 (33.92%); Água1/Água2 (1.18%), Água2/Água1 (4.60%); Água3/Planta1 (21.38%) e Fundo/Água1 (0.093).




Figura 37 – Tabulação Cruzada para as imagens de 4 e 8 metros de resolução espacial

A Figura 38 mostra a imagem resultante da tabulação cruzada entre as imagens de 4 e 16 metros de resolução espacial. Como para a tabulação das imagens 4 e 8 metros, estão em evidência apenas as classes que obtiveram uma menor coincidência espacial nas duas imagens




Figura 38 – Tabulação Cruzada 4 e 16 metros de resolução espacial

Analisando a Figura 38, pode-se perceber que a menor concordância espacial é entre as classes Planta2 (4 metros) e Planta1 (16 metros), já que o aumento da resolução espacial, a rede neural aparentemente não conseguiu separar os tipos de plantas aquáticas.

As classes que obtiveram uma maior confusão de acordo com a Tabela 6, e representadas na Figura 37, foram: Planta1/Fundo (1/6) com a porcentagem de 4,04%; Planta2/Planta1 (2/1), 55,93%; Água1/Planta1 (3/1), 6,55%, Água2/Água1 (4/3), 3,37%; Água3/Planta1 (5/1), 20,53% e Fundo/Planta1 (6/1), 0,117.

A Figura 39 mostra a imagem resultante da tabulação cruzada as imagens de 4 e 32 metros de resolução espacial. Como para as tabulações anteriores, foi gerada uma imagem com 36 classes.




Figura 39 – Tabulação Cruzada 4 e 32 metros de resolução espacial

Analisando a Figura 39, pode-se perceber que a menor coincidência ocorreu entre Planta1 (original) e Planta 2 (32 metros). Isso também pode ser atribuído à redução na resolução espacial, que faz com que o classificador não consiga separar as diferenças entre os tipos de plantas aquáticas. As classes que obtiveram uma maior confusão nestas classificações de acordo com a Tabela 6 (grifadas em vermelho na tabela), foram: Planta1/Planta2 (1/2) com a porcentagem de 32,09; Planta2/Planta1 (2/1), 17,37%; Água1/Água2 (3/4), 12,34%, Água2/Planta2 (4/2), 2,49%; Água3/Água2 (5/4), 22,57% e Fundo/Planta1 (6/1), 0,13.

6.5.3 Análise do desempenho das classificações para as imagens multiescala

A imagem classificada utilizando os dados originais foi obviamente a que possibilitou uma melhor diferenciação entre os tipos de plantas (Planta1 e Planta2) e também dos tipos de água (Água1, Água2 e Água3). A partir de sua comparação com as demais, pode-se analisar o desempenho da classificação nos níveis de menor resolução espacial, mesmo considerando que essas classificações foram

realizadas a partir de redes neurais artificiais com diferentes pesos entre as conexões.

Uma primeira análise pode ser feita, considerando a proporção de pixels atribuídos a cada classe, para cada imagem multiescala, cujos valores são mostrados na Tabela 8.

Tabela 8- Proporção de pixels por classes para os 4 níveis de resolução da imagem

Classes	4 metros		8 metros		16 metros		32 metros	
	(%)	Km ²	(%)	Km ²	(%)	Km ²	(%)	Km ²
Planta 1	1,6	1319,417	1,76	1451,359	2,52	2078,083	1,08	890,607
Planta 2	1,1	907,099	0,83	684,448	0,6	494,781	1,54	1269,939
Água1	4,35	3587,167	4,81	3966,499	4,17	3438,732	3,93	3240,820
Água2	4,16	3430,486	3,95	3257,312	3,99	3290,298	4,59	3785,079
Água3	0,09	74,217	0,06	49,478	0,04	32,985	0,1	82,463
Fundo	88,7	73145,227	88,59	73054,517	88,69	73136,981	88,75	73186,459

Para uma melhor análise, a partir dessa tabela, foi feito um gráfico mostrando a porcentagem de pixels para cada classe nos quatro níveis de resolução da imagem, e está apresentado na Figura 40.




Figura 40- Proporção de pixels por classe para os 4 níveis de resolução das classificações

Pela análise da porcentagem de pixels para cada classe (Tabela 8) e também pela Figura 40, percebe-se as duas classes de plantas não apresentam uma redução ou aumento sistemático na medida que a resolução da imagem é reduzida. Isso pode estar relacionado com a mistura de plantas nas áreas infestadas (que ficam suavizadas), e também pelo fato da RNA ter sido treinada individualmente para os vários níveis de resolução. Para as classes de água (Água1, Água2 e Água3) a proporção de pixels por classe não apresentou variações bruscas nos quatro níveis de resolução da imagem.

Para complementar a análise anterior, no sentido de incorporar o caráter espacial da definição das classes, foi elaborada a Figura 41, a qual mostra um gráfico contendo o índice de concordância *Kappa* resultante das tabulações cruzadas entre as imagens de 4 e 8; 4 e 16; 4 e 32 metros de resolução espacial.




Figura 41- Índice *Kappa* para as tabulações cruzadas

Pela análise do gráfico da Figura 41, pode-se perceber que a classe Água3 foi a que resultou em um menor grau de concordância espacial em todos os níveis de resolução. Isso pode ter acontecido pelo fato dessa classe ter a menor representatividade na imagem (pequena área) dificultando a coleta de amostras, e também, como dito anteriormente, pelo fato de que cada uma das imagens

multiescala ter sido treinada individualmente, resultando em redes diferentes. As classes Planta1 e Planta2 apresentam-se pouco coincidentes no gráfico, o que pode ser atribuído ao efeito da reamostragem do tamanho do pixels, suavizando as variações espectrais nas imagens de menor resolução espacial. As classes que apresentaram uma maior concordância foram aquelas que se apresentam na imagem com características espectrais distintas, como as demais classes de água. Assim, para a classe Água2, nos três níveis de resolução, apresentou-se estável, com o índice de concordância maior que 0,92. A classe Água1 apresentou um resultado sistemático, quanto menor a resolução da imagem, menor a concordância espacial entre os pixels.

7 CONSIDERAÇÕES FINAIS

Para o caso de estudo em questão, os resultados da utilização de um procedimento de análise multiescala na discriminação das classes de interesse indicaram que a redução sistemática na resolução espacial das imagens multiespectrais Ikonos não teve influencia 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 por apenas um tipo de planta específico, apenas infestações mistas, porém mostrando as áreas com maiores quantidades de cada planta aquática presente no reservatório.

O procedimento metodológico aplicado no processamento das imagens IKONOS, gerou imagens multiescala com resoluções espaciais de 8, 16 e 32 metros e, a partir dessas imagens foi possível verificar até qual o nível de resolução o classificador (RNA) conseguiu distinguir os alvos de interesse, e também mapear as diferenças entre os tipos de plantas aquáticas e a água no presente no reservatório.

A aplicação das Redes Neurais Artificiais na classificação dos dados multiespectrais, apesar de necessitar um alto tempo de processamento na etapa de treinamento, permite incorporar dados de natureza não espectral que, neste caso se constituíram da imagem de textura e da imagem índice de vegetação. A incorporação destes dados foi muito importante para o treinamento e também para a discriminação das classes, visto a alta similaridade das bandas multiespectrais IKONOS para as classes em questão (Plantas1, Plantas2, Água1, Água2, Água3).

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, quanto menor a resolução fica mais difícil identificar as classes de interesse. Para as imagens de 4 e 8 metros de resolução espacial não houve maiores dificuldades na coleta de amostras, a partir de 16 metros de resolução, os tipos de plantas, principalmente, 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 devido a mistura dos pixels causada pela reamostragem.

Outra questão relevante na aplicação das Redes Neurais Artificiais para as imagens multiescala, é a questão da definição dos parâmetros necessários para o treinamento e classificação dos dados. Assim, primeiramente foram definidos os parâmetros para o treinamento da rede para a imagem original, a rede foi treinada e então as imagens foram classificadas. Após o ajustamento dos pesos, e verificada a consistência da classificação da imagem original, os mesmos parâmetros definidos para a esta imagem foram utilizados para o treinamento das imagens multiescala (8, 16 e 32 metros de resolução espacial). No entanto, houve necessidade de aumentar o número de iterações no único treinamento das 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 a menor separabilidade das classes nas imagens de média e baixa resolução (

suavização das variações). Os mapas temáticos resultantes dessa classificação mostraram bem essa situação.

Pelas análises realizadas mediante a tabulação cruzada, verificou-se que as classes Planta1 e Planta2 foram as menos coincidentes, devido a reamostragem da imagem que resultou em médias próximas para os níveis de cinza, dificultando a 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 das RNA na classificação supervisionada de plantas aquáticas e água em reservatórios mostrou-se uma abordagem promissora na detecção e no monitoramento destas plantas. Quando há a necessidade diferenciar os tipos de plantas presentes em reservatórios, é necessário a utilização de imagens de alta resolução espacial (como neste caso, IKONOS), porém se o caso for apenas detectar se existem ou saber as áreas afetadas, imagens de média resolução (TM/LANDSAT e CCD/CBERS) são suficientes para isso.

Tendo em vista os resultados obtidos considera-se que as imagens orbitais de Sensoriamento Remoto constituem-se de uma fonte de dados útil para representar espacialmente e fornecer informações importantes para análises de reservatórios. O uso das Redes Neurais Artificiais e imagens multiescala permitiram a avaliação da dispersão espacial das plantas aquáticas e o nível de resolução necessário para a classificação da imagem, para o reservatório de Salto Grande.

8 REFERÊNCIAS BIBLIOGRÁFICAS

BOCANEGRA, C.W.R. Procedimentos para tornar mais Efetivo o Uso das Redes Neurais Artificiais em Planejamento de Transportes. São Carlos, 2002. Dissertação (Mestrado), Escola de Engenharia de São Carlos. Universidade de São Paulo, São Carlos.

BRONDINO, N.C.M. Estudo da Influencia da Acessibilidade no Valor de Lotes Urbanos Através do Uso de Redes Neurais, São Carlos, SP, 1999. Tese (Doutorado em Engenharia Civil – Transportes) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

BURT P.J. Fast filter tranforms of image processing. Computer Vision, Graphics, and Image Processing, 16:20-51, 1981.

CAVENAGHI, A. L. “Caracterização da qualidade da água e sedimento relacionados com a ocorrência de plantas aquáticas em cinco reservatórios da bacia do rio Tietê”, 2003, 73 f. Tese (Doutorado em Agronomia - Proteção de Plantas) – Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista “Julio Mesquita Filho”, Botucatu.

CENTENO, J.A.S. Sensoriamento Remoto e Processamento Digital de Imagens. Departamento de Geomática, UFPR, Curitiba, 2003, 210p.

CONGALTON, R.G.; ODERWALD, R.G.; MEAD, R.A. Assessing Landsat classification accuracy using discrete multivariate analysis statistical techniques. Photogrammetric Engineering and Remote Sensing, 1983, 1671-1678p.

_____.; GREEN, K. Assessing the Accuracy of Remotely Sensed Data: Principles and Practices. Boca Ratton: Lewis Publishers, 1999, 137p. Cap. 3, pg. 12-14, 1999.

CROSTA, A. P.. Processamento digital de imagens de sensoriamento remoto. IAG/UNICAMP, Campinas, 1992. 170p.

CROWELEY J. R. Representation for visual Inf. PhD thesis, Carnegie – Mellon University, Robotics Institute, Pittsburgh, Pennsylvania, 1981.

CUNHA, A. M. Espaço-escala detecção de arestas. Dissertação de mestrado, IMPA. 2000, Rio de Janeiro-RJ.

CURRAN, P.J. Principles of Remote Sensing. 1983. Longman , 282 p.

EASTMAN, J.R. Idrisi for windows – User's guide, version 2.0. Worcenter, Clark Labs for Cartographic Technology and Geographic Analysis, Clark University, 1998.

ESPINHOSA, M. C. Utilização do Sensoriamento Remoto Orbital e Redes Neurais Artificiais no mapeamento de macrófitas aquáticas emersas em grandes reservatórios. Presidente Prudente, 2004. Dissertação de Mestrado, Faculdade de Ciências e Tecnologia. UNESP.

GALO, M. L. B. T. Aplicação de redes neurais artificiais e sensoriamento remoto na caracterização ambiental do Parque Estadual Morro do Diabo. São Carlos, 2000a. 205f. Tese (Doutorado), Escola de Engenharia de São Carlos. Universidade de São Paulo.

_____, 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.

GOMES, J; VELHO L.; Computação Gráfica: Imagem, 1994. Rio de Janeiro. IMPA-SBM p. 424.

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

GONZALES, R. C.; WOODS, R. E.. Recognition and Interpretation. In: Digital Image Processing. Reading, Addison-Wesley, 1993.

INPE – Instituto Nacional de Pesquisas Espaciais. (2002). *Tutorial* – SPRING 3.6.

LEE, J.; WEGER, R. G.; SENGUPTA, S. K.; WELCH, R. M. A neural network approach to cloud classification. IEEE Transaction on Geoscience and Remote Sensing, v.28, n.5, 1990, p.846-55.

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

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

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

MARQUES, A. J. Mapeamento de fragmentos de mata no município de Maringá, PR: Uma abordagem da ecologia da Paisagem. Presidente Prudente, 2004. Dissertação de Mestrado, Faculdade de Ciências e Tecnologia. UNESP.

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 Blucher, 1989.

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

_____; 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.

RAIA, A. A. J.. Acessibilidade e Mobilidade na Estimativa de um Índice de Potencial de Viagens Utilizando Redes Neurais Artificiais. São Carlos, SP, 2000, Tese (Doutorado em Engenharia Civil – Transportes) – Escola de Engenharia de São Carlos, Universidade de São Paulo.

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

ROBIN, M. La Télédétection. Coll. Fac Géographie. Paris. Nathan. 1995

ROSENFELD, G.H.; FITZPATRICK-LINZ, K. (1986). A coefficient of agreement as a measure of thematic classification accuracy. Photogrammetric Engineering and Remote Sensing, 52(2):223-227.

SCHALKOFF, R.. Pattern Recognition: Statistical, Structural and Neural Approaches. Singapore, 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.

SCHENK, T. Digital Photogrammetry, Ohio: TerraScience, 1999. v.1, 428p.

STUCKI, P: Image Processing for Document Reproduction: Advances in Digital Image Processing, New York, 1979.

TATIBANA & KAETSU. Uma Introdução a Redes Neurais. Disponível em:
<www.din.uem.br/ia/neuruais>. Acesso em: 2000.

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.

ZELL, A. et al. SNNS: Stuttgart Neural Network Simulator. User Manual, Version 4.1. Stuttgart, University of Stuttgart, 1995 (Report No. 6/95).

Apêndice I

(comandos usados no software Matlab 3.6)

Apêndice I

Os comandos utilizados para o desenvolvimento do trabalho a partir do software Matlab:

Acessar um diretório

Para passar para uma determinada área, procede-se da seguinte maneira:

cd (local ou nome da área em questão)

Exemplo: >> cd c:/ teste

Abrir uma imagem

Para abrir uma imagem qualquer:

imread('nome da imagem.extensão')

Exemplo: >> a=imread('imagem.tif');

Procedimentos para os procesamentos

Transformar a imagem em double:

Imagem = double(imagem que foi aberta);

Exemplo: >> a=double(a);

Binarização da imagem da represa:

Nome da imagem resultante = nome da imagem a ser binarizada >0, assim a imagem conterá apenas os valores de a maiores que zero.

Exemplo: >> bin=a>0;

Multiplicação da imagem da represa com as bandas da imagem Ikonos:

Nome da imagem resultante= nome da imagem da represa.* banda IKONOS

Exemplo: >> Azul-rio= bin.*AZUL;

Transformar a imagem em um padrão para a visualização:

Nome da imagem= uint8 (nome)

Exemplo: >> AZUL= uint8 (azul-rio);

Mostrar a imagem resultante:

Imshow (nome da imagem a ser mostrada);

Exemplo: >> azul-represa =imshow(AZUL);

Salvar a imagem em um formato tiff:

imwrite (nome da imagem de entrada, 'nome da imagem de saída.extensão')

Exemplo: imwrite (AZUL, ' AZUL_recortada.tiff ');

Apêndice II

(Represa de Salto Grande – Americana/SP)

APÊNDICE II
RESERVATÓRIO DE SALTO GRANDE - AMERICANA / SP



ESCALA APROXIMADA
1/ 45000

